

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KRONİK BÖBREK HASTALIĞI VE DİYABET İÇİN
ELEKTROKARDİYOGRAM ÜZERİNDEN İYONİK
KONSANTRASYON TAHMİNİ**

DOKTORA TEZİ

Sebahattin BABUR

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

ARALIK 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KRONİK BÖBREK HASTALIĞI VE DİYABET İÇİN
ELEKTROKARDİYOGRAM ÜZERİNDEN İYONİK
KONSANTRASYON TAHMİNİ**

DOKTORA TEZİ

Sebahattin BABUR

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Mühendisliği Bilim Dalı

Tez Danışmanı: Prof.Dr. Mehmet Recep BOZKURT

Ortak Danışman: Dr. Öğr. Üyesi Sanam MOGHADDAMNIA

ARALIK 2024

Sebahattin Babur tarafından hazırlanan “Kronik böbrek hastalığı ve diyabet için elektrokardiyogram üzerinden iyonik konsantrasyon tahmini” adlı tez çalışması 13.12.2024 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 :

Jüri Üyesi :

Jüri Üyesi :

Jüri Üyesi :

Jüri Üyesi :



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 “KRONİK BÖBREK HASTALIĞI VE DİYABET İÇİN ELEKTROKARDİYOGRAM ÜZERİNDEN İYONİK KONSANTRASYON TAHMİNİ” 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, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(13/12/2024)

Sebahattin BABUR





Eşime ve çocuklarıma,



TEŞEKKÜR

Bu tez çalışması boyunca bana yol gösteren, bilgi ve deneyimleriyle tezimin her aşamasında yanımda olan saygıdeğer tez danışmanım Prof.Dr. Mehmet Recep Bozkurt'a en içten teşekkürlerimi sunarım. Ayrıca, bu süreçte desteğini esirgemeyen ve katkılarıyla tezin tamamlanmasına yardımcı olan eş danışmanım Dr. Öğretim Üyesi Sanam Moghaddamnia'ya da teşekkür ederim.

Tezimin gerçekleştirilmesinde maddi ve manevi destek sağlayan aileme, arkadaşlarıma ve değerli meslektaşlarıma teşekkürü borç bilirim.

Sebahattin BABUR



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	xxv
1. GİRİŞ	1
1.1. Literatür Araştırması	1
2. KANDAKİ İYONİK KONSANTRASYON DEĞİŞİKLİĞİNE BAĞLI HASTALIKLAR	11
2.1. Kronik Böbrek Hastalığı	11
2.1.1. Tanım ve sınıflandırma	11
2.1.2. EKG tabanlı kan potasyum ve kalsiyum tahmini	12
2.2. Diyabet Hastalığı	13
2.2.1. Tanım ve sınıflandırma	14
2.2.2. EKG tabanlı kan glükoz tahmini	14
3. ELEKTROKARDİYOĞRAFI SİNYALİNİN İNCELENMESİ	17
3.1. EKG Sinyalinin Oluşumu ve Ölçülmesi	17
3.2. EKG Sinyalinin Analizi ve İşlenmesi	18
3.3. EKG Sinyalini İnceleme Metotları	21
4. VERİ SETLERİ	23
4.1. MIMIC III Veri Seti	23
4.1.1. MIMIC-III ikili özellik etiketleme	25
4.2. D1NAMO Veri Seti	25
5. ÖZELLİK ÇIKARMA	29
5.1. Giriş	29
5.2. Morfolojik ve Zaman Tabanlı Özellikleri	29
5.2.1. Morfolojik özellikler	29
5.2.2. Sinyal özellikleri	29
5.2.2.1. İstatistiksel özellikler	29
5.2.2.2. İmpulsif özellikler	30
5.2.2.3. Harmonik özellikler	31
5.2.3. Zaman serisinde özellikler	32
5.2.3.1. Dağılım özellikleri	32
5.2.3.2. Otokorelasyon özellikleri	32
5.2.3.3. Kısmi otokorelasyon özellikleri	32
5.3. Frekans Tabanlı Özellikler	32
5.3.1. Spektral tepe değerleri	33

5.3.2. Modal katsayıları.....	33
5.3.3. Bandpower	33
5.4. Zaman-Frekans Tabanlı Özellikler.....	34
5.4.1. Spektrogram özellikleri	34
5.4.2. Ampirik mod ayrıştırma özellikleri.....	34
5.5. Veri Seti İstatistikleri.....	37
6. METODLAR	39
6.1. Giriş	39
6.2. Özellik Seçme Algoritması.....	39
6.2.1. F-test özellik seçme algoritması	39
6.2.2. ANOVA özellik seçme algoritması	40
6.3. Makine Öğrenmesi Metodları.....	40
6.3.1. Regresyon algoritmaları	41
6.3.1.1. Yapay sinir ağı regresyon modeli.....	41
6.3.1.2. Regresyon tabanlı FIS modeli	42
6.3.1.3. Ensemble regresyon	43
6.3.2. Sınıflandırma algoritmaları	43
6.3.2.1. Destek vektör makinaları	43
6.3.2.2. Ensemble sınıflandırma.....	43
6.3.2.3. K-en yakın komşu algoritması	44
6.3.3. Hiperparametre ayarı.....	44
6.4. Performans Değerlendirme Kriterleri.....	48
7. SONUÇLAR	51
7.1. Özellik Seçme.....	51
7.2. Sınıflandırma Sonuçları.....	59
7.3. Regresyon Sonuçları.....	65
8. TARTIŞMA VE KARAR	71
KAYNAKLAR.....	75
ÖZGEÇMİŞ.....	83

KISALTMALAR

ABP	: Arteriyel kan basıncı
ACC	: Akselerometre
ACF	: Otokorelasyon değeri
CGM	: Sürekli glikoz izleme
CNN	: Konvolüsyonel sinir ağları
DVM	: Destek vektör makineleri
EKG	: Elektrokardiyografi
EMD	: Ampirik mod ayrıştırma
FIS	: Bulanık çıkarım sistemleri
GFH	: Glomerüler filtrasyon hızı
HbA1c	: Hemoglobin
HHT	: Hilbert-Huang dönüşümü
HR	: Kalp atış hızı
HRV	: Kalp atış hızı değişkenliği
IMF	: İçsel mod fonksiyonu
IQR	: Çeyrekler arası genişlik
KBH	: Kronik böbrek hastalığı
KDIGO	: Böbrek hastalığı: küresel sonuçların iyileştirilmesi
kNN	: k-En yakın komşu
MARD	: Ortalama mutlak göreceli fark
MCC	: Matthews korelasyon katsayısı
NN-R	: Yapay sinir ağı regresyonu
PACF	: Kısmi otokorelasyon değeri
PACF	: Kısmi otokorelasyon fonksiyonu
PAK	: Persistan albüminüri kategorileri
PCA	: Ana bileşen analizi
PCA	: Ana bileşen analizi
PPG	: Fotopletismografi
PSD	: Güç spektral yoğunluğu
RCNN	: Bölge tabanlı konvolüsyonel sinir ağları

RMS	: Karekök ortalama
RMSE	: Hataların ortalama kare kökü
RMSE	: Kök ortalama kare hatası
SE	: Spektral entropi
SF	: Şekil faktörü
SINAD	: Sinyal-gürültü ve bozulma oranı
SK	: Spektral kurtosis
SMNR	: Sinyal modülasyon gürültü oranı
SNR	: Sinyal gürültü oranı
ssACF	: Otokorelasyon değerinin karelerinin toplamı
ssPACF	: Kısmi otokorelasyon değerinin karelerinin toplamı
T1DM	: Tip 1 diyabet
T2DM	: Tip 2 diyabet
THD	: Toplam harmonik distorsiyon
WE	: Dalgacık entropisi
YBN	: Yatak başı noktası
YSA	: Yapay sinir ağları
YZ	: Yapay zeka

SİMGELER

$ x_i $	: i. özelliğın mutlak değeri
imf_i	: İçsel mod değeri
p_j	: Belirli bir sınıfa ait veri noktalarının kesiri
$p_x(k)$	: k. frekans bileşinindeki SMNR değeri
$\bar{x}$	: Ortalama
x_{SF}	: Sinyalin şekil faktörü
$x_{clearance}$	: Temizlik faktörü
x_{crest}	: Tepe faktörü
x_i	: i. özelliğın değeri
$x_{impulse}$	: İmpuls faktörü
$x_{kurtosis}$	: Basıklık
x_{peak}	: Peak değeri
x_{rms}	: Ortalama karakök değeri (Root mean squared value)
$x_{skewness}$	: Çarpıklık
μ_j	: Belirli bir sınıftaki veri noktalarının ortalaması
σ_j	: Belirli bir sınıftaki veri noktalarının standart sapması
i	: i. örnek sayısı
mEq/l	: Miliekivalan/litre
mM	: Milimolar
$mmol/l$	: Milimole/litre
N	: Vektör eleman sayısı
R^2	: Çoklu korelasyon katsayısı
W_n	: Doğal frekanslar
$Zeta$	: Sönümleme katsayıları
$p(k)$	: k. normalize edilmiş güç değeri
μ	: Özelliğe ilişkin verilerin küresel ortalaması



TABLO LİSTESİ

Sayfa

Tablo 2.1. 2012 KDIGO Kılavuzu'na göre kronik böbrek hastalığında GFH kategorileri.	12
Tablo 4.1. İyon konsantrasyonlarıyla eşleşen dalga formlarının sayısı.	24
Tablo 4.2. Böbrek hastalıkları için ilgili ICD kodları.	25
Tablo 4.3. Yaş grubunu kategorize etme.	25
Tablo 4.4. Veri setinin istatistikleri (Dubosson vd., 2018).	27
Tablo 5.1. EKG sinyali için morfolojik ve istatistiksel zaman tabanlı özellikleri. ...	35
Tablo 5.2. EKG sinyali için zaman serisi özellikleri.	36
Tablo 5.3. EKG sinyali için frekans tabanında özellikler.	36
Tablo 5.4. EKG sinyali için zaman-frekans tabanında spektrogram ve EMD özellikleri.	36
Tablo 5.5. Özellik gruplarının kategorize edilmesi ve veri seti örnek sayısı.	37
Tablo 6.1. Potasyum ve Kalsiyum için sınıflandırma modellerinde kullanılan hiperparametre optimizasyon stratejisi.	46
Tablo 6.2. Glükoz için sınıflandırma modellerinde kullanılan hiperparametre optimizasyon stratejisi.	47
Tablo 7.1. İyonik konsantrasyonların sınıflandırılmasında kullanmak için ANOVA ile özellik seçme sonuçları.	58
Tablo 7.2. İyonik konsantrasyonların regresyon tahmininde kullanmak için F-test ile özellik seçme sonuçları.	59
Tablo 7.3. Glükoz için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları.	60
Tablo 7.4. Glükoz için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları.	60
Tablo 7.5. Glükoz için belirlenen özelliklere ait Ensemble sınıflandırıcı sonuçları.	61
Tablo 7.6. Kalsiyum için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları. ...	61
Tablo 7.7. Kalsiyum için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları. ...	62
Tablo 7.8. Kalsiyum için belirlenen özelliklere ait Ensemble sınıflandırıcı sonuçları.	62
Tablo 7.9. Potasyum için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları. ...	63
Tablo 7.10. Potasyum için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları. ...	63
Tablo 7.11. Potasyum için belirlenen özelliklere ait Ensemble öğrenme sınıflandırıcı sonuçları.	64
Tablo 7.12. Sınıflandırma sonuçları için genel değerlendirme tablosu.	64
Tablo 7.13. Potasyum için belirlenen özelliklere ait regresyon sonuçları.	66
Tablo 7.14. Kalsiyum için belirlenen özelliklere ait regresyon sonuçları.	67
Tablo 7.15. Glükoz için belirlenen özelliklere ait regresyon sonuçları.	68



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Tez genel akış diyagramı.	10
Şekil 2.1. KDIGO 2012: GFH ve albüminüri kategorilerine göre kronik böbrek hastalığı prognozu (Levey vd., 2005).	12
Şekil 3.1. EKG sinyalinin oluşumu (Gong vd., 2024).	17
Şekil 3.2. Tipik 10 elektrot konfigürasyonu (Luz vd., 2016).	18
Şekil 3.3. Sinyal ön işleme aşamaları a) Ham EKG sinyali b) Temel düzey kaldırıldı c) Yüksek ve düşük geçiren filtreleme d) Temiz sinyal.	19
Şekil 3.4. Ön sinyal işleme P, QRS, T tespiti için önerilen algoritma (Pilia vd., 2021).	20
Şekil 3.5. FilterBank yöntemi ile P-QRS-T noktalarının tespiti.	20
Şekil 3.6. Konsantrasyon değişikliklerini belirlemek için değerlendirilen EKG morfolojik özellikleri (Dillon vd., 2015).	21
Şekil 4.1. MIMIC III veritabanındaki hasta verilerindeki iyon konsantrasyonlarının incelenmesi.	24
Şekil 4.2. MIMIC III kayıtlarının işleme akışı.	24
Şekil 4.3. Zephyr BioHarness 3, D1NAMO veri setini toplama aşamasında kullanıldı (Dubosson vd., 2018).	26
Şekil 4.4. Veri örnekleri (Dubosson vd., 2018).	27
Şekil 6.1. Yapay sinir ağları regresyon modeli diyagramı.	42
Şekil 7.1. Diyabet hastası için glukoz konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.	52
Şekil 7.2. KBH hastası için kalsiyum konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.	53
Şekil 7.3. KBH hastası için potasyum konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.	54
Şekil 7.4. Diyabet hastası için glukoz konsantrasyonunun F-test istatistiksel analiz sonuçları.	55
Şekil 7.5. KBH hastaları için kalsiyum konsantrasyonunun F-test istatistiksel analiz sonuçları.	56
Şekil 7.6. KBH hastaları için potasyum konsantrasyonunun F-test istatistiksel analiz sonuçları.	57



KRONİK BÖBREK HASTALIĞI VE DİYABET İÇİN ELEKTROKARDİYOGRAM ÜZERİNDEN İYONİK KONSANTRASYON TAHMİNİ

ÖZET

Kronik böbrek hastalığı ülkemizde ve dünyada önemli bir sağlık problemi olarak ortaya çıkmaktadır. Türk Nefroloji Derneği tarafından ülkemizde yapılan çalışmalarda, erişkinlerin %15,7'sinde çeşitli evrelerde kronik böbrek hastası bulunmaktadır. Bu oranın, yaklaşık olarak 7,5 milyona yakın kişinin kronik böbrek hastası bulunduğunu ve her 7 erişkinden birinin böbrek hastası olduğu anlamına gelmektedir. Bu hastalar için ilk tedavi hemodiyalizdir. Bununla birlikte, diyalize giren hastalarda kardiyovasküler hastalıkların neden olduğu ölüm sıklığı, genel popülasyona göre %10 ile %30 daha yüksektir. Bu iki hastalık arasındaki bağlantı nedenlerinden biri, iki hasta grubunda kalsiyum ve potasyumun değişen iyonik konsantrasyonları olabilmektedir. Alta yatan etkileri analiz etmek ve olası bir risk tahmini için diyalizden etkilenen iyonik konsantrasyonların sürekli olarak izlenmesinin önemli olduğu görülmektedir. Özellikle hemodiyaliz tedavisi gören hastalarda, elektrokardiyogram (EKG) tabanlı kan potasyum (K^+) ve kalsiyum (Ca^{2+}) seviyelerinin tahmini, elektrolit dengesizliklerini izlemek için umut verici bir invaziv olmayan yöntemdir. Bu yöntem, QRS kompleksi ve T dalgası gibi EKG sinyallerindeki morfolojik değişikliklerden yararlanarak serum elektrolit konsantrasyonlarını tahmin edebilir ve bu da sık sık kan testlerine olan ihtiyacı azaltılmasına yardımcı olmaktadır.

Kronik böbrek hastalığına benzer bir şekilde Diyabet hastalığı, insülin salgısındaki, insülin etkisindeki veya her ikisindeki bozukluklar nedeniyle hiperglisemi ile karakterize edilen bir durumdur ve bu da uzun vadede organ hasarına yol açmaktadır. Patojenik süreçler, pankreatik β -hücrelerin otoimmün yıkımından insülin direncine ve yetersiz insülin salgılanmasına neden olmaktadır. Diyabet hastalığının belirtileri arasında kilo kaybı ve bulanık görme yer almaktadır. Kronik hiperglisemi, büyüme bozukluğuna ve enfeksiyonlara karşı artan duyarlılığa yol açmaktadır. Akut uzun vadeli komplikasyonlar arasında retinopati, nefropati, periferik ve otonom sinir hastalığı ile kardiyovasküler hastalıklar için risk bulunmaktadır. EKG ve kan şekeri arasındaki ilişki, son dönemde yapılan araştırmaların önemli bir odak noktası haline gelmiştir. Kan şekeri seviyelerindeki değişimlerin, kalbin elektriksel aktivitesini etkilediği bilinmektedir. Hipoglisemi (düşük kan şekeri) ve hiperglisemi (yüksek kan şekeri) dönemleri, EKG'deki belirli parametreler üzerinde önemli etkiler yaratmaktadır. Özellikle, ST, QT, PR aralıkları ve HRV parametreleri bu değişikliklere duyarlı olabilir. Yapılan çalışmalar, bu parametreler ile kan şekeri seviyeleri arasında bir doğrusal ilişki olduğunu göstermektedir. Bu bulgu, kan şekeri seviyelerinin non-invaziv olarak EKG verileri üzerinden tahmin edilmesine olanak tanıyacak yeni yöntemlerin geliştirilmesine kapı aralamaktadır. Böylelikle, sürekli glukoz takibinin, özellikle diyabet hastaları için, ağrısız, düşük maliyetli ve kullanıcı dostu bir yöntemle sağlanabileceği düşünülmektedir.

Diyabet ve kronik böbrek hastalığı (KBH) gibi yaygın sağlık sorunlarını yönetmek için elektrolit dengesizliklerini doğru bir şekilde izlemek, hastaların tedavi süreçlerini iyileştirmek için çok önemlidir. Bu dengesizliklerin izlenmesi mevcut klinik uygulamalarda genellikle kan testleri ile yapılmaktadır. Bununla birlikte, bu testlerin invaziv olması hastaları rahatsız edebilir ve sürekli gözlem gerektiren durumlarda yetersiz olabilir. Sonuç olarak, çağdaş tıp, daha az invaziv olan ve sürekli takip gerektiren alternatif yöntemler üretilmelidir.

Bu tez çalışması, iyonik konsantrasyonları izlemek için biyo-sinyallerin, özellikle EKG sinyallerinin nasıl kullanılabileceğini incelemektedir. EKG, kalbin elektriksel aktivitesini kaydeder ve vücuttaki elektrolit seviyelerindeki değişiklikler bu sinyallerle ilişkilendirilebilir. Elektrolit seviyelerindeki değişiklikler, EKG’de belirli dalgalar üzerinde morfolojik değişikliklere sebep olabilir. Bu elektrolit ve EKG arasındaki ilişki, EKG sinyallerinin iyonik konsantrasyon tahmininde kullanılabileceğini göstermektedir.

Çalışmada, Potasyum, Kalsiyum ve Glükoz için sırasıyla 116, 101 ve 1062 bireyden alınan EKG sinyali kullanılmıştır. Sınıflandırma ve regresyon için EKG sinyali kullanılarak yapay zekâ tabanlı algoritmalar tasarlanmıştır. Çalışma için EKG’den 61, özellik çıkarılmıştır. Çıkarılan özelliklerin, ANOVA ve F-test yöntemiyle, istatistiksel olarak, normal ve anormal durumlar veya konsantrasyon seviyeleri için ayırt edici olup olmadığı tespit edilmeye çalışılmıştır. Ayrıca, özellikler, ANOVA ve F-test özellik seçme yöntemleriyle üç defa azaltılarak sınıflandırma ve regresyon algoritmalarına uygulanmıştır.

Çalışmanın ilk bölümünde makine öğrenmesi yöntemlerinin bu alanda nasıl kullanılabileceği tartışılmıştır k-NN, DVM ve Ensemble Öğrenme Yöntemleri kullanarak potasyum, kalsiyum ve glükoz konsantrasyonlarındaki anormal ve normal durumları tahmin etmek için sınıflandırma modelleri incelenmiştir. Bu modellerin performansı, doğruluk, duyarlılık, özgüllük, F-ölçümü, MCC ve kappa skoru dahil olmak üzere bir dizi kriter kullanılarak karşılaştırılmıştır. Sınıflandırma sonuçlarına göre kalsiyum verisi için normal ve anormal durumları 14 özellik ile, %75,93 duyarlılık, %55,32 özgüllük ve %66,34 sınıflandırma doğruluk oranı ile k-NN sınıflandırıcısı yardımıyla başarı ile sınıflandırılmıştır. Potasyum verisi için normal ve anormal durumları 6 özellik ile, %47,83 duyarlılık, %86,02 özgüllük ve %78,45 sınıflandırma doğruluk oranı ile Ensemble sınıflandırıcısı yardımıyla başarı ile sınıflandırılmıştır. Glükoz verisi için Hipoglisemi Hiperglisemi Euglisemi durumlarını 61 özellik ile, %56,47 duyarlılık, %80,52 özgüllük ve %80,13 sınıflandırma doğruluk oranı ile başarıyla gerçekleştirilmiştir.

Ensemble için belirlenen modeller, özellikle potasyum ve glükoz seviyelerinin tahmininde yüksek doğruluk göstermiştir. Ancak, düşük duyarlılık oranı nedeniyle doğru pozitif sonuçlar göz ardı edilir. Bu durum, modelin potasyum ve glükoz tahminlerinde yüksek doğruluk gerektiren ancak yanlış negatif sonuçların tolere edilebileceği durumlar için kullanılabileceğini göstermektedir. Kalsiyum seviyeleri üzerinde daha dengeli çalışan k-NN modeli en yüksek F-ölçümü skorunu almıştır. Bu, k-NN'nin yanlış pozitif ve negatif sonuçlar arasında denge gerektiren uygulamalar için uygun bir model olabileceğini göstermektedir. Ensemble yöntemleri, belirli bir alanda öne çıkmaksızın tüm ölçütlerde ortalama değerler sunarak dengeli bir yaklaşım sağlamıştır. Bu, modelin uygulamanın gereksinimlerine uygun olarak seçilmesi gerektiğini vurgulamaktadır.

Çalışmanın ikinci bölümünde, kronik böbrek hastalığı ve diyabet hastalarında kalsiyum, potasyum ve glukoz seviyelerinin tahminine yönelik regresyon modelleri ile yöntemler önerilmektedir. Bu hastalar için, iyonik konsantrasyonların doğru bir şekilde izlenmesi çok önemlidir. Bu konsantrasyon seviyelerindeki değişiklikler, hemodiyaliz tedavisi gören hastalarda kalp hastalığı riskini artırabilmekte ya da diyabet hastalarında ani kan şekeri yükselmesine bağlı sağlık sorunlarını ortaya çıkarabilmektedir. Bu nedenle, hastaların yaşam kalitesi ve hayatta kalma şansı, sürekli izleme ve hızlı müdahale ile artırılabilir. Bu amaçla, EKG sinyallerinden önemli özellikler karşılaştırılarak Ensemble regresyon, YSA regresyon modeli ve FIS regresyon algoritmaları kullanılarak değerlendirilmektedir. RMSE ve R^2 gibi ölçütler kullanılarak önerilen yaklaşımın performansı değerlendirilmiştir. Regresyon sonuçlarına göre konsantrasyon değerlerinin tahmininde, RMSE değeri 0,646 ve R^2 değeri 0,3495 ile potasyum için Ensemble regresyon yönteminde başarılı olmuştur. Kalsiyum veri kümesi için ise NN-R ile yüksek performans göstermektedir. Bu sonuçlara göre seçilen 4 özellik ile, R^2 0,3732 değeri ve RMSE 0,71 değeri elde edilmiştir. Glukoz için Ensemble yöntemler, Bagging modeli ile en düşük RMSE değeri olan 2,3061 ve R^2 0,4354, ile 13 özellikli modelde en iyi performansı göstermiştir. Bu da özellik seçiminin doğruluk üzerinde etkili olduğunu göstermektedir. NN-R algoritmasında ise, 2 katmanlı ve sigmoid aktivasyonlu model en iyi sonucu vermiştir (RMSE 2,8375, R^2 0,1737), ancak NN-R modellerinde genel olarak R^2 değerleri düşük kalmıştır. Bu durum, NN-R modellerinin bu veriyi açıklamada sınırlı kaldığını göstermektedir.

Sonuç olarak, bu doktora tezi çalışması, sağlık alanında iyonik konsantrasyonların izlenmesi ve tahmin edilmesi için yeni bir yöntem sunmaktadır. EKG sinyallerinin biyobelirteç olarak kullanılması, ucuz, güvenilir ve sürekli izleme sağlayan bir alternatif olarak büyük potansiyele sahiptir. Bu çalışmanın sonuçları, daha geniş kapsamlı klinik uygulamalar ve sağlık hizmetlerinde yeni teknolojiler için gelecekte temel oluşturabilir. Ek olarak, hastaların yaşam kalitesi ve sağlık hizmetlerinin etkinliği, bu yöntemlerin daha da geliştirilmesi ve mevcut sağlık izleme sistemlerine dahil edilmesi yoluyla iyileşecektir. Bu nedenle, sağlık alanında makine öğrenmesi ve sinyal işleme tekniklerinin daha yaygın olarak kullanılması beklenmektedir.



IONIC CONCENTRATION ESTIMATION FROM ELECTROCARDIOGRAM FOR CHRONIC KIDNEY DISEASE AND DIABETES

SUMMARY

Chronic kidney disease emerges as a significant health problem in our country and worldwide. In studies conducted in our country by the Turkish Nephrology Society, 15.7% of adults have chronic kidney disease at various stages. This rate means that there are approximately 7.5 million chronic kidney disease patients, which means that one in every 7 adults has kidney disease. The first treatment for these patients is hemodialysis. However, the mortality rate due to cardiovascular diseases in patients undergoing dialysis is 10% to 30% higher than in the general population. One of the reasons for the connection between these two diseases may be the varying ionic concentrations of calcium and potassium in the two patient groups. It appears to be important to continuously monitor the ionic concentrations affected by dialysis in order to analyze the underlying effects and predict potential risks. Especially in patients undergoing hemodialysis, the estimation of blood potassium (K^+) and calcium (Ca^{2+}) levels based on electrocardiogram (ECG) is a promising non-invasive method for monitoring electrolyte imbalances. This method can predict serum electrolyte concentrations by utilizing morphological changes in ECG signals such as the QRS complex and T wave, thereby helping to reduce the need for frequent blood tests.

Similar to chronic kidney disease, diabetes is a condition characterized by hyperglycemia due to disturbances in insulin secretion, insulin action, or both, which leads to organ damage in the long term. Pathogenic processes range from the autoimmune destruction of pancreatic β -cells to insulin resistance and insufficient insulin secretion. Among the symptoms of diabetes patients are weight loss and blurred vision. Chronic hyperglycemia leads to increased susceptibility to growth disorders and infections. Among the acute long-term complications, there is a risk of retinopathy, nephropathy, peripheral and autonomic nerve disease, as well as cardiovascular diseases. The relationship between EKG and blood sugar has recently become a significant focus of research. It is known that changes in blood sugar levels affect the electrical activity of the heart. Periods of hypoglycemia (low blood sugar) and hyperglycemia (high blood sugar) have significant effects on certain parameters in the ECG. Especially, the ST, QT, PR intervals, and heart rate variability (HRV) parameters may be sensitive to these changes. Studies have shown that there is a linear relationship between these parameters and blood sugar levels. This finding paves the way for the development of new methods that will allow blood sugar levels to be predicted non-invasively through ECG data. Thus, it is thought that continuous glucose monitoring could be provided in a painless, low-cost, and user-friendly manner, especially for diabetic patients.

To manage common health issues such as diabetes and chronic kidney disease (CKD), it is very important to accurately monitor electrolyte imbalances in order to improve patients' treatment processes. Monitoring these imbalances is generally done through

blood tests in current clinical practices. However, the invasiveness of these tests can discomfort patients and may be inadequate in situations requiring continuous monitoring. As a result, contemporary medicine should develop alternative methods that are less invasive and do not require continuous monitoring.

This thesis examines how biosignals, particularly ECG signals, can be used to monitor ionic concentrations. ECG records the electrical activity of the heart, and changes in electrolyte levels in the body can be associated with these signals. Changes in electrolyte levels can cause morphological changes in specific waves on the electrocardiogram. This relationship between electrolytes and ECG suggests that ECG signals can be used to predict ionic concentrations.

In the study, ECG signals from 116, 101, and 1062 individuals were used for Potassium, Calcium, and Glucose, respectively. Artificial intelligence-based algorithms have been designed using the ECG signal for classification and regression. For the study, 61 features were extracted from the ECG. It was attempted to determine whether the extracted features are statistically distinguishable for normal and abnormal conditions or concentration levels using the ANOVA and F-test methods. Additionally, the features were reduced three times using ANOVA and F-test feature selection methods and applied to classification and regression algorithms.

In the first part of the study, it was discussed how machine learning methods can be used in this field. Using K-Nearest Neighbors (k-NN), Support Vector Machines (SVM), and Ensemble Learning Methods, classification models were examined to predict abnormal and normal conditions in potassium, calcium, and glucose concentrations. The performance of these models was compared using a series of criteria, including accuracy, sensitivity, specificity, F-measure, Matthew's correlation coefficient (MCC), and kappa score. According to the classification results, normal and abnormal conditions for calcium data were successfully classified using the k-NN classifier with 14 features, achieving 75.93% sensitivity, 55.32% specificity, and a classification accuracy rate of 66.34%. For potassium data, normal and abnormal conditions were successfully classified using the Ensemble classifier with 6 features, achieving 47.83% sensitivity, 86.02% specificity, and a classification accuracy rate of 78.45%. For glucose data, the conditions of hypoglycemia, hyperglycemia, and euglycemia were successfully classified with 61 features, achieving 56.47% sensitivity, 80.52% specificity, and 80.13% classification accuracy. The models determined for the ensemble showed high accuracy, particularly in predicting potassium and glucose levels. However, due to the low sensitivity rate, true positive results are overlooked. This situation indicates that the model can be used for potassium and glucose predictions where high accuracy is required, but false negative results can be tolerated. The k-NN model, which works more balanced on calcium levels, received the highest F-measure score. This indicates that k-NN could be a suitable model for applications requiring a balance between false positive and false negative results. Ensemble methods have provided a balanced approach by offering average values across all criteria without excelling in any specific area. This emphasizes that the model should be selected according to the requirements of the application.

In the second part of the study, regression models and methods for predicting calcium, potassium, and glucose levels in patients with chronic kidney disease and diabetes are proposed. For these patients, it is very important to accurately monitor ionic concentrations. Changes in these concentration levels can increase the risk of heart

disease in patients undergoing hemodialysis or cause health problems related to sudden blood sugar spikes in diabetic patients. Therefore, patients' quality of life and chances of survival can be improved through continuous monitoring and rapid intervention. For this purpose, important features from ECG signals are compared and evaluated using Ensemble regression, Artificial Neural Network regression model, and fuzzy inference systems (FIS) regression algorithms. The performance of the proposed approach was evaluated using metrics such as RMSE and R^2 . According to the regression results, in the prediction of concentration values, the RMSE value was 0.646 and the R^2 value was 0.3495, indicating success for potassium using the Ensemble regression method. For the calcium dataset, it shows high performance with NN-R. According to these results, with the selected 4 features, an R^2 value of 0.3732 and an RMSE value of 0.71 were obtained. For glucose, Ensemble methods, with the Bagging model, showed the best performance in the 13-feature model, achieving the lowest RMSE value of 2.3061 and an R^2 of 0.4354. This shows that feature selection has an impact on accuracy. In the NN-R algorithm, the 2-layer model with sigmoid activation yielded the best result (RMSE 2.8375, R^2 0.1737), but overall, the R^2 values of the NN-R models remained low. This situation indicates that NN-R models are limited in explaining this data.

In conclusion, this doctoral thesis presents a new method for monitoring and predicting ionic concentrations in the field of health. The use of ECG signals as biomarkers has great potential as a cheap, reliable, and continuous monitoring alternative. The results of this study could serve as a foundation for broader clinical applications and new technologies in healthcare in the future. Additionally, the quality of life of patients and the effectiveness of healthcare services will improve through the further development of these methods and their integration into existing health monitoring systems. Therefore, it is expected that machine learning and signal processing techniques will be used more widely in the field of healthcare.

.



1. GİRİŞ

Tıp alanındaki teknolojik gelişmeler, hastalıkların daha erken teşhis edilmesini ve tedavi süreçlerinin daha etkili yürütülmesini sağlar. Bu teknolojik gelişmelerin odak noktası tıbbi görüntüleme ve sinyal işleme alanındaki gelişmelerdir. Tıbbi görüntüleme, vücuttaki iç organların ve dokuların kapsamlı bir şekilde incelenmesine olanak tanır, bu da hastalıkların erken aşamada tespit edilmesini kolaylaştırır. Sinyal işleme yöntemleri ise, genellikle karmaşık matematiksel modeller kullanarak verileri analiz eder ve teşhis yöntemlerinin doğruluğunu artırır. Bu yöntemler, hastalıkların teşhis edilmesinde ve sağlık durumlarının izlenmesinde çok önemlidir çünkü sinyalleri anlamlı bilgilere dönüştürerek klinik karar verme süreçlerine yardımcı olurlar.

Yapay zeka (YZ) alanı da son zamanlarda tıpta önemli bir rol oynamıştır. Klinik karar destek sistemleri, veri analizi ve görüntü tanıma gibi çeşitli alanlarda yapay zeka kullanıldığında, tıbbi süreçler daha verimli ve doğru hale gelmektedir. Özellikle büyük veri setleri ve karmaşık modeller kullanarak, yapay zeka hastalıkların teşhis ve tedavisinde devrim niteliğinde değişiklikler getirmiştir. Bu teknolojik trendler, kişiselleştirilmiş tıp uygulamalarını teşvik edebilir ve sağlık hizmetlerinin kalitesini artırmasını sağlayabilir.

1.1. Literatür Araştırması

Dünya çapında milyonlarca insan kronik böbrek hastalığı (KBH) ile mücadele etmektedir. Bu ciddi ve yaygın bir sağlık sorunudur. Küresel olarak %8 ile %16 arasında KBH hastası olduğu tahmin edilmektedir (Jha vd., 2013). KBH, Amerika Birleşik Devletleri'nde yaklaşık %13,1 ve Avrupa'da yaklaşık %18,38 oranında görülen en yaygın hastalıklardan biridir (Coresh vd., 2007; Hill vd., 2016). Bu hastalık ilerleyen bir süreç ve zamanla böbrek fonksiyonlarında giderek azalmasına neden olmaktadır. Hastalığın son aşamasında böbrek yetmezliği gelişir ve diyaliz veya böbrek nakli gerektirir. KBH'nin belirtilerini göstermesi uzun bir süre alabilir, bu durum erken teşhisi zorlaştırmaktadır. Böbrek hastalığı olan kişiler genellikle teşhis edilmeden kalmakta ve hastalar bu süreçte yeterli bakım alamamaktadır (Perotte vd., 2015).

Bu tez çalışması, iyonik konsantrasyon değişiklikleri ile ilişkili hastalıkların teşhis edilmesi zorluğunu, geçici önlemlerin ötesine geçen invaziv olmayan bir tanı yöntemi önererek ele almaktadır. Klinik olarak kabul edilen ancak invaziv olan geleneksel kan testlerinden farklı olarak, bu çalışma, elektrolit konsantrasyonlarının sürekli olarak evde izlenmesi için EKG veya biyo-sinyal kullanımını araştırmaktadır. Böbrek yetmezliği nedeniyle hastaların kan serum elektrolit konsantrasyonlarında değişiklikler meydana gelir. Kalsiyum, potasyum ve sodyum, kalbin elektrofizyolojisini etkileyen elektrolitler arasında yer alır. Bu nedenle, kronik böbrek hastalığı olan hastalar, kardiyovasküler hastalıklara yakalanma riski taşır (Sarnak vd., 2003). Potasyumda hiperkalemi ve hipokalemi, klinik denemelerde ani kalp ölümlerinin yaygın nedenleri arasındadır. Bu tür ölümcül sonuçları önlemek için potasyum (K^+) bozukluklarının derhal tespit edilmesi ve tedavi edilmesi gerekmektedir (C.-S. Lin vd., 2020; Priori vd., 2015)

Mevcut durumda, disskalemiya laboratuvar testleri ile teşhis edilmektedir. Yatak başı kan testleri elektrolit seviyelerinin geçici analizini sağlar, ancak bu testlerin doğruluğu ve hassasiyeti merkezi klinik laboratuvarlardan elde edilen sonuçlar kadar güvenilir olmayabilir. Acil servislerde hemşireler tarafından yapılan yatak başı noktası (YBN) testleri, çeşitli analitler için merkez laboratuvar sonuçları ile yüksek bir korelasyon göstermiş ve yalnızca 400 ölçümden 3'ü klinik olarak kabul edilebilir sapmaları aşmıştır (McIntosh vd., 2018). Bu farkın ana nedeni, tahmin edilen plazma potasyum K^+ konsantrasyonunun gerçek değerinin altında kalmasıdır, bu da hemoliz pseudo-hiperkalemisini ayırt etmeyi zorlaştırır. Özetle Pseudo-hiperkalemi, gerçek bir anormal durum olmadan kandaki potasyum seviyesinin yanlış bir şekilde yüksek ölçülmesi durumu olarak ifade edilir (Dylewski & Linas, 2018; Gavala & Myrianthefts, 2017). EK), kalp dokusu bu hastalığa oldukça duyarlı olduğu için, disskalemiya durumunda tipik değişiklikler gösterebilen kardiyak ve kardiyak olmayan acil hastalar için temel bir testtir. Hipokalemi ile ilişkili başlıca EKG değişiklikleri, T dalgası amplitüdünde azalma, ST-segment değişiklikleri, T dalgası tersine dönmesi, PR aralığında uzama ve QT aralığında (QTc) artış olarak sıralanabilir (Diercks vd., 2004a). Hiperkalemi için tipik EKG bulguları, uzun tepeli T dalgalarından ve kısaltılmış QT aralığından, uzatılmış PT aralığına ve P dalgasının kaybolmasına kadar ilerler. Ardından, genişleyen bir QRS kompleksi ve nihayetinde bir sinus dalga morfolojisi gözlenir (Diercks vd., 2004a; Slovis, 2002). Bu morfolojik değişiklikler

dissskalemiya durumunda iyi bilinse de, deneyimli klinisyenler bile bu belirtilerin tümünü tanımakta zorlanabilir (Van Mieghem vd., 2004).

Potasyum, en önemli hücre içi elektrolittir. Organizma içinde sistemin büyük bir kısmı, kan seviyesini ve genellikle nöromusküler aktiviteyi etkileyen hücre içi katyonlardan oluşur. Potasyum fazlalığının (hiperkalemi) birçok belirti ve semptomu, kardiyovasküler, merkezi sinir ve kas sistemlerinde görülür. Potasyum dengesi böbreklerde düzenlenir. Bu nedenle, potasyum kaybının büyük bir kısmı idrarda bulunur (Halperin & Kamel, 1998; Periz & Sanmartín, 1997).

Son dönem böbrek yetmezliği olan hastalar, böbreğin temel bir işlevi olan iç ortam düzenlemesinin eksikliği nedeniyle bir dizi hidro-elektrolitik değişiklik yaşar. Bu değişikliklerden biri olan hiperkalemi, nöromusküler semptomlar, elektrokardiyografik değişiklikler ve kardiyak aritmiler üzerinde yaygın bir etkiye sahiptir (Schaefer & Wolford, 2005; Szerlip vd., 1986). Hiperkalemi kötüleştikçe, potansiyel olarak ölümcül elektrokardiyografik değişiklikler meydana gelir ve yüksek T dalgaları, uzamış P-R aralığı, bradikardi, ventriküler aritmiler ve P dalgasının düzleşmesi ve kaybolması gibi kardiyak iletim değişikliklerine neden olur (A. Webster, 2002).

Bu elektrolitin serum seviyelerinin laboratuvarında belirlenmesi biraz zaman alabilir. Elektrokardiyografik izleme ve aynı zamanda hastalarda gösterilen semptomların belgelenmesi, sonuçlar yayınlandığında çok faydalı olabilir (Diercks vd., 2004b). Bir uzman, anormal durumlarda meydana gelebilecek değişikliklerin farkında ise, EKG çok yararlı bir tanı aracı olabilir (Szerlip vd., 1986).

Ayrıca, bu tanı aracı, halsizlik, kas zayıflığı ve yorgunluk gibi farklı nedenlerle hemodiyaliz hastalarının böbrek fonksiyonlarının nedeni olup olmadığını hızlı bir şekilde belirlemeye yardımcı olabilir (Evans & Greenberg, 2005; Fisch, 1973). Ayrıca, kronik böbrek hastalığı olan hastaların son aşamalarında hiperkalsemiyi daha iyi tolere ettiklerini ve normal böbrek fonksiyonuna sahip insanlara göre daha az aritmi ve nöromusküler belirti gösterdiklerini sonucuna varılmıştır (Diercks vd., 2004b; Frohnert vd., 1970).

Corsi ve arkadaşları, kanda potasyum konsantrasyonunun EKG üzerinde etkisi olduğunu ve özellikle T dalgasını etkilediğini belirtmiştir. Geliştirilen EKG tabanlı potasyum tahmin modeli, 23 hemodiyaliz hastasından alınan 3 ayrı ölçümden oluşan

69 örneği kapsamaktadır. Yazarlar, EKG sinyallerindeki T dalgasının azalan eğimi ile T dalgasının genlik değeri arasındaki oranı esas alarak bir tahmin şeması geliştirmiş ve bunu 12 örnekle test etmiştir. Test sonuçlarına göre, mutlak hata ve standart sapma sırasıyla $0,43 \pm 0,28$ mM olarak hesaplanmıştır. Bu çalışma, önerilen yöntemin hiper-ve hipokalemi riski taşıyan hastaların izlenmesinde etkili bir şekilde uygulanabilir olduğunu göstermiştir (Corsi vd., 2012).

Corsi, C., DeBie, J. ve arkadaşları, hemodiyaliz hastalarında kandan potasyum konsantrasyonunun invaziv olmayan ölçümü için 45 hemodiyaliz ve 12 LQT hastasından alınan 12 derivasyonlu EKG'leri analiz etmişlerdir. T dalgasının genliği ve azalan eğimi gibi ilgili özellikleri belirlemişlerdir. Sunulan tahminin kalitesi çapraz doğrulama ile değerlendirilmiştir. Test veri setinin sonuçlarına göre, mutlak hata ve standart sapma sırasıyla $-0,09 \pm 0,59$ mM ve $0,46 \pm 0,39$ mM olarak hesaplanmıştır. Çalışmada önerilen yöntemin hiper/hipokalemi riski taşıyan hastaların izlenmesinde etkili olduğu gösterilmiştir (Corsi vd., 2017).

Mesa, M. H., Pilia, N. ve arkadaşları, serum kalsiyum ve potasyum konsantrasyon seviyelerinin tahmininde derivasyon azaltma tekniklerinin etkinliğini incelemişlerdir. Tahmin modeli, EKG sinyallerinin standart sapmasını kullanarak geliştirilmiştir. Kalpten dönüştürülen elektrik sinyalleri, derivasyon azaltma yöntemleriyle kan konsantrasyonlarının lead V2 azaltımı sonucu elde edilmiştir. Sinyallerden elektrolit değişikliklerini tanımlayan beş özellik, ana bileşen analizi (PCA) ve maksimum genlik dönüşümü kullanılarak hesaplanmıştır. Hesaplanan özellikleri ve konsantrasyon değerlerini birleştirerek iyonik konsantrasyonları yeniden oluşturmak için birinci ve üçüncü dereceden polinom denklemi uygulanmıştır. Ayrıca, EKG'lere 30 dB beyaz Gauss gürültüsü ekleyerek klinik olarak ölçülen sinyaller simüle edilmiştir.

Analiz sonuçları, birinci dereceden polinom regresyon ile elde edilen potasyum ve kalsiyum tahmininin, sırasıyla $0,0003 \pm 0,0767$ mmol/l (ortalama $\pm$ standart sapma) ve $-0,0036 \pm 0,1710$ mmol/l olduğunu göstermiştir. Gürültülü sinyal senaryosu ile ilgili olarak, elde edilen sonuçlar sırasıyla potasyum ve kalsiyum için $-0,003 \pm 0,2040$ ve $-0,0002 \pm 0,2040$ mmol/l'dir (Hernández Mesa vd., 2019).

Sánchez ve arkadaşları, son dönem kronik böbrek hastalığı olan hastalarda potasyumla ilgili elektrokardiyografik değişikliklerin değerlendirilmesi ve önceki çalışmalarla karşılaştırılmasını gerçekleştirmiştir. Çalışma, hemodiyaliz hastalarının hemodiyaliz

öncesi ve sonrası serum potasyum ve diğer elektrolit konsantrasyonlarını ölçmüş ve ilk oturumda eşzamanlı olarak 12 derivasyonlu EKG sinyalleri elde etmiştir. Tüm hastaların EKG'leri uzman bir doktor tarafından değerlendirilmiş ve yaş ortalaması 67,35 (24-89) olan 39 hasta çalışmaya dahil edilmiştir; bunların %58,9'u kadın ve %41,1'i erkektir. Hemodiyaliz öncesi serum potasyum aralığı 2,8 ile 7,4 mEq/l (ortalama 5,07 mEq/l) arasında değişmektedir. Örneğin, hastaların %29,4'ünde serum potasyum seviyeleri 5,5 mEq/l olup, V2 derivasyonunda T dalgalarının tepe değeri en sık görülen değişikliklerdir. Ayrıca, V4 derivasyonunda hiperkalemi vakalarında, T dalgasının ortalama yüksekliği 7 mm'dir. Sonuçlar, EKG'nin hiperkaleminin erken tahmini ve tanısında yararlı bir araç olabileceğini göstermektedir (Sánchez vd., 2007).

Mesa, M. H., Pilia, N. ve arkadaşları, elektrolit varyasyonunun kardiyak sinyaller (aksiyon potansiyeli ve EKG) üzerindeki etkilerini, kronik böbrek hastalığı ve kardiyovasküler hastalıklar arasındaki bağı incelemek için bir tahmin modeli kullanarak incelemişlerdir. İlk adım, hücresel düzeyde ventriküler hücre modeline bakmak ve sodyum (Na^+), kalsiyum (Ca_2^+) ve potasyum (K^+) seviyeleri dışındaki hücre dışı seviyeleri dikkate almak olmuştur. Çalışmada önerilen simülasyonları kullanarak 12 derivasyonlu bir EKG hesaplanmıştır. Hücresel ve ventriküler düzeyde elde edilen sonuçlar literatür ile tutarlıdır. Ayrıca, elektrolit değişikliklerini temsil etmek için yeni özellikler önerilmiştir, bu özellikler, EKG kayıtlarına dayalı iyonik konsantrasyonları tahmin etmeyi amaçlayan gelecekteki çalışmalar için yararlı olabilir (Hernández Mesa vd., 2018)

Pilia, N. ve arkadaşları, EKG'den kalsiyum ve potasyum iyonik konsantrasyonlarını yeniden oluşturmak için bir yöntem önermiştir. İlk adım, farklı hücre dışı iyonik konsantrasyonlar için on Tusscher ventriküler hücre modeli ile 91 monodomain simülasyonu gerçekleştirmektir. Kalsiyum ve potasyum seviyelerinde, genlikte ve morfolojik farklılıklarda değişiklikler içeren EKG'ler elde edilmiştir. İkinci adımda, EKG kayıtlarından iyonik konsantrasyonları doğrudan yeniden oluşturmak için simüle edilmiş EKG sinyalleri kullanılmıştır. Farklı iyonik konsantrasyonlar tarafından neden olunan değişiklikleri belirlemek için sinyallerden çıkarılan özellikler kullanılmıştır. İyonik konsantrasyonlardan EKG özelliklerini geri kazanmayı içeren ters problem, bir yapay sinir ağı tarafından çözülmüştür. Potasyum tahmin sonuçları yedi kat çapraz doğrulama ile hesaplanmış ve $0,00 \pm 0,28$ mmol/l (ortalama $\pm$ standart sapma) hata

değeri elde edilmiştir. Kalsiyum için tahmin hatası $0,00 \pm 0,08$ mmol/l'dir (Pilia vd., 2017).

Dillon ve arkadaşları, iyonik konsantrasyonların tespiti için seçilen 12 repolarizasyon ile ilgili özelliği denetimli makine öğrenmesi kullanarak sunmuşlardır (Dillon vd., 2015).

Özellikle, akıllı cihazlardan elde edilen veriler, klinik uygulamalara kolayca entegre edilebilecek yeni yaklaşımlar sunmaktadır. Bu bağlamda, Cedars Sinai Tıp Merkezi'nde geliştirilen Kardio-Net modeli, hiperkaleminin uzaktan izlenmesi için 12-derivasyonlu ve tek-derivasyonlu EKG verilerinden yararlanmıştır. Model, 152.508 hastadan elde edilen 293.557 EKG ve serum potasyum seviyeleri ile eğitilmiş ve farklı hasta gruplarında test edilmiştir. Elde edilen sonuçlar, hem klinik ortamda hem de akıllı saat gibi taşınabilir cihazlardan elde edilen verilerle hiperkaleminin yüksek doğrulukla tespit edilebileceğini göstermiştir (AUC: 0,831-0,876, MAE: 0,527-0,580 mEq/L). Bu bulgular, iyon konsantrasyonlarının tahmininde yapay zekanın potansiyelini açıkça ortaya koymaktadır (Chiu vd., 2024).

EKG sinyallerinden glükoz seviyelerini derin öğrenme teknikleri kullanarak tahmin etmek büyük ilgi görmektedir. Bu yöntem, kalp aktivitesi ve glükoz metabolizması arasındaki fizyolojik ilişkiyi kullanarak invaziv olmayan bir şekilde glükozu izlemeyi amaçlamaktadır. Birçok çalışma, elektrokardiyogram verilerinden glükoz seviyesi tahminlerinin doğruluğunu ve öngörülebilirliğini artırmak için derin öğrenme ve makine öğrenimi gibi çeşitli teknikleri incelemiştir.

Makine öğrenimi, kan şekeri seviyelerini tahmin etme yeteneğine sahip olabildiğine yönelik Marcus ve arkadaşları, geleneksel tekniklerin kısıtlamalarına dikkat çekiyorlar ve glükoz seviyelerini hipoglisemi ve hiperglisemi gibi kategorilere ayırabilen daha gelişmiş algoritmalara ihtiyaç duyulduğunu belirtiyorlar (Marcus vd., 2020). Bununla birlikte, yöntemlerinin doğrudan glükoz değeri tahminleri yapmadığını belirtilmiştir. Benzer şekilde, derin öğrenmeyi kullanan bir pilot çalışma, EKG sinyallerine dayalı olarak hipoglisemik durumları belirlemeyi hedeflemektedir (Porumb vd., 2020). Bu çalışmada ise, EKG verilerinden özellik çıkarımı yoluyla invaziv olmayan izleme yeteneğini vurgulanmaktadır. Bu, düşük glükoz seviyeleriyle ilişkili bazı elektrokardiyogram özelliklerini, örneğin uzamış QT aralıklarını

belirleyen araştırma sonuçlarıyla uyumlu olduğu görülmüştür (Fellah Arbi vd., 2022). Ayrıca, bu ölçümlerin glukoz izleme amacıyla kullanılabileceğini önermektedir.

Ek olarak, tek kanallı elektrokardiyogram kayıtlarını kullanarak disglisemi tahmin eden kişiselleştirilmiş makine öğrenimi modelleri önerilmiştir (Chiu vd., 2022a, 2022b). Modellerin yüksek doğruluk gösterdiği ve bu da invaziv olmayan glukoz izleme yöntemlerinin güvenilir olduğu savunulmaktadır. Bu çalışma ise yapılan sistematik bir inceleme tarafından daha da desteklenmiştir (Zanelli vd., 2022). EKG ve PPG sinyallerin diyabeti teşhis etmek ve yönetmek için nasıl kullanılabileceğini tartışmaktadır ve diyabetle ilgili kardiyovasküler değişikliklerin analiz edilmesinin önemini vurgulamaktadır.

Bu bağlamda, derin öğrenmenin uygulanma tabanlı IGRNet modelinin EKG analizi aracılığıyla gerçek zamanlı olarak prediabetin teşhisi için kullanılmasıyla da gösterilmiştir (Wang vd., 2020). Buna göre derin öğrenme, EKG ile ilgili fizyolojik sinyalleri etkili bir şekilde çıkarabilir ve glukoz seviyeleri tahminlerinin doğruluğunu artırabilir. Ek olarak, makine öğrenimi yöntemlerinin invaziv olmayan glukoz ölçümü için yararlı olduğunu gösteren bir çalışma, kalp atış hızı değişkenliği ile glukoz seviyeleri arasındaki ilişkiyi incelemiştir (Gusev vd., 2020).

Bununla birlikte, invaziv olmayan glukoz ölçümü için kullanılan cihazların doğruluğu, klinik uygulamalara entegrasyonu önündeki temel engellerden biri olarak kalmaktadır. Örneğin, PPG tabanlı bir cihaz olan InCheck, glukoz seviyelerini non-invaziv olarak tahmin etmek için umut verici bir teknoloji sunmaktadır. Ancak, yapılan bir çalışmada, bu cihazın doğruluğu Uluslararası Standardizasyon Organizasyonu 15197:2013 kriterlerini karşılamamış ve ölçümlerin yalnızca %18.5'i bu standartlara uygun bulunmuştur. Ayrıca, hata grid analizinde koordinatların %67.25'inin A ve B bölgelerinde yer aldığı, ancak izleme hata grid analizine göre ölçümlerin yalnızca %29.4'ünün risk içermeyen bölgede olduğu belirtilmiştir. Bu durum, mevcut teknolojilerin daha fazla geliştirilmesi gerektiğini vurgulamaktadır. Glukoz tahmininde PPG tabanlı cihazların doğruluğunu artırmak amacıyla derin öğrenme ve diğer yapay zeka yöntemlerinin entegrasyonu, bu alanda önemli bir ilerleme sağlayabilir (Mondal vd., 2024).

Son yıllarda, non-invaziv glukoz tespiti konusunda hem PPG hem de çoklu yakın kızılötesi yöntemlerinde önemli ilerlemeler kaydedilmiştir. PPG, bazal glukoz

seviyelerinin tahmininde daha iyi bir performans sergilerken, günlük dalgalanmalara karşı duyarlılık eksikliği göstermektedir. Öte yandan, yakın kızılötesi yöntemler kısa vadeli değişimlere duyarlı olmakla birlikte bireysel ve çevresel faktörler nedeniyle zorluklarla karşılaşmaktadır. Bu sınırlamaları aşmak amacıyla, her iki yöntemi birleştiren yenilikçi bir parmak ucu glukoz tespit sistemi geliştirilmiştir. Bu sistem, çoklu ışık sensörlerini ve hafif bir derin öğrenme modelini kullanarak oral glukoz tolerans testlerinde umut verici sonuçlar elde etmiştir. Çalışmaya katılan 10 katılımcı, her biri yaklaşık 10 saniyelik 700 veri segmenti sağlayarak sistemin performansını değerlendirmiştir. Elde edilen sonuçlar, RMSE değerinin 0.242 mmol/L ve Parkes hata grid analizinde %100 doğruluk ile Bölge A'da yer almıştır. Bu yaklaşım, çoklu yakın kızılötesi sensörlerin, invaziv olmayan glukoz tespiti için potansiyelini açıkça ortaya koymaktadır. Bu tür kombinasyonel sistemler, non-invaziv glukoz ölçüm teknolojilerinin doğruluğunu artırmak için gelecekteki çalışmalar için güçlü bir temel oluşturmaktadır (Du vd., 2024).

İnvaziv olmayan glukozu izlemek için derin öğrenme tekniklerinin elektrokardiyogram sinyali analizi ile birleştirilmesi umut vericidir. Çalışmalar, kullanılan tekniklerin kapsamlı bir özetini, EKG özellikleri ile glukoz seviyeleri arasındaki ilişkinin fizyolojik temellerini ve diyabet yönetiminde klinik uygulamalar için potansiyel potansiyeli sunmaktadır. Bu modellerin geliştirilmesi, daha doğru ve daha kolay erişilebilir glukoz izleme çözümlerine yol açabilir.


Bu tez çalışmasının ana katkısı, EKG kayıtlarına dayalı zaman ve frekans alanı özellik çıkarımı ve makine öğrenmesi kullanarak kalsiyum ve potasyum değerlerindeki anormallikleri tespit etmek için güvenilir bir regresyon yaklaşımı önermesidir. Çalışma, denetimli makine öğrenmesi üzerine odaklanmakta ve giriş olarak kullanılan EKG kayıtlarına dayalı zamansal morfolojik özelliklerin ve frekans değişimlerinin analizini dikkate almaktadır. Birçok çalışma, potasyum ve kalsiyum tespiti için morfolojik özelliklerin potansiyelini göstermiştir. Ancak, iyonik konsantrasyonlar ile zaman ve frekans alanı özellikleri arasındaki ilişkiyi ele alan bir çalışma bulunmamaktadır.

Yapay sinir ağları (YSA'lar), Ensemble yöntemler ve bulanık mantık sistemleri seçimi, bu yöntemlerin kendine özgü ve tamamlayıcı avantajlarına dayanmaktadır. YSA'lar karmaşık ve doğrusal olmayan ilişkileri yakalama potansiyeline sahip olup, oldukça esnek ve güçlüdür. Öte yandan, bulanık mantık sistemleri, belirsizliği etkili

bir şekilde yönetmede ve yorumlanabilirlik sağlamada mükemmeldir. Diğer yöntemler bazı durumlarda potansiyel faydalar sağlayabilse de, genellikle seçilen yöntemler kadar esneklik, yorumlanabilirlik veya doğrusal olmayan etkileşimleri simüle etme yeteneğine sahip değildirler. Bu nedenle, YSA'lar, Ensemble yöntemler ve Bulanık Mantık Sistemleri, doğru tahminler ile sonuçları analiz etme ve uzman bilgisini dahil etme kapasitesini birleştiren dengeli bir yöntem sunmaktadır.

Ayrıca, bu çalışmada normal ve anormal durumlar ile iyonik konsantrasyon değerleri, EKG sinyallerindeki frekans değişimlerinden türetilen özelliklere dayalı denetimli makine öğrenme algoritmaları ile belirlenmiştir. Tez çalışmasında, morfolojik özellikleri frekans ve zaman-frekans alanı tabanlı teknikler ve denetimli makine öğrenme algoritmaları ile birleştirerek başarıyı artırmayı hedeflenmektedir.

Bu tez çalışmasında adımlar şu şekilde düzenlenmiştir. İkinci bölüm, bu araştırma alanındaki mevcut durumu özetlemektedir. Üçüncü bölümde, EKG işaretlerinin oluşumu ve ölçümü anlatılmaktadır. Dördüncü bölümde, kullanılan veritabanı hakkında ilgili bilgiler verilmektedir. Beşinci bölümde, morfolojik, frekans ve zaman-frekans alanına dayalı iyonik konsantrasyonların analiz yöntemleri anlatılmakta bunun akabinde ve uygulanan YZ yöntemleri ayrıntılı olarak açıklanmaktadır. Yedinci ve son bölümde, önerilen şemanın değerlendirme sonuçları sunulmakta ve tartışılmaktadır. Son olarak, makale, ana katkıların vurgulanması ve gelecekteki araştırma yönlerinin sunulması ile sonlandırılmaktadır.



Şekil 1.1. Tez genel akış diyagramı.

2. KANDAKİ İYONİK KONSANTRASYON DEĞİŞİKLİĞİNE BAĞLI HASTALIKLAR

2.1. Kronik Böbrek Hastalığı

Böbrek fonksiyonlarının zamanla azalması kronik böbrek hastalığı olarak bilinir. Dünya çapında önemli bir halk sağlığı sorunu olup, özellikle kardiyovasküler hastalıklarla ilişkili yüksek mortalite oranlarına sahiptir. Diyabet ve hipertansiyon, KBH yönetiminin ana odak noktalarıdır ve erken teşhis, hastalığın ilerlemesini yavaşlatma ve komplikasyonları çözmeye odaklanır.

2.1.1. Tanım ve sınıflandırma

KBH erken tespiti ve tedavisi, komplikasyonları önleyebilir ve yaşam kalitesini artırabilir. KBH, ilerleyici, yaşamı tehdit eden bir durumdur ve yüksek ölüm riski ile yaşam kalitesinin düşmesiyle ilişkilidir; bu durumun başlıca nedenleri kardiyovasküler hastalıklar ve kanserdir. Ulusal Böbrek Vakfı'nın kronik böbrek hastalığına yönelik uygulama kılavuzları, erken tanı ve tedaviyi geliştirmeyi amaçlamakta, bu sayede böbrek yetmezliği ve kardiyovasküler hastalığa ilerlemeyi önlemeyi potansiyel olarak sağlamaktadır. Kronik böbrek hastalığı, kamu sağlığı açısından artan bir sorun olup, en yaygın nedeni diyabet mellitus'tur. Tarama ve müdahale ile bu hastalık önlenabilir, ancak topluluklar ve hekimler arasında farkındalık hala düşük seviyededir. Kidney Disease: Improving Global Outcomes (KDIGO)'nun KBH tanımı ve sınıflandırması, uluslararası klinik uygulama kılavuzları için hastalığı tanımlamak ve sınıflandırmak amacıyla basit, tek tip bir sistem olarak kabul edilmekte ve bazı açıklamalarla desteklenmektedir. Hastalık, GFH seviyelerine göre beş evreye ayrılır ve 5. evre böbrek yetmezliğini gösterir (Jha vd., 2013; Levey vd., 2003, 2005; Romagnani vd., 2017; A. C. Webster vd., 2017)

Hastalığın teşhis ve ilerleme seviyesi tespiti ise, Glomerüler filtrasyon hızı (GFH) ≥ 60 ml/dk/1.73 m² veya 24 saatte en az 30 mg albüminüri, KBH'nin tipik olarak 3 aydan uzun süren sürekli bir anormallik olarak tanımlanır. Şekil 2.1, vücuttaki GFH ve albüminüri ölçümleri kullanılarak KBH derecesini ölçmek için kullanılmaktadır (Levey vd., 2003). Tablo 2.1'de görüldüğü üzere A1'den A3'e kadar olan albüminüri

(PAK olarak kısaltılır) ve G1'den G5'e kadar değişen glomerüler filtrasyon (GFH) kategorileri, kronik böbrek hastalığının sınıflandırılmasında hastalığın nedeni ile birlikte değerlendirilir.

Tablo 2.1. 2012 KDIGO Kılavuzu'na göre kronik böbrek hastalığında GFH kategorileri.

GFH Evreleri	GFH (ml/dk/1.73 m ²)	Tanımlar
G1	≥90	Normal veya yüksek
G2	60-89	Hafif azalmış
G3a	45-59	Hafif-orta derecede azalmış
G3b	30-44	Orta-şiddetli derecede azalmış
G4	15-29	Şiddetli azalmış
G5	<15	Böbrek yetmezliği

				Persistan Albüminüri Kategorileri		
				A1	A2	A3
				Normal / yüksek normal	Yüksek	Çok yüksek
				<30 mg/g <3 mg/mmol	30-300 mg/g 3-30 mg/mmol	>300 mg/g >30 mg/mmol
GFH Kategorileri (ml/dk/1.73 m ²)	G1	Normal veya yüksek	≥90			
	G2	Hafif azalmış	60-89			
	G3a	Hafif – orta derecede azalmış	45-59			
	G3b	Orta – şiddetli derecede azalmış	30-44			
	G4	Şiddetli azalmış	15-29			
	G5	Böbrek yetmezliği	<15			

Şekil 2.1. KDIGO 2012: GFH ve albüminüri kategorilerine göre kronik böbrek hastalığı prognozu (Levey vd., 2005).

2.1.2. EKG tabanlı kan potasyum ve kalsiyum tahmini

Özellikle hemodiyaliz tedavisi gören hastalarda, EKG bazlı kan potasyum [K⁺] ve kalsiyum [Ca²⁺] seviyelerinin tahmini, elektrolit dengesizliklerini izlemek için umut

verici bir invaziv olmayan yöntemdir. Bu yöntem, QRS kompleksi ve T dalgası gibi EKG sinyallerindeki morfolojik değişikliklerden yararlanarak serum elektrolit konsantrasyonlarını tahmin edebilir ve bu da sık sık kan testlerine olan ihtiyacı azaltabilir.

QRS morfoloji işaretçileri, T dalgası işaretçileriyle birleştirildiğinde, kalp atış hızı değişimlerine düşük hassasiyetle $[K^+]$ ve $[Ca^{2+}]$ 'yı doğru bir şekilde tahmin edebilir (Bukhari vd., 2022). T dalgası genliği ve inişi, özellikle T dalgası eğimi ile genlik oranı (TS/A), $[K^+]$ tahmini için etkilidir (Corsi vd., 2012, 2017).

Tek kanallı EKG'lerin ileri seviye sinyal işleme teknikleri, doğru $[K^+]$ tahminleri sağlayarak uzaktan izleme için uygulanabilir hale getirebilir. Yüksek çözünürlüklü dijital EKG kayıtlarına dayanan kişiselleştirilmiş regresyon modelleri, $[K^+]$ değerini klinik olarak anlamlı bir doğrulukla tahmin edebilir (Z. I. Attia vd., 2016; Yasin vd., 2017).

EKG özellikleri üzerinde eğitilmiş yapay sinir ağları, gürültülü koşullarda bile kabul edilebilir bir hassasiyetle ekstraselüler $[K^+]$ ve $[Ca^{2+}]$ konsantrasyonlarını yeniden oluşturabilir (Pilia vd., 2017, 2019). Makine öğrenimi yaklaşımları, PCA ve polinom regresyonu da dahil olmak üzere, EKG sinyallerinden elektrolit konsantrasyonu tahminlerinin sağlamlığını ve doğruluğunu artırmaktadır (Hernández Mesa vd., 2019).

EKG tabanlı yöntemler, klinik ortamlarda umut verici sonuçlar göstermiştir; $[K^+]$ tahminindeki hatalar minimal düzeyde olup beklenen fizyolojik desenlerle tutarlıdır (Z. Attia vd., 2018). Hesaplamalı modeller ve simülasyonlar, EKG tabanlı tahminlerin fizyolojik temelini destekleyerek, klinik uygulama potansiyellerini güçlendirmektedir (Corsi vd., 2012; Pilja vd., 2020).

2.2. Diyabet Hastalığı

Diyabet mellitus, insülin salgısı, insülin etkisi veya her ikisindeki bozukluklar nedeniyle kronik hiperglisemi ile karakterize edilen bir metabolik hastalıklar grubudur. Bu durum, gözler, böbrekler, sinirler, kalp ve kan damarları da dahil olmak üzere çeşitli organlarda uzun vadeli hasara ve işlev bozukluğuna yol açar. İki ana diyabet türü, tip 1 diyabet (T1DM) ve tip 2 diyabet (T2DM) olup, her birinin kendine özgü etiyopatogenetik mekanizmaları vardır.

2.2.1. Tanım ve sınıflandırma

Diyabet, insülin salgısındaki, insülin etkisindeki veya her ikisindeki bozukluklar nedeniyle hiperglisemi ile karakterize edilen bir durumdur ve bu da uzun vadede organ hasarına yol açar. Patojenik süreçler, pankreatik β -hücrelerin otoimmün yıkımından T1DM insülin direncine ve yetersiz insülin salgısına kadar uzanmaktadır. Belirtiler arasında poliüri, polidipsi, kilo kaybı, polifaji ve bulanık görme yer almaktadır. Kronik hiperglisemi, büyüme bozukluğuna ve enfeksiyonlara karşı artan duyarlılığa yol açabilir. Akut komplikasyonlar arasında ketoasidoz veya nonketotik hiperosmolar sendrom yer alırken, uzun vadeli komplikasyonlar arasında retinopati, nefropati, periferik ve otonom sinir hastalığı ile kardiyovasküler hastalıklar için artmış risk bulunmaktadır.

T1DM, pankreas β -hücrelerinin otoimmün yıkımı nedeniyle insülin salgısında mutlak bir eksiklikten kaynaklanır ve genellikle otoimmüniteye dair serolojik kanıtlar ve genetik belirteçlerle tanımlanır. T1DM'li hastalar, ömür boyu insülin tedavisine ihtiyaç duyarlar ve yoğun glisemik kontrol sağlansa bile mikrodamar ve makrodamar komplikasyonları geliştirme riski taşırlar. T2DM, insülin direnci ve yetersiz telafi edici insülin salgısı kombinasyonu ile karakterize edilen, çeşitli etiyolojik bileşenlere sahip son derece heterojen bir poligenik hastalıktır. T2DM, yaşam tarzı değişiklikleri, ağızdan alınan glukoz düşürücü ilaçlar ve bazen insülin ile yönetilebilir, ancak hastalığın ilerlemesi ve tedaviye yanıt hastalar arasında önemli ölçüde farklılık gösterebilir (American Diabetes Association, 2007, 2008, 2009, 2010, 2011, 2012; Guo vd., 2023; Katsarou vd., 2017; Pearson, 2019).

2.2.2. EKG tabanlı kan glüköz tahmini

EKG tabanlı kan şekeri tahmini, kardiyovasküler sinyaller ile kan şekeri seviyeleri arasındaki ilişkiyi kullanan yeni bir alan olarak ortaya çıkmaktadır. Bu invaziv olmayan yaklaşım, diyabet yönetimi için maliyet etkin, ağrısız ve sürekli izleme çözümü sunmayı hedeflemektedir.

EKG ve kan şekeri arasındaki ilişki, son dönemde yapılan araştırmaların önemli bir odak noktası haline gelmiştir. Kan şekeri seviyelerindeki değişimlerin, kalbin elektriksel aktivitesini etkilediği bilinmektedir. Hipoglisemi (düşük kan şekeri) ve hiperglisemi (yüksek kan şekeri) dönemleri, EKG'deki belirli parametreler üzerinde önemli etkiler yaratmaktadır. Özellikle, ST, QT, PR aralıkları ve kalp hızı değişkenliği (HRV) parametreleri bu değişikliklere duyarlı olabilir. Yapılan çalışmalar, bu

parametreler ile kan şekeri seviyeleri arasında bir doğrusal ilişki olduğunu göstermektedir. Bu bulgu, kan şekeri seviyelerinin non-invaziv olarak EKG verileri üzerinden tahmin edilmesine olanak tanıyacak yeni yöntemlerin geliştirilmesine kapı aralamaktadır. Böylelikle, sürekli glukoz takibinin, özellikle diyabet hastaları için, ağrısız, düşük maliyetli ve kullanıcı dostu bir yöntemle sağlanabileceği düşünülmektedir (Fellah Arbi vd., 2022; Y. Lin vd., 2023).

Makine öğrenimi ve derin öğrenme yaklaşımları, diyabet yönetiminde kan şekeri ve glukoz ile hemoglobin (HbA1c) seviyelerinin non-invaziv olarak izlenmesine yönelik önemli adımlar sunmaktadır. İlk çalışmada, kan şekeri ile ilişkili EKG sinyalleri kullanılarak, düşük, orta ve yüksek glukoz seviyeleri için Convolutional Neural Networks (CNN) tabanlı bir model geliştirilmiştir. Bu model, %87,94 doğrulukla düşük glukoz seviyelerini belirlemiştir. İkinci çalışmada, Region Based Convolutional Neural Networks (RCNN) ile yüzey EKG sinyallerinden kan şekeri tahmin edilmiş ve doğrusal bir ilişki saptanmıştır. Üçüncü çalışmada ise, EKG sinyalleri kullanılarak HbA1c tahmini yapılmış ve diyabet komplikasyonları öngörülmüştür. Tüm bu yaklaşımlar, makine öğrenimi ve derin öğrenme ile diyabet yönetiminde yenilikçi ve non-invaziv çözümler sunmaktadır (Fellah Arbi vd., 2022; Li vd., 2021; C.-S. Lin vd., 2021).

Kan glukoz seviyelerindeki değişiklikler, diyabet yönetiminde EKG ve photoplethysmography (PPG) sinyallerini kullanarak kan şekeri seviyelerini izleme üzerine odaklanmaktadır. İlk çalışmada, EKG ve PPG sinyallerini birleştirerek bir kan şekeri izleme modeli oluşturulmuş ve bu modelin, zamansal istatistiksel ve mekansal morfolojik özellikleri kullanarak başarılı sonuçlar verdiği gösterilmiştir Root mean square error (RMSE): 1.49 mmol/L, mean absolute relative difference (MARD): %13.42) (Li vd., 2023). İkinci çalışmada ise, EKG ve PPG sinyallerinin diyabet tespiti, kan şekeri tahmini ve diyabetle ilişkili komplikasyonların izlenmesi için kullanımı detaylı bir inceleme ile ele alınmıştır. Sonuçlar, bu tekniklerin diyabet bakımında umut verici olduğunu göstermektedir (Zanelli vd., 2022).

Kan şekeri, insan vücudunun önemli fizyolojik parametrelerinden biridir. Bu çalışmanın amacı, kalp ritmi ölçümleri ile kan şekeri seviyelerini tahmin eden bir yöntem geliştirmektir. Bu yaklaşım, sürekli izleme imkanı sunarken, giyilebilir, non-invaziv, ağrısız, düşük maliyetli ve kullanımı kolay olma avantajlarına sahiptir. Deneyde, insan vücudundaki kan şekeri değişiklikleri Continuous Glucose Monitoring

(CGM) sistemi ile elde edilerek EKG parametreleri ile karşılaştırılmıştır. Sonuçlar, kan şekeri ile bu EKG parametreleri arasında doğrusal bir ilişki olduğunu göstermiştir. Bu yenilikçi yöntem, kronik hastalıkların uzaktan teşhisi ve hassas tıp stratejileri için bir çözüm sunmaktadır (Y. Lin vd., 2023).




3. ELEKTROKARDİYOĞRAFI SİNYALİNİN İNCELENMESİ

EKG, kardiyolojide kritik bir araçtır; kalbin elektriksel aktivitesini kaydederek çeşitli kardiyovasküler durumları teşhis etmeye yardımcı olur. Son zamanlardaki hesaplama teknikleri ve makine öğrenimindeki ilerlemeler, EKG sinyallerinin analiz ve tanı yeteneklerini önemli ölçüde geliştirmiştir. Bu bölümde EKG sinyalinin oluşumu ve ölçülmesi, EKG sinyalinden P-QRS-T noktalarının tespit edilmesine yönelik metotlar anlatılacaktır.

3.1. EKG Sinyalinin Oluşumu ve Ölçülmesi


EKG sinyali, SA düğümünden başlayarak atriyumlara ve AV düğümüne yayılan elektriksel impulsların, ventriküllerin kasılmasını sağlayan His demeti ve Purkinje liflerine ulaşmasıyla oluşur. Bu elektriksel aktivite, kalbin düzenli ritmini ve pompa işlevini yönetir.



Şekil 3.1. EKG sinyalinin oluşumu (Gong vd., 2024).

Beş elektrot, yaygın olarak kullanılan bir elektrot konfigürasyonudur. Bunlardan biri sol kolda, biri sağ kolda, biri sol bacakta, biri sağ bacakta ve biri göğüste dışa doğru sağda bulunur. Başka bir yaygın yöntem, 10 elektrot kullanır (Barill, 2003). Göğüste


V1 bacaklarda ve kollarda göğüste 5 ek elektrot (V2'den V6'ya kadar) yerleştirilerek 12 derivasyon oluşturulabilir. Şekil 3.2, 10 elektrotlu ve 12 derivasyonlu bir kombinasyonunu göstermektedir.



Şekil 3.2. Tipik 10 elektrot konfigürasyonu (Luz vd., 2016).

3.2. EKG Sinyalinin Analizi ve İşlenmesi

Temel kayma, elektriksel parazitler, kas artefaktları ve hareket artefaktları, elektrokardiyogram kayıtlarını sıklıkla etkiler. Bu durumda elektrokardiyogram sinyallerinin kullanılabilirliği kısıtlanır ve bu artefaktlar ortadan kaldırılmalıdır. Temel kayma ve sapma düzeltmesi, ön işleme sürecinin ilk adımıdır. Daha sonra 5 Hz'den 100 Hz'e kadar bir bant geçiren filtre kullanılır. Son aşamada, temiz elektrokardiyogram sinyalleri elde etmek için bir öngörücü izolasyon düzeltmesi yapılmıştır (Lenis vd., 2017). Her adıma ait EKG sinyalleri Şekil 3.3. 'de verilmiştir.




Şekil 3.3. Sinyal ön işleme aşamaları a) Ham EKG sinyali b) Temel düzey kaldırıldı c) Yüksek ve düşük geçiren filtreleme d) Temiz sinyal.


EKG, kalp hastalıklarının erken tespiti için maliyet etkin ve invaziv olmayan bir araçtır. Bu, her EKG dalga formunun başlangıç ve bitiş noktalarını, ayrıca zirvesini işaret eden referans noktalarının tespit edilmesini gerektirir. Bu noktaları manuel olarak ayarlamak zaman alıcıdır ve uzman bilgisi gerektirir. MATLAB için ECGdeli araç kutusu, klinik olarak kaydedilmiş 12 derivasyonlu EKG sinyallerini filtrelemek ve referans noktalarını tespit etmek amacıyla geliştirilmiştir (Pilia vd., 2021). Sonuçlar, ECGdeli'nin P dalgalarını, QRS komplekslerini ve T dalgalarını güvenilir bir şekilde tespit edebildiğini, bu durumun belirli kalp hastalıklarının tanısına katkıda bulunduğunu göstermiştir.

Çıkarılan özellikler, her bir EKG dalga formunun zirvesinin (P dalgası, QRS kompleksi, T dalgası) yanı sıra açık ve kapanış belirleyici referans noktalarının tanımlanmasını gerektirir. Bu amaçla, esasen sürekli dalgacık dönüşümünü kullanan FilterBank yöntemi kullanılmaktadır (Lenis vd., 2016; Sörnmo & Laguna, 2005). Uygulanan algoritmanın akış diyagramı Şekil 3.4'te gösterilmiştir.

Şekil 3.5, FilterBank yönteminin EKG sinyaline uygulanmasının sonuçlarını göstermekte ve tespit edilen P, QRS ve T noktalarını vurgulamaktadır. Bu noktaların doğru bir şekilde tespit edilmesi, kalbin elektriksel aktivitesini analiz etmek ve tahmin modeli için kullanılan özellikleri çıkarmak açısından hayati öneme sahiptir.



Şekil 3.4. Ön sinyal işleme P, QRS, T tespiti için önerilen algoritma (Pilia vd., 2021).




Şekil 3.5. FilterBank yöntemi ile P-QRS-T noktalarının tespiti.

3.3. EKG Sinyalini İnceleme Metotları

Genel olarak, özellik çıkarımı çoğu sinyal işleme uygulamasında ilk adımdır. Morfolojik özellik çıkarımı, biyomedikal sinyali kısa çerçevelere ayırmayı gerektirir, böylece lokal bilgiler elde edilebilir.

İlk verilere ve fizyolojik öneme dayanarak derinlemesine analiz için 12 EKG özelliği çıkardık. Bu özellikler, P, R ve T dalgalarının genliği, PR ve QT aralıkları, PR ve ST segmentleri, QRS kompleksi, R-T süresi, sağ eğim (T sağ eğimi), sol eğim (T sol eğimi) ve T-dalgası genliğinin T sağ eğimine oranını içermektedir. Bu 12 özelliği çıkarmak için otomatik algoritmalar geliştirdik. Şekil 3.6, bu özelliklerin çıkarım sürecini ve temsilini göstermektedir.



Şekil 3.6. Konsantrasyon değişikliklerini belirlemek için değerlendirilen EKG morfolojik özellikleri (Dillon vd., 2015).

Bu tez çalışması kapsamında da EKG'ye ait istatistiksel zaman ve frekans tabanlı özellikler kullanılmıştır. Hem zaman hem de frekans alanı özellikleri, önceki çalışmalarda sınıflandırma amaçları için başarıyla kullanılmıştır (Bocklet vd., 2008; Metze vd., 2007). EKG'den çıkarılan diğer özellikler ilerleyen bölümlerde detaylı olarak anlatılmıştır.



4. VERİ SETLERİ

Bu bölümde tez çalışması kapsamında kullanılan veri setleri, hastalara ait belirli bir zaman diliminde klinik veriler, demografik bilgiler, sinyaller ve kandaki konsantrasyon türlerine göre elde edilen veri setleri anlatılacaktır.


4.1. MIMIC III Veri Seti

Boston, Massachusetts'taki Beth Israel Deaconess Tıp Merkezi, 2001 ile 2012 yılları arasında MIMIC III veritabanını kaydetmiştir. Bu çalışma için en son sürümü (v1.4) kullanılmıştır (Johnson vd., 2016). MIMIC III veritabanı, 46.520 hastanın 58.976 hasta durumunun kayıtlarını içermektedir. Şekil 4.1 ve Şekil 4.2'de gösterilen kriterler, analiz için yeterli minimum veri miktarına sahip olan hastaları filtrelemek amacıyla uygulanmıştır.


Bir dalga formu kayıtları alt kümesi, hasta kayıtlarını güvenilir bir şekilde tanımlamak için yeterli bilgi içermektedir ve bu kayıtlar MIMIC III Klinik Veritabanı tarafından temsil edilen zaman dilimiyle örtüşmektedir. Tüm mevcut bilgileri, ya manuel düzeltmelerle ya da esasen otomatik eşleştirme süreçleriyle kullanılmıştır. Veritabanındaki toplam 22.317 sinyal, (%34) klinikteki hasta kayıtlarına karşılık gelen hastayla eşleştirilmektedir.

Belirli bir hastayla ilişkili tüm veriler, hastanın MIMIC III kimlik numarasıyla adlandırılmış tek bir alt dizinde saklanmaktadır. 10 seviye (match/p00'dan match/p09'a kadar) halinde bu alt dizinlere ayrılmaktadır.

Eşleşen her dalga kaydının adı şu formatta: Matched /pXX /pXXNNNN /pXXNNNN-YYYY-MM-DD-hh-mm; burada XXNNNN, eşleşen MIMIC III Klinik Veritabanı SubjectID'sidir ve YYYY, MM, DD, hh ve mm, yıl, ay (01-12), gün (01-31), gerçek saat (00-23) ve dakikalar (00-59) başlangıç tarihi ve saatinden türetilmiştir. Bu veriler, MIMIC III Klinik Veritabanındaki karşılık gelen veri kayıtlarıyla eşleşmektedir.



Şekil 4.1. MIMIC III veritabanındaki hasta verilerindeki iyon konsantrasyonlarının incelenmesi.



Şekil 4.2. MIMIC III kayıtlarının işlenme akışı.

Tablo 4.1. filtrelemeler sonucunda elde edilen veri setinin özelliklerini göstermektedir.

Tablo 4.1. İyon konsantrasyonlarıyla eşleşen dalga formlarının sayısı.

Alt dizin Id	Dalga formları ile eşleşen potasyum sayısı	Dalga formları ile eşleşen kalsiyum sayısı
0	206	157
1	179	146
2	261	223
3	103	84
4	589	460
5	678	530
6	677	557
7	579	468
8	597	482
9	562	452
Toplam	4196	3559

4.1.1. MIMIC-III ikili özellik etiketleme

MIMIC-III veri seti, hasta kayıtlarına Uluslararası Hastalık Sınıflandırması (ICD) kodları atamaktadır. Tablo 4.2., böbrek hastalıkları için ilgili ICD kodlarını özel olarak listelemektedir. Bu yaklaşım, araştırmacıların böbrekle ilgili hastalıklara sahip hastaları etkili bir şekilde tanımlayıp analiz etmelerini sağlar.

Tablo 4.2. Böbrek hastalıkları için ilgili ICD kodları.

ICD Kodu	Açıklama
5851	KBH, Evre I
5852	KBH, Evre II
5853	KBH, Evre III
5854	KBH, Evre IV
5855	KBH, Evre V
5859	KBH, Belirsiz

Hastalara ait yaş bilgisi, gruplandırmamız gereken bir diğer özelliktir. MIMIC-III veri seti içerisinde, 89 yaşından büyük hastalar için yaş bilgisi sabit bir sayı ile ifade edilmiştir. Bu sorunu ele almak için yaş bilgisi 20 yıllık dilimlere ayrıldı, yaş gruplarına ait bilgiler Tablo 4.3'de gösterilmiştir. Bu, yaş bilgisini sabit olarak belirtilen hastaları analizimizden hariç tutmadan ele almamıza olanak tanımıştır.

Tablo 4.3. Yaş grubunu kategorize etme.

Yaş aralığı grubu	Açıklama
< 20	1
21 - 40	2
41 - 60	3
> 61	4

4.2. D1NAMO Veri Seti

Giyilebilir cihazların kullanımı, özellikle sağlık ve yaşam kalitesi açısından son zamanlarda popülerlik kazanmıştır. Bu cihazların kullanımına diyabet gibi kronik hastalıkların yönetimini iyileştirmek için son zamanlarda daha fazla ilgi var. Giyilebilir sensörlerden alınan veriler genellikle tıbbi cihazlardan daha kalitelidir ve mevcut veri setleri çoğunlukla son derece kontrollü klinik koşullarda elde edilmiştir. D1NAMO projesinde glisemik olayları invaziv olmayan elektrokardiyogram desen analizi yoluyla belirlemeyi amaçlayan bir veri seti oluşturulmuştur. Bu veri seti, klinik olmayan koşullarda giyilebilir cihazlara dayalı sağlık sistemlerinin geliştirilmesine yardımcı olabilir.

Bu bölüm, çeşitli sensörlerden alınan verileri kullanarak diyabet tahmininde kullanılan veri setini açıklar. Bu tez çalışmasında kullanılan D1NAMO veri seti açıklanmaktadır (Dubosson vd., 2018). Bu veri seti, EKG, solunum sensörü, accelerometer (ACC) sinyalleri ve glukoz ölçümleri dahil olmak üzere dört farklı sensör verisinden oluşmaktadır. Veri seti ile ilgili örnek bir veri Şekil 4.4'de gösterilmiştir. Veri setinde gıda etiketli resimler de yer almaktadır ancak bu çalışmada dört sensörden gelen veriler dikkate alınmıştır. Zephyr BioHarness'in üç giyilebilir cihazı, klinik olmayan koşullardaki hastalardan bu çok modlu veri setini oluşturmuştur.

Bu çok modlu veri setindeki 29 bireyden 20'si sağlıklı bireyler, 9'u diyabet hastasıdır. Veri seti, diyabetik ve sağlıklı bireyler için dört gün boyunca EKG, ACC ve solunum sinyalleri için sürekli değerlerden oluşmaktadır. Veri seti ile ilgili istatistiksel bilgiler Tablo 4.4'de gösterilmiştir. Diyabetik hastalar için glukoz ölçümleri bir ila beş dakika arasında ve diyabetik olmayan hastalar için düzensiz aralıklarla kaydedilmiştir.

EKG, ACC ve solunum dalgalarının kayıt frekansları 250, 100 ve 25 Hz'dir. Bu veri seti ayrıca kalp atış hızı (HR), nefes alma hızı, cilt sıcaklığı ve kalp atış hızı değişkenliği (HRV) gibi diğer ölçümler içeriyordu. Bu çalışmada yalnızca EKG sensörden elde edilen dalga formu verilerini ve glukoz ölçümlerini dikkate alınmıştır.


Fizyolojik sinyallerin alınması: Her iki alt grup için de Zephyr Bioharness 3 cihazı kullanılarak elektrokardiyogram, nefes alma ve ACC çıktıları alınmıştır. Bu aygıt, Şekil 4.3'de gösterildiği gibi bir spor göğüs kemerine benzemektedir.



Şekil 4.3. Zephyr BioHarness 3, D1NAMO veri setini toplama aşamasında kullanıldı (Dubosson vd., 2018).

Tablo 4.4. Veri setinin istatistikleri (Dubosson vd., 2018).

Veriseti	Toplam	Katılımcı başına ortalama
Subset: sağlıklı birey katılımcı sayısı	20	-
Sinyal kaydı süresi	~ 1550 h	~ 53 h
Glükoz ölçümü	8884	306,3
Gıda etiketleri	473	16,3
Gıda resimleri	352	12,1
Subset: diyabetli birey katılımcı sayısı	9	-
Sinyal kaydı süresi	~ 450 h	~ 53 h
Glükoz ölçümü	8414	934,9
Gıda etiketleri	115	12,8
Gıda resimleri	106	11,8



Şekil 4.4. Veri örnekleri (Dubosson vd., 2018).



5. ÖZELLİK ÇIKARMA

5.1. Giriş

Genel olarak, çoğu sinyal işleme uygulamasında özellik çıkarımı ilk adımdır. Sinyallere ait özellikler genellikle zaman, frekans ve zaman-frekans alanlarında çıkarılır. Morfolojik özellik çıkarımı, biyomedikal sinyali küçük çerçevelere ayırarak yerel bilgi elde etmek için gereklidir. Her kare için bir özellik vektörü daha sonraki aşamada elde edilmektedir. Ayrıca, frekans alanındaki özellikler çıkarılmıştır. Önceki araştırmalar, sınıflandırma amaçları için hem zaman hem de frekans alanı özelliklerini başarıyla kullanmıştır (Bocklet vd., 2008; Metze vd., 2007).

5.2. Morfolojik ve Zaman Tabanlı Özellikleri

5.2.1. Morfolojik özellikler

EKG sinyalinden literatürde birçok farklı özellik çıkarılmıştır. Sinyal şeklinden bazı özellikler hesaplanabilmektedir (Halperin & Kamel, 1998). Bu tür özelliklere morfolojik özellikler denilmektedir. Bu çalışmada EKG sinyalinden 12 morfolojik özellik çıkarılmıştır. Şekil 3.5.'de sinyalin karakteristik özellikleri gösterilmektedir ve Bölüm 3.4 içerisinde morfolojik özelliklerin ayrıntıları bulunmaktadır.

5.2.2. Sinyal özellikleri

Bu bölümde EKG sinyallerinden 13 adet zaman tabanında istatistiksel, impulsif ve harmonik özellikler çıkarılmıştır. Tablo 5.1.'de çıkarılan özellikler gösterilmektedir.

5.2.2.1. İstatistiksel özellikler

Ortalama, standart sapma ve karekök ortalama (RMS) gibi temel ölçümler, istatistiksel özelliklere örneklerdir. Bu özellik seti ayrıca çarpıklık, şekil faktörü ve daha yüksek dereceli kurtosis için istatistikleri de içermektedir. Bu istatistiksel ölçümler, tipik sinyal davranışından sapmaları tespit edebilir ve sinyal desenlerindeki değişikliklere karşı hassastır, özellikle de anormal belirtileri mevcut olduğunda önemli bir özellik olmaktadır.

Şekil faktörü (SF), RMS'in mutlak değerinin ortalamasına bölünmesi ile hesaplanmaktadır. Sinyalin şekli, sinyalin boyutlarından etkilenmeden ŞF etkilerini vermektedir.

$$x_{SF} = \frac{x_{rms}}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (5.1)$$

Yüksek dereceli istatistikler, bir sistemin davranışına dair değerli bilgiler sunarak sinyalin kurtosis (dördüncü moment) ve çarpıklığını (üçüncü moment) incelemektedir.

Kurtosis, bir sinyal dağılımının kuyruklarının ne kadar uzandığını ifade eder ve sinyalin aykırı değerlere karşı duyarlılığını gösterir. Gelişim sırasında anormalliklerin meydana gelmesi, daha yüksek sayıda uç değerle sonuçlanabilir ve bu da kurtosis metriğinin değerinin artmasına neden olabilir. Burada, x_i : sinyalin i. değerini, $\bar{x}$: sinyalin ortalama değerini vermektedir.

$$x_{Kurtosis} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^2} \quad (5.2)$$

Çarpıklık, bir sinyalin dağılımındaki asimetri varlığıdır. Değişiklikler dağılımın eşitliğini etkileyebilir ve böylece asimetri derecesini artırabilir.

$$x_{Skewness} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left[\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{3/2}} \quad (5.3)$$

5.2.2.2. İmpulsif özellikler

İmpulsif metrikler, sinyalin en yüksek noktalarıyla ilişkili özellikleri ifade eder.

Peak değeri, bir sinyalin en yüksek mutlak değeridir. Sinyalin impulsif metriklerini hesaplamak için kullanılmıştır.

$$x_{Peak} = \max_i |x_i| \quad (5.4)$$

İmpuls faktörü, zirve yüksekliği ile sinyalin ortalama seviyesi arasındaki oranı belirler.

$$x_{Impulse} = \frac{x_{Peak}}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (5.5)$$

Tepe faktörü, tepe değerini RMS değere bölerek hesaplanır. Genellikle, sinyalin zirve yoğunluğundaki değişiklikler, sorunların sinyalin kare ortalama enerjisinde kendini göstermeden önce ortaya çıktığını gösterir. Tepe faktörü, sorunların gelişiminin erken aşamalarında bir başlangıç göstergesi olarak hizmet edebilir.

$$x_{Crest} = \frac{x_{Peak}}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}} \quad (5.6)$$

Temizlik faktörü, zirve değerinin mutlak genliklerin kareköklerinin kare ortalamasına bölünmesiyle hesaplanır.

$$x_{Clearance} = \frac{x_{Peak}}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|}} \right)^2} \quad (5.7)$$

5.2.2.3. Harmonik özellikler

Sinyal işleme metrikleri, bozulmaları ölçmek için fonksiyonlar içerir. Sistem bozulması, gürültü seviyesinde bir artışa, temel frekansa olan harmonik oranında bir değişikliğe veya her ikisine birden yol açabilir.

Sinyal-gürültü oranı (SNR), sinyalin gücünün gürültünün gücüne oranı olarak tanımlanır.

Sinyal-modülasyon-gürültü oranı (SMNR), rastgele değişimin saf periyodiklikle karşılaştırıldığında ne kadar olduğunu ölçen bir değerdir (Moghaddamnia vd., 2013). Aşağıdaki tahminler kullanılarak hesaplanabilir:

$$S = \sum_{k=1}^K p_x(k) \quad (5.8)$$

burada $p_x(k)$, k frekans bileşenindeki SMNR değeridir.

Toplam harmonik distorsiyon (THD), tüm harmonik bileşenlerin gücünün temel bileşenin gücüne oranı olarak tanımlanır.

Sinyal-gürültü ve bozulma oranı (SINAD), sinyalin toplam gücünün gürültü ve bozulmanın birleşik gücüne oranı olarak tanımlanır.

5.2.3. Zaman serisinde özellikler

Bu bölümde EKG sinyalinden 11 basit zaman serisinde sinyalden istatistiksel, impulsif ve harmonik özellikler çıkarılmıştır. Tablo 5.2.'de çıkarılan özellikler gösterilmektedir.

5.2.3.1. Dağılım özellikleri

Dağılım özellikleri bölümü, verilerin genel dağılımını tanımlayan geleneksel istatistiksel özellikleri içerir. Özellikler, en düşük değer, ortanca değer, en yüksek değer, çeyrek istatistikleri ve belirli bir değer için kullanıcı tanımlı çeyrekler içerir.

5.2.3.2. Otokorelasyon özellikleri

Otokorelasyon özellikleri bölümü, bir değişkenin kendisiyle iki farklı zaman noktasındaki doğrusal ilişkisini temsil eden özellikleri içerir. Sabit süreçler için, iki konum arasındaki zaman gecikmesi yalnızca aralarındaki otokorelasyonu belirler. Otokorelasyon fonksiyonu, her potansiyel gecikme değeri için otokorelasyon değerlerini temsil eden bir dizidir. Verilen bir N değeri için, ilk N otokorelasyonunun karelerinin toplamıdır.

5.2.3.3. Kısmi otokorelasyon özellikleri

Kısmi otokorelasyon özellikleri bölümü, otokorelasyon özellikleriyle karşılaştırılabilir özellikler içermektedir. Ancak, bu özellikler, dizideki diğer değişkenler üzerindeki karşılıklı doğrusal bağımlılığın etkisini dikkate alır. Kısmi otokorelasyon fonksiyonu (PACF), farklı gecikme değerleri için kısmi otokorelasyonları temsil eden bir dizidir. Verilen bir N değeri için, ilk N kısmi otokorelasyonlarının karelerinin toplamıdır.

5.3. Frekans Tabanlı Özellikler

Bu adımda, EKG sinyalinin spektral özelliklerinin analiz edileceği frekans aralığının tanımlanması gerekmektedir. Bu frekans aralığının alt ve üst sınırlarını belirlemek çok önemlidir çünkü bu, spektral analizde dikkate alınacak sinyalin frekans spektrumunun hangi kısımlarının değerlendirileceğini belirler. Bu sınırları belirlenerek, analizin ilgili frekans bileşenlerine odaklanmasını sağlar. Bu durum da özellik çıkarımının ve sonraki modellemenin doğruluğunu artırabilir. Bu adım, EKG sinyalindeki temel

desenleri tanımak ve yorumlamak için kritik olan belirli frekans bantlarını izole etmek açısından önemlidir ve nihayetinde elektrolit seviyelerinin etkili bir şekilde izlenmesine ve tahmin edilmesine katkıda bulunur.

5.3.1. Spektral tepe değerleri

Bu özellikte ise frekans tabanlı analizinde, genliklerin pik değerlerinin (PeakAmp, PeakFreq) ne sıklıkla meydana geldiği analiz edilerek bir özellik hesaplanmaktadır. Oluşturulan özellik için oluşturulan pik sayısı, seçilen frekans aralığındaki en belirgin tepe değerlerini tanımlar ve bunları azalan genlik sırasına göre düzenlenebilir. Düşük genlikli tepe değerlerini hariç tutmak için, piklerin maksimum boyutunu sınırlayarak düşük genlikli olanlar filtrelenebilmektedir. Frekanslardaki minimum fark belirtilerek, eğer iki tepe değeri arasındaki mesafe bu belirtilen değerden küçükse, algoritma çiftin daha küçük tepe değerini hesaplanmasını dikkate almamaktadır. Tepe değerinin sapma toleransı ise, bir tepe değerinin dikkate alınabilmesi için gereken minimum belirginliği ifade eder. Bir tepe değerinin belirginliği, onun doğal yüksekliği ve komşu tepe değerlerine göre konumu temelinde ölçülmektedir.

5.3.2. Modal katsayıları

Sistemin modal analizinden elde edilen modal katsayılar, titreşim, sönümleme ve dinamik tepki gibi davranışların tanımlanmasına yardımcı olan özelliklerdir. Modal katsayılar olarak da bilinir. Modal katsayıları, bu uygulamada özellikle EKG sinyallerinin analiz edilmesi ve hataların veya anormalliklerin belirlenmesi için kullanılmaktadır.

Doğal frekanslar (W_n), sistemin çeşitli titreşim modlarının frekanslarıdır. Modların doğal titreşim frekansı, her birinin frekansını temsil eder.

Sönümleme katsayıları (Zeta), sistemin her modunun sönümlenme hızını gösteren katsayılardır. Bu, titreşim genliğinin zaman içinde azaldığını gösterir.

5.3.3. Bandpower

Frekans tabanlı özellikler arasında yer alan bandpower, belirli bir frekans bandı içindeki sinyal gücünü hesaplayan bir özelliktir. Bu metrik, özellikle EKG sinyallerinin enerji içeriğini belirli frekans aralıklarında incelemek için kullanılır.

5.4. Zaman-Frekans Tabanlı Özellikler

Zamanla kayan durağan olmayan frekanslara sahip sinyaller, zaman-frekans özellikleri ile tanımlanır. Frekans alanı özellik çıkarımı genellikle güç spektral yoğunluğu (PSD), spektral entropi (SE) ve toplam SMNR kullanımını içerir

5.4.1. Spektrogram özellikleri

Spektral kurtosis (SK) metriği, bir sinyaldeki geçici bileşenlerin varlığını ölçerek, ağırlıklı olarak durağan Gauss gürültüsünden oluşan frekanslara düşük değerler, geçici bileşenler içeren frekanslara ise yüksek değerler atar. Burada parametre olarak pencere boyutu '10' olarak belirlenmiştir.

SE, bir sinyalin zaman içindeki spektral güç dağılımındaki dalgalanmaları nicelendirir. Değerdeki önemli dalgalanmalar, anormallikleri gösterebilir.

SE metriği ile birlikte, burada belirlenen SK metriğine göre Bölüm 5.2.2.2. 'de tanımlanan 4 impulsif metrik, sinyalin en yüksek noktalarıyla ilişkili özelliklerine SK pencere aralığı hesaplanarak tekrardan hesaplanmıştır.

5.4.2. Ampirik mod ayrıştırma özellikleri

Bir sinyalden elde edilen ampirik mod ayrıştırmasından türetilen özellikler (EMD), sinyalin frekans içeriğindeki rastgelelik ve öngörülemezlik derecesini nicelendirir. Bir değerdeki artış, bir hatanın varlığını gösterebilir ve EMD hesaplamasıyla üretilen içsel mod fonksiyonu (IMF) sinyalinden elde edilen enerjiyi işaret edebilir. Burada IMF sayısı metriği '3' olarak tanımlanmıştır.

Hilbert-Huang dönüşümü (HHT), durağan olmayan ve doğrusal olmayan verilerin zaman-frekans analizinde faydalıdır. HHT, analitik sinyali hesaplamak için kullanılır (Huang vd., 2009; Huang & Shen, 2014).

EMD yöntemi, HHT'nin önemli bir parçasıdır ve rastgele verilerin sonlu sayıda IMF'ye ayrılmasını sağlar. Bu nedenle, sinyal $X(t)$ aşağıdaki gibi ifade edilebilir.

$$X(t) = \sum_{i=1}^n imf_i(t) + r_n(t) \quad (5.9)$$

burada $i = 1, \dots, n$ IMF'lerin sayısını temsil etmektedir.

Dalgacık entropisi (WE), sinyal düzensizliğini nicelendirmenin yaygın olarak kullanıldığı bir özelliktir. Aşağıdaki ifadelerde, normalize edilmiş güç p değeri ile gösterilmektedir (Coifman & Wickerhauser, 1992).

$$WE = - \sum_{m=1}^N p(k) \log_2 p(k) \quad (5.10)$$

Bu, dalgacık katsayısı ve dalgacık enerjisinin olasılık dağılımıdır.

Tablo 5.1. EKG sinyali için morfolojik ve istatistiksel zaman tabanlı özellikleri.

EKG Özellik Numarası	Özellik	Formül/Kısaltmalar
1	P noktasının genlik değeri	P_{AMP}
2	R noktasının genlik değeri	R_{AMP}
3	T noktasının genlik değeri	T_{AMP}
4	P-R interval	$P-R_{interval}$
5	P-R segmenti	$P-R_{segment}$
6	Q-R-S kompleksi	$QRS_{complex}$
7	Q-T interval	$Q-T_{interval}$
8	S-T segment	$S-T_{segment}$
9	R-T duration	$R-T_{duration}$
10	T dalgasının sağ eğimi	$T_{righslope}$
11	T dalgasının sol eğimi	$T_{leftslope}$
12	T dalgasının genlik değerinin T sağ eğimine oranı	$T_{AMP} / T_{righslope}$
13	Ortalama	$\bar{x}$
14	Ortalama karakök değeri (Root mean squared value)	x_{rms}
15	Standart sapma	x_{std}
16	Şekil faktörü (Shape factor)	x_{SF}
17	Basıklık (Kurtosis)	$x_{Kurtosis}$
18	Çarpıklık (Skewness)	$x_{Skewness}$
19	Tepe değeri	x_{peak}
20	İmpulse faktörü (İmpulse factor)	$x_{impulse}$
21	Tepe faktörü (Crest factor)	x_{crest}
22	Temizlik faktörü (Clearance factor)	$x_{clearance}$
23	Sinyal-Gürültü oranı (SNR)	SNR
24	Toplam harmonik distorsiyon (THD)	THD
25	Sinyal-Gürültü ve bozulma oranı (SINAD)	SINAD

Tablo 5.2. EKG sinyali için zaman serisi özellikleri.

EKG Özellik Numarası	Özellik	Formül/Kısaltmalar
26	Minimum	x_{min}
27	Medyan	x_{med}
28	Maksimum	x_{max}
29	First quartile	x_1
30	Third quartile	x_3
31	Çeyrekler arası genişlik (IQR)	x_{iqr}
32	Custom Quartile (0.95)	x_{cqr}
33	Otokorelasyon değeri (ACF)	ACFn
34	Otokorelasyon değerinin karelerinin toplamı (ssACF)	ssACFn
35	Kısmi otokorelasyon değeri (PACF)	PACFn
36	Kısmi otokorelasyon değerinin karelerinin toplamı (ssPACF)	ssPACFn

Tablo 5.3. EKG sinyali için frekans tabanında özellikler.

EKG Özellik Numarası	Özellik	Formül/Kısaltmalar
37	Spektral tepe değerinin genliği	PeakAmp
38	Spektral tepe değerinin frekansı	PeakFreq
39	Doğal frekansı (Natural frequency)	Wn
40	Sönümlleme katsayıları (Damping factor)	Zeta
41	Frekans bandı enerjisi	Band Power

Tablo 5.4. EKG sinyali için zaman-frekans tabanında spektrogram ve EMD özellikleri.

EKG Özellik Numarası	Özellik	Formül/Kısaltmalar
42	Spektral entropi	SpectralEntropy
43	Tepe değeri	PeakValue
44	İmpulse faktörü (İmpulse factor)	ImpulseFactor
45	Tepe faktörü (Crest factor)	CrestFactor
46	Temizlik faktörü (Clearance factor)	ClearanceFactor
47-49	*Enerji	EnergyIMFn
50-52	*Tepe değeri	PeakValueIMFn
53-55	*İmpulse faktörü (İmpulse factor)	ImpulseFactorIMFn
56-58	*Tepe faktörü (Crest factor)	CrestFactorIMFn
59-61	*Temizlik faktörü (Clearance factor)	CleatanceFactorIMFn

* işaretli özellikler için IMF sayısı 3 olarak belirlenmiştir. Buradaki n sayısı kadar IMF sinyaller için 20 ,21, 22 numaralı özellikler tekrardan hesaplanmıştır. 44, 45, 46 numaralı özellikler zaman frekans bandında ayrıca hesaplanarak eklenmiştir.

5.5. Veri Seti İstatistikleri

Potasyum ve kalsiyum için kan örneklerini topladığımız hastaların demografik bilgilerini de ekliyoruz. Bunları sayısal olarak ICD kodları ve belirli yaş aralıkları kullanarak temsil ediyoruz. Son olarak özellik vektörü toplamda 63 özelliğten oluşmasını sağlıyoruz. Glükoz veri setinde bu özellikler hastalığın evresine ve yaş grubuna ayrılmadığı için bu verileri orada kullanılmamıştır.

Normal serum kalsiyum seviyeleri genellikle desilitre başına 8,5 ile 10,5 miligram (mg/dL) arasında değişir. Serum kalsiyum seviyelerindeki anormallikler, hiperkalsemi (yüksek kalsiyum seviyeleri) ve hipokalsemi (düşük kalsiyum seviyesi) olarak ikiye ayrılabilir. Aynı şekilde potasyum için normal serum potasyum seviyeleri 3,5 (mg/dL) ile 4,5 (mg/dL) arasındadır. Bunun dışındaki seviyeler anormal serum seviyeler ayrılmaktadır.

Glükoz seviyesinin sınıflandırılması için, 30 dakika sonra kan şekeri değeri 10 (mmol/l) 'den yüksekse sınıf hiperglisemi olarak tanımlandı; 3,9 (mmol/l) 'ten düşükse sınıf hipoglisemi olarak tanımlandı. Bunun dışındaki seviyeler Euglisemi serum seviyeleri olarak ayrılmaktadır.

Tablo 5.5. Özellik gruplarının kategorize edilmesi ve veri seti örnek sayısı.

Veri seti tipi	Özellik sayısı	Özellik tipleri	Örnek sayısı	EKG sinyali uzunluğu	Sınıflar
Potasyum (Kronik böbrek hastası)	63	• Morfolojik ve Zaman • Zaman Serisi • ICD kodları ve Yaş • Frekans • Zaman-Frekans	116	1000	Normal Anormal
Kalsiyum (Kronik böbrek hastası)	63	• Morfolojik ve Zaman • Zaman Serisinde • ICD kodları ve Yaş • Frekans • Zaman-Frekans	101	1000	Normal Anormal
Glükoz (Diyabet hastası)	61	• Morfolojik ve Zaman • Zaman Serisinde • Frekans • Zaman-Frekans	1062	15000	Hipoglisemi Hiperglisemi Euglisemi



6. METODLAR

6.1. Giriş

Tez çalışmasının bu bölümünde verilerin işlenmesi için kullanılan yöntemlere yer verilmiştir. Özellik seçme algoritması olarak F-test ve ANOVA özellik seçme algoritmaları kullanılmıştır. Daha sonraki bölümlerde ise sınıflandırma ve regresyon algoritmalarının tahmininde doğruluğu artırmak için nasıl entegre edildiğini açıklanmıştır. Bu adımların her biri modelin performansını etkilemede kritik öneme sahiptir ve sonraki alt bölümlerde bu süreçlerin detaylı analizine odaklanılmıştır.

6.2. Özellik Seçme Algoritması

6.2.1. F-test özellik seçme algoritması

Özellik seçimi, bir model oluşturmak için en ilgili özellikleri belirlemeye yönelik makine öğreniminde kritik bir adımdır. F-test, özellik seçimi için yaygın olarak kullanılan bir yöntemdir.

Özellik seçiminde F-test ölçümlerinin optimize edilmesi, her bir sınıfa farklı maliyetler atayarak sınıflar arasındaki dengesizliği azaltmayı amaçlamaktadır. Bu yaklaşım, yalnızca çoğunluk sınıfını değil, tüm sınıfları doğru bir şekilde yansıtan özelliklerin seçimine odaklanmaktadır. Böylelikle, dengesiz veri setlerinde modellerin performansı arttırılabilmektedir (Liu vd., 2018).

F-test değerlerini sıralayıp grafiksel olarak analiz ederek, özelliklerin önem seviyesinin kırılma noktasını tespit etmek mümkündür. Bu yöntemde, F-test'e göre sıralanmış özelliklerin grafiği çizilir ve eğrinin en keskin şekilde değiştiği dirsek (elbow) noktası belirlenir. Dirsek noktası, özelliklerin model performansına olan katkısının azaldığı yeri gösterir ve genellikle en uygun eşik değeri olarak kabul edilir. Böylece, daha az önemli olan özellikler elenir. Eşik değeri belirlerken, veri setinin yapısını ve model performansını göz önünde bulundurmak kritiktir. Ayrıca çapraz doğrulama bu süreçte en güvenilir yöntemdir (Tibshirani vd., 2001).

$$F - test = \frac{\sum_{j=1}^k p_j (\mu_j - \mu)^2}{\sum_{j=1}^k p_j \sigma_j^2} \quad (6.1)$$

F-test için gerekli terimler aşağıda tanımlanmıştır:

μ_j : Belirli bir özellik için belirli bir sınıftaki veri noktalarının ortalaması.

σ_j : Belirli bir özellik için belirli bir sınıftaki veri noktalarının standart sapması.

p_j : Belirli bir sınıfa ait veri noktalarının kesiri.

μ : Özelliğe ilişkin verilerin küresel ortalaması.

Tablo 7.2’de F-test algoritması kullanılarak sıralanan glükoz, kalsiyum ve potasyum için özellik önem derecelerini gösterilmektedir. Her bir satır, EKG ölçümleriyle ilgili farklı bir özelliği temsil etmekte olup, karşılık gelen F-test puanları, her bir özelliğin analiz bağlamındaki önemini veya anlamını göstermektedir. Buradaki sıralama da dirsek eğrisi üzerinden en yüksek olduğu noktalar belirlenmiştir.

6.2.2. ANOVA özellik seçme algoritması

ANOVA varyans tabanlı bir istatistiksel teknik, grup ortalamalarını karşılaştırmak ve aralarındaki istatistiksel olarak anlamlı farkları belirlemek için kullanılır. Veri değişkenliği, popülasyon ortalaması eşitsizliğini belirlemek için tek yönlü ANOVA kullanılarak analiz edilir. Kullanıcıların doğrudan tek yönlü ANOVA gerçekleştirmesine ve grup ortalamalarının önemli ölçüde farklı olup olmadığını gösteren p-değerini belirlemesine olanak tanır. İki farklı faktörün verileri nasıl etkilediğini belirleyerek, bu işlev bileşenler arasındaki değişkenlik ve etkileşimin daha kapsamlı bir şekilde anlaşılmasını sağlar (Stohle & Wold, 1989).

Tablo 7.1’de ANOVA algoritması kullanılarak sıralanan glükoz, kalsiyum ve potasyum için özellik önem derecelerini gösterilmektedir.

6.3. Makine Öğrenmesi Metodları

Bu bölümde, Regresyon ve Sınıflandırma yöntemlerine dayanan yaygın olarak kullanılan modelleme yaklaşımları tanımlanmaktadır.

6.3.1. Regresyon algoritmaları

Bu bölüm, Ensemble regresyonu, Yapay Sinir Ağları regresyonu (NN-R) ve FIS regresyonuna dayanan yaygın olarak kullanılan modelleme tekniklerini açıklamaktadır.

6.3.1.1. Yapay sinir ağı regresyon modeli


Bu çalışmada, çok katmanlı ileri beslemeli yapay sinir ağı kullanılmıştır. Modelde üç ara katmana sahip çok katmanlı bir yapı ile eğitim modeli oluşturulmuştur.

Geri besleme kontrollü yapay sinir ağları, bir giriş katmanı, bir çıkış katmanı ve bir veya daha fazla ara katmana sahip olan sinir ağlarıdır. Bu ağlar, bilgiyi giriş katmanından çıkış katmanına tek yönde iletmek için farklı aktivasyon parametreleri kullanılır. Gizli katmandaki hücre sayısını belirlemek için farklı yöntemler kullanılabilmektedir. Ancak, genellikle deneme yanılma ile hücre sayısı belirlenmektedir. Bu çalışmada parametreler hiper parametre analizinde bayes optimizasyonu ile tespit edilmiştir (Walczak & Cerpa, 1999).

Gizli katman çıkış vektörü $h = (h_1, h_2, h_s)$ ağ giriş vektörü $x = (x_1, x_2, x_k)$ üzerinden elde edilir ve çıktı katmanında işlendikten sonra çıkış vektörü $y = (y_1, y_2, y_z)$, haline dönüştürülür. Çıkış vektörleri $Y = [y(1), \dots, y(N)]$, şeklindedir; burada N, giriş ve çıkış vektörlerinin sayısını ifade eder ve tüm dikkate alınan giriş vektörleri için $X = [x(1), \dots, x(N)]$ aşağıdaki gibi hesaplanır.

$$Y = \varphi(W^y[\psi(W^h X + b^h)] + b^y) \quad (6.2)$$

Burada $\varphi(.)$ ve $\psi(.)$ sırasıyla çıkış katmanındaki ve gizli katmandaki hücrelerin aktivasyon fonksiyonlarını temsil etmektedir. Hem gizli katman hem de çıkış katmanı, kullanıcılara hücreleri için bir sınır değeri vektörü sağlar. Şekil 6.1 'de giriş, çıkış ve ara katman sayıları bayes optimizasyon teknikleri ile belirlenmiştir.



Şekil 6.1. Yapay sinir ağı regresyon modeli diyagramı.

NN-R modeli için burada seçilen model parametreleri şunlardır. Bir gizli katmanı olan çok katmanlı ileri beslemeli bir ağ, bu gizli katmanda üç ara katman bulunmaktadır ve farklı aktivasyon fonksiyonu kullanılmaktadır; çıkış katmanı ise tek bir nöron içermektedir.

6.3.1.2. Regresyon tabanlı FIS modeli

FIS, belirsizlikleri ve verilerdeki hataları etkili bir şekilde yönetmek için bulanık mantık ve çıkarımsal yöntemleri birleştiren hesaplama çerçevesidir. Özellikle geleneksel ikili mantık sistemlerinin yetersiz kaldığı durumlarda son derece değerlidirler. Bu, açık kuralları olmayan ve birçok değişkenin yönetilebilen tip-2 FIS bu çalışmada kullanılmıştır. Sistem, girdileri temsil etmek için Gauss üye fonksiyonları kullanılmaktadır ve çıktıyı elde etmek için lineer parametrelili sistem fonksiyonları kullanılır. Genetik bir algoritma, çoklu hedef fonksiyonuna dayalı olarak

sistem parametrelerini belirlemek için kullanılmaktadır. Bu yaklaşım, evrimsel algoritmayı bir özellik seçme yöntemi ile birleştirir. Fonksiyonların amacı iki bileşenden oluşmaktadır: aktif özelliklerin sayımı ve regresyon modelleri için doğrulama hatası ya da sınıflandırma modelleri için doğruluktur. Bu yöntemin amacı, modelin kalitesi ile sadeliği arasında uyumlu bir denge sağlamaktır (Wiktorowicz, 2023).

6.3.1.3. Ensemble regresyon

Topluluk algoritmaları, makine öğreniminde özellikle regresyon görevleri için güçlü bir araçtır. Birden fazla modeli birleştirerek öngörü performansını, dayanıklılığı ve genelleştirmeyi artırır. Bu sentez, regresyon için çeşitli topluluk yöntemlerini, teorik temellerini, pratik uygulamalarını ve karşılaştırmalı performanslarını keşfeder (Duffy & Helmbold, 2002).

Boosting yöntemleri, modifiye edilmiş örnekler üzerinde temel regresyonları yinelemeli olarak çağırarak performansı artırır. Gradyan inişine dayalı algoritmalar, güçlü teorik garantiler ve rekabetçi performans sunar. Kural toplulukları, karar ağaçlarını regresyon görevleri için optimize edilmiş kurallara dönüştürür (Zelenkov, 2023).

6.3.2. Sınıflandırma algoritmaları

Sınıflandırma problemleri, makine öğrenimi alanında önemli bir rol oynamaktadır çünkü verilerin ayrı sınıflara ayrılmasını ve tahminler yapılmasını sağlar. Destek Vektör Makineleri, Ensemble Öğrenme yöntemleri ve k-En Yakın Komşu birçok yaklaşım arasında verimlilikleri ile geniş çapta kabul görmektedir.

6.3.2.1. Destek vektör makinaları

Destek Vektör Makineleri , verileri hem lineer hem de lineer olmayan senaryolarda etkili bir şekilde sınıflandırabilen sağlam ve esnek bir makine öğrenimi modelidir. Algoritma, özellik alanındaki sınıfları en etkili şekilde ayıran hiper düzlemi belirleyerek çalışır (Mammone vd., 2009).

6.3.2.2. Ensemble sınıflandırma

Topluluk öğrenme yöntemleri, birden fazla modeli bir araya getirerek, yalnızca bileşen modellerden elde edilebilecek olandan daha iyi bir tahmin performansı elde etmeyi

amaçlar. Her bir model, veri setini bağımsız olarak sınıflandırır ve sonuçlar daha sonra nihai tahmin yapmak için topluluk oyu yöntemiyle birleştirilir. Bu yaklaşım, tek sınıflandırma modellerine kıyasla üstün doğruluk ve genelleme yetenekleri sergilemiştir (Opitz & Maclin, 1999).

6.3.2.3. K-en yakın komşu algoritması

k-NN, sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir. Basit bir ilkeye dayanır: Verilen bir örneğin sınıfını belirlemek için, özellik alanındaki 'k' en yakın eğitim örneğini tanımlar ve aralarındaki en yaygın sınıf örneğine atanır (Peterson, 2009).

6.3.3. Hiperparametre ayarı

Hiperparametre ayarlama sürecinde, ilk adım değiştirilecek parametrelerin belirlenmesidir; ardından bu parametreler için olası değerlerin veya aralıkların tanımlanması gelmektedir. Daha sonra, modelin performansını değerlendirmek için bir doğrulama yöntemi oluşturulur ve bu strateji için uygun bir optimizasyon tekniği seçilir. Optimizasyon metodolojisi genellikle kapsamlı arama, rastgele arama veya olasılıksal yöntemler gibi birçok metodolojiyi içerir.

Hiperparametre ayarı, bir öğrenme algoritması için ideal bir hiperparametre setinin seçilmesini içeren makine öğreniminde önemli bir süreçtir. Makine öğrenimi modellerinin verimliliği, hiperparametrelerin yapılandırmasından büyük ölçüde etkilenebilir. Varsayılan değerler genellikle mevcut olsa da, bu değerler her zaman optimal model performansı sağlamayabilir.

Örneğin, bir modelin performansı, ensemble öğrenme algoritmasında ağaç sayısı veya gradyan artırma öğrenme oranı gibi hiperparametrelerden etkilenebilir. Bu hiperparametreler, hem tahmin performansını hem de değişkenlerin önem ölçülerini etkileyebilir. Varsayılan hiperparametreler birçok senaryoda etkili olabilirken, bunların ince ayarının yapılması performansı artırabilir (Bocklet vd., 2008; Gavala & Myriantsefs, 2017).

Tablo 6.1. ve Tablo 6.2.'de, Potasyum, Kalsiyum ve Glüköz veri setinde kullanılan üç farklı makine öğrenimi yöntemleri için hiperparametre optimizasyon tekniklerinin özeti verilmiştir. Bayes optimizasyonu tekniği model performansını maksimize etmek için en optimal hiperparametre değerlerinin belirlenmesini kolaylaştırmaktadır. Bu kapsamlı tablo, kullanılan birçok hiperparametreyi ve bunların ilgili değer aralıklarını

özetleyen geniş bir çerçeve sunarak, her bir modelin optimize edilmesi amacıyla gösterilmektedir. Bu yaklaşım, hiperparametre seçiminin her modelin veri setindeki performansını belirlemedeki önemini vurgular ve bu seçimlerin sonuçlar üzerindeki etkilerini incelemek için bir temel sunmaktadır.



Tablo 6.1. Potasyum ve Kalsiyum için anıflandırma modellerinde kullanılan hiperparametre optimizasyon stratejisi.

Veriseti adı	Örnek sayısı	Öznitelik sayısı	Sınıf etiketi	Sınıflandırma modeli	Hiperparametre stratejisi: 100 iterasyon ile Bayes Optimizasyonu		Türü	Dönüşüm
					Parametre adı	Aralık		
Potasyum	116	63	Anormal Normal	k-NN	Komşuluk sayısı	[1,52]	Tam Sayı	log
					Uzaklık	["cityblock", "chebychev", "correlation", "cosine", "euclidean", "hamming", "jaccard", "minkowski", "seuclidean", "spearman"]	Kategorik	-
					Standlaştırma	["true", "false"]	Kategorik	-
Kalsiyum	101				Uzaklık ağırlığı	["Equal", "inverse", "squaredinverse"]	Kategorik	-
Potasyum	116	63	Anormal Normal	DVM	Lambda	[9.7087x10 ⁸ -970.8738]	Gerçek Değer	log
					Learner	["svm", "logistic"]	Kategorik	-
Kalsiyum	101				Regularization	["lasso", "ridge"]	Kategorik	-
Potasyum	116	63	Anormal Normal	Ensemble öğrenme	Method	["Bag", "GentleBoost", "LogitBoost", "AdaBoostM1", "RUSBoost"]	Kategorik	log
					Öğrenme döngü sayısı	[1,950]	Tam Sayı	-
					Öğrenme oranı	[0.00001,1]	Gerçek Değer	-
Kalsiyum	101				Min yaprak boyutu	[1,100]	Tam Sayı	-
					Öncelik	["uniform", "empirical"]	Kategorik	log

Tablo 6.2. Glükoz için sınıflandırma modellerinde kullanılan hiperparametre optimizasyon stratejisi.

Veriseti adı	Örnek sayısı	Öznitelik sayısı	Sınıf etiketi	Sınıflandırma modeli	Hiperparametre stratejisi: 100 iterasyon ile bayes optimizasyonu			
					Parametre adı	Aralık	Türü	Dönüşüm
Glükoz	1062	61	Hipoglisemi Hiperglisemi Euglisemi	k-NN	Komşuluk sayısı	[1,52]	Tam Sayı	log
					Uzaklık	["cityblock", "chebychev", "correlation", "cosine", "euclidean", "hamming", "jaccard", "minkowski", "seuclidean", "spearman"]	Kategorik	-
					Standlaştırma	["true", "false"]	Kategorik	-
					Uzaklık ağırlığı	["Equal", "inverse", "squaredinverse"]	Kategorik	-
Glükoz	1062	61	Hipoglisemi Hiperglisemi Euglisemi	DVM	Lambda	[9.7087x10 ⁸ -970.8738]	Gerçek Değer	log
					Learner	["svm", "logistic"]	Kategorik	-
					Regularization	["lasso", "ridge"]	Kategorik	-
Glükoz	1062	61	Hipoglisemi Hiperglisemi Euglisemi	Ensemble öğrenme	Method	["Bag", "GentleBoost", "LogitBoost", "AdaBoostM1", "RUSBoost"]	Kategorik	log
					Öğrenme sayısı	[1,950]	Tam Sayı	-
					Öğrenme oranı	[0.00001,1]	Gerçek Değer	-
					Min yaprak boyutu	[1,100]	Tam Sayı	-
					Öncelik	["uniform", "empirical"]	Kategorik	log

6.4. Performans Değerlendirme Kriterleri

Sınıflandırma için önerilen sistemlerin doğruluk oranları, çeşitli performans değerlendirme kriterleri kullanılarak test edilmiştir. Doğruluk oranı (Accuracy oranı), duyarlılık (sensitivity), özgüllük (specificity), kappa katsayısı, MCC ve F-ölçütü hesaplanmıştır. Regresyon tabanlı uygulama için performans değerlendirmesinde RMSE ve R^2 katsayıları hesaplanmıştır.

Denklem 6.3, 6.4, 6.5 ve 6.7’de yer alan TP, TN, FP ve FN sırasıyla Gerçek Pozitif (True Positives, TP), Gerçek Negatif (True Negatives, TN), Yanlış Pozitif (False Positives, FP) ve Yanlış Negatif (False Negatives, FN)’dir.

$$\text{Doğruluk} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (6.3)$$

$$\text{Duyarlılık} = \frac{TP}{(TP + FN)} \quad (6.4)$$

$$\text{Özgüllük} = \frac{TN}{(TN + FP)} \quad (6.5)$$

$$F - \text{ölçütü} = 2 \times \frac{(\text{Duyarlılık} \times \text{Özgüllük})}{(\text{Duyarlılık} + \text{Özgüllük})} \quad (6.6)$$

$$MCC = \frac{(TP \times TN - FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (6.7)$$

Kappa katsayısı, iki değerlendirici veya yöntem arasındaki anlaşmayı ölçen bir istatistiktir ve genellikle epidemiyoloji, tıbbi araştırmalar ve güvenilirlik çalışmaları gibi çeşitli alanlarda kullanılır. Şansa bağlı olarak meydana gelen anlaşmazlıkları dikkate alır ve basit yüzdelik anlaşmaya kıyasla daha sağlam bir değerlendirici güvenilirliği ölçüsü sağlar. Hesaplanan kappa katsayısı 0 ile 1 arasında değişmektedir. Eğer kappa katsayısı 1’e yaklaşırsa tahmin edilen ile gerçek değer çok iyi düzeyde uyum sağladığını göstermektedir. 0’a yaklaştıkça ise zayıf uyum sağlamaktadır (Fleiss & Cohen, 1973).

R^2 ve hataların ortalama kare kökü (RMSE) metrikleri, diğer ölçümlere kıyasla daha kapsamlı ve içgörülü bilgiler sağlar. R^2 olarak adlandırılan belirleme katsayısı, regresyon analizini değerlendirmek için diğer metriklerden üstün kabul edilir. Bunun

nedeni, R^2 'nin yalnızca gerçek değerlerin büyük bir kısmı doğru bir şekilde tahmin edildiğinde yüksek bir puan sağlaması ve diğer metriklerde ortaya çıkan yorumlanabilirlik sınırlamalarının üstesinden gelmesidir (Chicco vd., 2021).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (6.8)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (6.9)$$




7. SONUÇLAR

Bu bölümde tez çalışması kapsamında elde edilen sonuçlar sunulmuştur. Tez kapsamında KBH ve Type-1 diyabet hastalığının teşhisi için kullanılabilecek, mevcut sistemlere alternatif yeni yaklaşım yöntemleri geliştirilmiştir. Öncelikle KBH için önemli olan Kalsiyum Potasyum seviyelerinin tahmini ve normal ve anormal durumlarının sınıflandırma performansına yönelik yapılan deneysel sonuçlar verilecek, ardından Diyabet hastaları için önemli bir konsantrasyon olan kandaki Glükoz seviyeleri için aynı yöntemler tekrarlanacaktır.


7.1. Özellik Seçme

Sınıflandırma ve regresyon tahmini işlemi için yapılan işlemler Şekil 1.1.'deki akış diyagramına göre yapılmış ve sonuçlar elde edilmiştir. EKG'den çıkarılan özellikler istatistiksel yöntemlerle analiz edilmiş, sınıflara göre ANOVA algoritması ile özellik sıralaması yapılmıştır. Aynı şekilde konsantrasyon değerleri ile özellikler arasında anlamlı ilişki olup olmadığı ise F-test parametresi ile araştırılmıştır. Bu analizlere göre elde edilen sonuçlar Şekil 7.1., Şekil 7.2., Şekil 7.3. Şekil 7.4., Şekil 7.5., Şekil 7.6.'da gösterilmiştir.


Ayrıca, EKG'ye ait olan özelliğin anlamlı olanlarının seçimi yapılması için bir eşik değeri belirlenmesi gerekmektedir. Bunun için, veri biliminde optimal özellik veya parametre seçimi için yaygın olarak kullanılan grafiksel analiz ve (elbow) dirsek yöntemi ile tespit edilmiş grafiklere eklenmiştir.




Şekil 7.1. Diyabet hastası için glukoz konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.




Şekil 7.2. KBH hastası için kalsiyum konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.




Şekil 7.3. KBH hastası için potasyum konsantrasyonunun belirlenen sınıf parametresine göre ANOVA istatistiksel analiz sonuçları.



Şekil 7.4. Diyabet hastası için glukoz konsantrasyonunun F-test istatistiksel analiz sonuçları.



Şekil 7.5. KBH hastaları için kalsiyum konsantrasyonunun F-test istatistiksel analiz sonuçları.



Şekil 7.6. KBH hastaları için potasyum konsantrasyonunun F-test istatistiksel analiz sonuçları

İyonik konsantrasyonların sınıflandırılması işleminde kullanılabilecek özellikler ANOVA yöntemi ile belirlenmesinden sonra sınıflandırma işlemleri yapılmıştır. Ayrıca sınıflandırıcıların performanslarını değerlendirebilmek için tüm çıkarılan özellikler Elbow dirsek yöntemi ile seçilerek kullanılmıştır. Özelliklerin belirlenmesi için Elbow dirsek eğrisinden en yüksek 3 noktası tespit edilmiş ve her adımda sınıflandırma yapılarak farklı seviyelerde uygulanan seçim yönteminin etkisi incelenmiştir. Tablo 7.1.'de Elbow dirsek yöntemi sonrasında seçilen Glükoz, Potasyum ve Kalsiyum için özellikler gösterilmiştir. Tablo 7.1.'de "Özellik Sayısı" sütununda konsantrasyonların belirlenen sınıflar için çıkarılan toplam özellik sayıları verilmiştir. 1., 2. ve 3. özellik seçimleri her bir sütunda seçilen özellik sayısı altında ayrıca eklenmiştir.

Tablo 7.1. İyonik konsantrasyonların sınıflandırılmasında kullanmak için ANOVA ile özellik seçme sonuçları.

Özellik Seçme Sayısı		1.Özellik Seçme	2.Özellik Seçme	3.Özellik Seçme
Veri Setleri	Özellik Sayısı	Seçilen Özellik Sayısı	Seçilen Özellik Sayısı	Seçilen Özellik Sayısı
Potasyum	63	14	11	6
Kalsiyum	63	21	14	7
Glükoz	61	14	7	4

Yukarıdaki işleme benzer olarak iyonik konsantrasyonların regresyon algoritmaları ile değerlerinin tahmin edilmesi işleminde kullanılabilecek özellikler F-test yöntemi ile belirlenmesinden sonra aynı şekilde regresyon işlemleri yapılmıştır. Regresyon sonucu tahmin performanslarını değerlendirebilmek için tüm çıkarılan özellikler Elbow yöntemi ile seçilerek kullanılmıştır. Özelliklerin belirlenmesi için Elbow eğrisinden en yüksek 3 nokta tespit edilmiş ve her adımda regresyon yapılarak farklı seviyelerde uygulanan seçim yönteminin etkisi incelenmiştir. Tablo 7.2.'de Elbow yöntemi sonrasında seçilen Glükoz, Potasyum ve Kalsiyum için özellikler gösterilmiştir. Özellik seçme işlemi tamamlandıktan sonra sınıflandırma ve regresyon işlemi yapılmıştır.

Tablo 7.2. İyonik konsantrasyonların regresyon tahmininde kullanmak için F-test ile özellik seçme sonuçları.

Özellik Seçme Sayısı		1.Özellik Seçme	2.Özellik Seçme	3.Özellik Seçme
Veri Setleri	Özellik Sayısı	Seçilen Özellik Sayısı	Seçilen Özellik Sayısı	Seçilen Özellik Sayısı
Potasyum	63	22	11	7
Kalsiyum	63	16	10	4
Glükoz	61	13	7	5

7.2. Sınıflandırma Sonuçları

Sınıflandırma işlemleri Potasyum, Kalsiyum ve Glükoz için ayrı ayrı yapılmıştır. Glükoz özelliklerine ve seçilen alt özelliklere ait sınıflandırma sonuçları Tablo 7.3., Tablo 7.4. ve Tablo 7.5.’de Kalsiyum özelliklerine ve seçilen alt özelliklere ait sınıflandırma sonuçları Tablo 7.6., Tablo 7.7. ve Tablo 7.8.’de, Potasyum özelliklerine ve seçilen alt özelliklere ait sınıflandırma sonuçları Tablo 7.9., Tablo 7.10. ve Tablo 7.11.’de, Potasyum, Kalsiyum ve Glükoz sınıflandırma sonuçları Tablo 7.12.’de özetlenmiştir.

Tabloda kullanılan her sınıflandırıcı için sonuçlar ayrıntılı bir biçimde verilmiştir. Sınıflandırma işlemleri sırayla yapılmış olup sıra şu şekildedir. Öncelikle Potasyum, Kalsiyum ve Glükoz’a ait tüm özellikler herhangi bir özellik seçme algoritmasına tabi tutulmadan sınıflandırılmış ve sınıflandırıcının performansının ölçülmesi için performans parametreleri hesaplanarak ilgili sütuna yazılmıştır. Daha sonra 2. ve 3. kez özellik seçme yöntemi ile indirgenmiş ve tekrar sınıflandırma işlemi yapılmıştır. Sınıflandırıcılara ait performans kriterleri hesaplanarak tabloda gösterilmiştir. ANOVA ile özellik seçimi için elbow grafiği uygulandığında elde edilen özellik sayıları da yazılmıştır. Her sınıflandırıcıya ait “Hiperparametre” adlı sekmede, bulunduğu sınıflandırıcı için kullanılan optimum parametreler hesaplanmıştır.

Tablo 7.3. Glüköz için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları.

K-En Yakın Komşuluk Algoritması				
Hiperparametre	NumNeighbors:1 Distance:cityblock Standardize: true DistanceWeight: squaredinverse	NumNeighbors:5 Distance:seuclidean Standardize: false DistanceWeight: inverse	NumNeighbors:8 Distance:minkowski Standardize: true DistanceWeight: squaredinverse	NumNeighbors:8 Distance:cityblock Standardize: true DistanceWeight: squaredinverse
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 61	Özellik Sayısı = 14	Özellik Sayısı = 7	Özellik Sayısı = 4
Doğruluk	0,7137	0,7307	0,7420	0,7260
Duyarlılık	0,4109	0,4355	0,4657	0,4055
Özgüllük	0,7161	0,7170	0,7162	0,7054
F-ölçümü	0,4165	0,4631	0,5020	0,4141
MCC	0,1997	0,2898	0,3256	0,2402
Kappa	0,3559	0,3941	0,4195	0,3835
k(5)-fold (%)				

Tablo 7.4. Glüköz için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları.

Destek vektör makinaları algoritması				
Hiperparametreleri	Coding:onevsall BoxConstraint:0.0071 KernelScale: 0.0720 Standardize: true	Coding:onevsone BoxConstraint:986.667 KernelScale: 0.2217 Standardize: true	Coding:onevsone BoxConstraint:986.5889 KernelScale: 0.2748 Standardize: true	Coding:onevsall BoxConstraint:291.8913 KernelScale: 207.3074 Standardize: false
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 61	Özellik Sayısı = 14	Özellik Sayısı = 7	Özellik Sayısı = 4
Doğruluk	0,7034	0,6328	0,6045	0,5829
Duyarlılık	0,3695	0,3777	0,3747	0,3589
Özgüllük	0,6870	0,6718	0,6977	0,6793
F-ölçümü	0,3533	0,3800	0,3738	0,3526
MCC	0,1240	0,0634	0,0740	0,0369
Kappa	0,3326	0,1737	0,1102	0,0614
k(5)-fold (%)				

Tablo 7.5. Glüköz için belirlenen özelliklere ait Ensemble sınıflandırıcı sonuçları.

		Ensemble Algoritması		
Hiperparametreleri	Method:AdaBoostM2	Method:AdaBoostM2	Method:AdaBoostM2	Method:AdaBoostM2
	NumlearningCycles:415	NumlearningCycles:895	NumlearningCycles:808	NumlearningCycles:906
	LearnRate: 0,9365	LearnRate: 0,2327	LearnRate: 0,9009	LearnRate: 0,9714
	MinLeafSize:59	MinLeafSize:1	MinLeafSize:5	MinLeafSize:3
	Prior:Uniform	Prior:Empirical	Prior:Empirical	Prior:Uniform
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 61	Özellik Sayısı = 14	Özellik Sayısı = 7	Özellik Sayısı = 4
Doğruluk	0,8013	0,7891	0,7863	0,7966
Duyarlılık	0,5647	0,5488	0,5506	0,5746
Özgüllük	0,8052	0,7929	0,7999	0,8067
F-ölçümü	0,6180	0,5993	0,5893	0,6238
MCC	0,4917	0,4581	0,4322	0,4804
Kappa	0,5530	0,5254	0,5191	0,5424
k(5)-fold (%)				

Tablo 7.6. Kalsiyum için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları.

		K-En Yakın Komşuluk Algoritması		
Hiper Parametreleri	NumNeighbors:24	NumNeighbors:4	NumNeighbors:11	NumNeighbors:1
	Distance:correlation	Distance:seuclidean	Distance: seuclidean	Distance:minkowski
	Standardize: false	Standardize: false	Standardize: false	Standardize: false
	DistanceWeight: inverse	DistanceWeight: inverse	DistanceWeight: inverse	DistanceWeight: inverse
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 21	Özellik Sayısı = 14	Özellik Sayısı = 7
Doğruluk	0,6139	0,6535	0,6634	0,5743
Duyarlılık	0,8889	0,7222	0,7593	0,5926
Özgüllük	0,2979	0,5745	0,5532	0,5532
F-ölçümü	0,7111	0,6903	0,7069	0,5981
MCC	0,2338	0,3003	0,3201	0,1456
Kappa	0,1940	0,2988	0,3159	0,1456
k(5)-fold (%)				

Tablo 7.7. Kalsiyum için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları.

Destek vektör makinaları algoritması				
Hiper Parametreleri	BoxConstraint:0.001	BoxConstraint:0.8555	BoxConstraint:0.0064	BoxConstraint:4.1425
	KernelScale: 5.7545	KernelScale: 164.7413	KernelScale: 0.0304	KernelScale: 0.001
	Standardize: false	Standardize: false	Standardize: false	Standardize: false
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 21	Özellik Sayısı = 14	Özellik Sayısı = 7
Doğruluk	0,5941	0,5941	0,6337	0,6040
Duyarlılık	0,8704	0,6481	0,7963	0,6481
Özgüllük	0,2766	0,5319	0,4468	0,5532
F-ölçümü	0,6963	0,6306	0,6992	0,6364
MCC	0,1840	0,1811	0,2606	0,2021
Kappa	0,1526	0,1808	0,2482	0,2019
k(5)-fold (%)				

Tablo 7.8. Kalsiyum için belirlenen özelliklere ait Ensemble sınıflandırıcı sonuçları.

Ensemble algoritması				
Hiper Parametreleri	Method:AdaBoostM1	Method:AdaBoostM1	Method:GentleBoost	Method:Bag
	NumlearningCycles:339	NumlearningCycles:89	NumlearningCycles:9	NumlearningCycles:440
	LearnRate: 0,0090	LearnRate:0,0293	LearnRate:0,1307	LearnRate: -
	MinLeafSize:2	MinLeafSize:1	MinLeafSize:7	MinLeafSize:3
	Prior:Uniform	Prior: Empirical	Prior:Empirical	Prior:Uniform
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 21	Özellik Sayısı = 14	Özellik Sayısı = 7
Doğruluk	0,6040	0,6139	0,6436	0,5842
Duyarlılık	0,5741	0,5926	0,7778	0,5741
Özgüllük	0,6383	0,6383	0,4894	0,5957
F-ölçümü	0,6078	0,6214	0,7000	0,5962
MCC	0,2121	0,2304	0,2800	0,1694
Kappa	0,2106	0,2293	0,2716	0,1689
k(5)-fold (%)				

Tablo 7.9. Potasyum için belirlenen özelliklere ait k-NN sınıflandırıcı sonuçları.

K-En Yakın Komşuluk Algoritması				
Hiper Parametreleri	NumNeighbors:4 Distance:chebychev Standardize: true DistanceWeight:Equal	NumNeighbors:9 Distance:cosine Standardize: true DistanceWeight:inverse	NumNeighbors:4 Distance:chebychev Standardize: false DistanceWeight:squaredinverse	NumNeighbors:2 Distance:spearman Standardize: false DistanceWeight:inverse
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 14	Özellik Sayısı = 11	Özellik Sayısı = 6
Doğruluk	0,8103	0,8017	0,8103	0,7672
Duyarlılık	0,2174	0,1739	0,1739	0,3478
Özgüllük	0,9570	0,9570	0,9677	0,8710
F-ölçümü	0,3125	0,2581	0,2667	0,3721
MCC	0,2599	0,2060	0,2372	0,2309
Kappa	0,2262	0,1735	0,1919	0,2301
k(5)-fold (%)				

Tablo 7.10. Potasyum için belirlenen özelliklere ait DVM sınıflandırıcı sonuçları.

Destek vektör makinaları algoritması				
Hiper Parametreleri	BoxConstraint:296.211 KernelScale: 14.3416 Standardize: true	BoxConstraint:0.1269 KernelScale: 0.0112 Standardize: false	BoxConstraint:0.0093 KernelScale: 0.0379 Standardize: false	BoxConstraint:0.0566 KernelScale: 0.0444 Standardize: false
	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 14	Özellik Sayısı = 11	Özellik Sayısı = 6
Doğruluk	0,7586	0,6466	0,8017	0,7845
Duyarlılık	0,3913	0,5652	0,1739	0,2174
Özgüllük	0,8495	0,6667	0,9570	0,9247
F-ölçümü	0,3913	0,3881	0,2581	0,2857
MCC	0,2408	0,1905	0,2060	0,1861
Kappa	0,2408	0,1726	0,1735	0,1733
k(5)-fold (%)				

Tablo 7.11. Potasyum için belirlenen özelliklere ait Ensemble öğrenme sınıflandırıcı sonuçları.

	Ensemble öğrenme algoritması			
	Method:AdaBoostM1 NumlearningCycles:663 LearnRate: 1.1051e-5 MinLeafSize:2 Prior:Uniform	Method:AdaBoostM1 NumlearningCycles:947 LearnRate: 0.0001 MinLeafSize:1 Prior:Uniform	Method:RUSBoost NumlearningCycles:947 LearnRate: 1.5151e-5 MinLeafSize:1 Prior:empirical	Method:LogitBoost NumlearningCycles:2 LearnRate: 4.9364e-5 MinLeafSize:6 Prior:uniform
Hiper Parametreleri	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
Performans Kriterleri	Özellik Sayısı = 63	Özellik Sayısı = 14	Özellik Sayısı = 11	Özellik Sayısı = 6
Doğruluk	0,8103	0,7759	0,6466	0,7845
Duyarlılık	0,3043	0,4348	0,7391	0,4783
Özgüllük	0,9355	0,8602	0,6237	0,8602
F-ölçümü	0,3889	0,4348	0,4533	0,4681
MCC	0,3031	0,2950	0,2908	0,3331
Kappa	0,2868	0,2950	0,2460	0,3330
k(5)-fold (%)				

Tablo 7.12. Sınıflandırma sonuçları için genel değerlendirme tablosu.

	Potasyum	Kalsiyum	Glüköz
Sınıflandırıcı	Ensemble	k-NN	Ensemble
Hiper Parametreleri	Method:LogitBoost NumlearningCycles:2 LearnRate: 4.9364e-5 MinLeafSize:6 Prior:uniform	NumNeighbors:11 Distance: seculdean Standardize: false DistanceWeight: inverse	Method:AdaBoostM2 NumlearningCycles:415 LearnRate: 0,9365 MinLeafSize:59 Prior:Uniform
Performans Kriterleri	Özellik Sayısı = 6	Özellik Sayısı = 14	Özellik Sayısı = 61
Doğruluk	0,7845	0,6634	0,8013
Duyarlılık	0,4783	0,7593	0,5647
Özgüllük	0,8602	0,5532	0,8052
F-ölçümü	0,4681	0,7069	0,6180
MCC	0,3331	0,3201	0,4917
Kappa	0,3330	0,3159	0,5530
k(5)-fold (%)			

7.3. Regresyon Sonuçları

MIMIC III ve DINAMO veri kümesi birçok klinik veriyi dağınık bir biçimde içermektedir. Bu nedenle, gerekli koşulları karşılayan veri setleri filtrelendi ve EKG gibi elektriksel sinyallerle eşleştirildi. Bu eşleşmelerden elde edilen EKG sinyalleri üzerinde farklı teknikler kullanılarak özellikler oluşturuldu. Amacımız, regresyon modelinin bir parçası olarak kabul edilen Ensemble Regresyon, Neural Network Regresyon ve Regresyon tabanlı FIS yöntemleri ile performans sonuçlarını, özelliklerin performansa etkisini ve doğrulama süreçlerini karşılaştırmaktır.

Morfolojik, frekans ve zaman-frekans alanına dayalı özellik verileri, hastaların kan kalsiyum, potasyum ve glukoz değerlerini tahmin etmek için regresyon modeline girdi olarak kullanılmıştır. Ensemble Regresyon, NN-R ve FIS'in performans sonuçları Tablo 7.13., Tablo 7.14. ve Tablo 7.15.'de gösterilmektedir.

Tablo 7.13. Potasyum için belirlenen özelliklere ait regresyon sonuçları.

Ensemble regresyon algoritması				
Hiper Parametreleri	Method:LSBoost NumLearningCycles:500 LearnRate:0.0075 MinLeafSize:13	Method:LSBoost NumLearningCycles:245 LearnRate:0.0592 MinLeafSize:17	Method:Bag NumLearningCycles:13 LearnRate: - MinLeafSize:2	Method:LSBoost NumLearningCycles:401 LearnRate: 0.0922 MinLeafSize:1
Performans Kriterleri	Özellik Seçimi Uygulanmadan Özellik Sayısı = 63	1.Özellik seçimi Özellik Sayısı = 22	2.Özellik seçimi Özellik Sayısı = 11	3.Özellik seçimi Özellik Sayısı = 7
RMSE	0,6219	0,8401	0,6766	0,6460
R ²	0,2562	0,1171	0,1488	0,3495
NN-R algoritması				
Hiper Parametreleri	NumLayers:3 Activations:sigmoid Standardize: false Lambda:0.0002 Layer_1_Size: 5 Layer_2_Size: 170 Layer_3_Size: 289	NumLayers:2 Activations:none Standardize:false Lambda:2.5098-6 Layer_1_Size: 298 Layer_2_Size: 200	NumLayers:3 Activations:none Standardize: true Lambda:9.7163e-6 Layer_1_Size: 50 Layer_2_Size:1 Layer_3_Size:218	NumLayers:3 Activations:none Standardize: true Lambda:3.4053e-5 Layer_1_Size: 69 Layer_2_Size:190 Layer_2_Size:43
RMSE	0,8881	0,7598	0,7897	0,7267
R ²	0,0181	0,2064	0,2247	0,2746
FIS Regresyon				
RMSE	-	0,9040	0,8966	0,6821
R ²	-	0,0583	0,0046	0,0153
Hold-on fold Eğitim= %70 Test= %30	-			

Tablo 7.14. Kalsiyum için belirlenen özelliklere ait regresyon sonuçları.

Ensemble Regresyon Algoritması				
Hiper Parametreleri	Method:Bag NumLearningCycles:14 LearnRate: - MinLeafSize:4	Method:LSBoost NumLearningCycles:170 LearnRate: 0.5281 MinLeafSize:5	Method:Bag NumLearningCycles:20 LearnRate: - MinLeafSize:50	Method:Bag NumLearningCycles:196 LearnRate: 0.0513 MinLeafSize:31
Performans Kriterleri	Özellik Seçimi Uygulanmadan	1.Özellik seçimi	2.Özellik seçimi	3.Özellik seçimi
	Özellik Sayısı = 63	Özellik Sayısı = 16	Özellik Sayısı = 10	Özellik Sayısı = 4
RMSE	0,8375	0,7867	0,9525	0,6929
R ²	0,0909	0,008	-0,0000	0,0144
NN-R algoritması				
Hiper Parametreleri	NumLayers:3 Activations:sigmoid Standardize: false Lambda:0.016 Layer_1_Size: 95 Layer_2_Size: 277 Layer_3_Size: 295	NumLayers:1 Activations:sigmoid Standardize: true Lambda:0.1537 Layer_1_Size: 299	NumLayers:1 Activations:none Standardize: true Lambda:8.0205e-7 Layer_1_Size: 35	NumLayers:1 Activations:tanh Standardize: true Lambda:1.0381e-7 Layer_1_Size: 3
RMSE	0,881	0,6769	0,6349	0,71
R ²	0,0278	0,0423	0,1487	0,3732
FIS Regresyon				
RMSE	-	0,7273	0,7284	0,6361
R ²	-	0,3013	0,2546	0,2187
Hold-on fold Eğitim= %70 Test= %30				

Tablo 7.15. Glüköz için belirlenen özelliklere ait regresyon sonuçları.

Ensemble regresyon algoritması				
Hiper Parametreleri	Method:Bag NumLearningCycles:151 LearnRate: - MinLeafSize:1	Method:Bag NumLearningCycles:14 LearnRate: - MinLeafSize:1	Method:Bag NumLearningCycles:232 LearnRate: - MinLeafSize:1	Method:Bag NumLearningCycles:67 LearnRate: - MinLeafSize:1
Performans Kriterleri	Özellik Seçimi Uygulanmadan Özellik Sayısı = 61	1.Özellik seçimi Özellik Sayısı = 13	2.Özellik seçimi Özellik Sayısı = 7	3.Özellik seçimi Özellik Sayısı = 5
RMSE	2,2933	2,3061	2,2948	2,4656
R ²	0,3551	0,4354	0,4196	0,4039
NN-R algoritması				
Hiper Parametreleri	NumLayers:3 Activations:tanh Standardize: true Lambda:0.0007 Layer_1_Size: 22 Layer_2_Size: 3 Layer_3_Size: 280	NumLayers:1 Activations:relu Standardize: true Lambda:0.0002 Layer_1_Size: 3	NumLayers:2 Activations:sigmoid Standardize: true Lambda:0.0441 Layer_1_Size: 4 Layer_2_Size: 214	NumLayers:2 Activations:sigmoid Standardize: true Lambda:5.5034e-8 Layer_1_Size: 1 Layer_2_Size:270
RMSE	2,9988	3,0094	2,8375	2,9914
R ²	0,0394	0,1695	0,1737	0,1158
FIS Regresyon				
RMSE	2,5991	2,93	2,8807	2,8459
R ²	0,2676	0,1059	0,1864	0,1489
Hold-on fold Eğitim= %70 Test= %30				

Potasyum, kalsiyum ve glüköz modellerinin tahmini için kullanılan veri seti performansını özetlemek gerekirse, çeşitli regresyon teknikleri, öznitelik sayısı ve veri seti türleri arasında çeşitli performans düzeylerinin farklılık gösterdiğini göstermektedir. RMSE değeri 0,646 ve R^2 değeri 0,3495 ile potasyum için Ensemble regresyon yönteminde başarılı olmuştur. Kalsiyum veri kümesi için ise NN-R ile yüksek performans göstermektedir. Bu sonuçlara göre seçilen dört özellik ile R^2 0,3732 değerini RMSE 0,71 değeri elde edilmiştir. Regresif tabanlı FIS, potasyum için daha yüksek bir RMSE'ye sahip olmasına rağmen NN-R'ye kıyasla daha tutarlı bir performans göstermektedir. R^2 değeri, test veri seti doğrulamaya daha iyi bir genelleme yapıldığını gösteriyor. NN-R algoritmasının farklı hiperparametre ayarları altında performansı değerlendirilmiştir.

Glüköz için Ensemble yöntemler, Bagging modeli ile en düşük RMSE değeri olan 2,3061 ve R^2 0,4354), ile 13 özellikli modelde en iyi performansı göstermiştir. Bu da özellik seçiminin doğruluk üzerinde etkili olduğunu göstermektedir. NN-R algoritmasında ise, 2 katmanlı ve sigmoid aktivasyonlu model en iyi sonucu vermiştir (RMSE 2,8375, R^2 0,1737), ancak NN-R modellerinde genel olarak R^2 değerleri düşük kalmıştır. Bu durum, NN-R modellerinin bu veriyi açıklamada sınırlı kaldığını göstermektedir.

Genel olarak, NN-R eğitim verilerindeki kalıpları doğru bir şekilde yakalayabilir, ancak bu kalıpları yeni, görülmemiş verilere uygulayamamaktadır. Bu nedenle, modelin doğrulama setinde değerlendirilmesi sırasında performansı önemli ölçüde düşer. Regresyon tabanlı FIS, eğitim setinde daha az doğru olsa da görülmemiş veriler için daha tutarlı ve güvenilir tahminler sağladığı görülmüştür.



8. TARTIŞMA VE KARAR

Bu çalışmanın ana amacı, kronik hastaların elektrokardiyogram kayıtlarından kalsiyum potasyum ve glükoz seviyelerini otomatik olarak tahmin etmektir. Bu elektrolit seviyelerini hesaplayabilen modeller oluşturmak için elektrokardiyogram sinyallerini içeren alt veri setleri oluşturulmuştur. Geleneksel kan testlerine göre müdahale gerektirmeyen ve potansiyel olarak anında ölçüm yapılabilen bir alternatif yöntem sunulmaktadır. Bu yöntem ile kronik hastaların temel kan parametrelerinin sürekli izlenmesi mümkün hale getirilmesi amaçlanmaktadır.

Bu çalışmada önerilen yöntem, iyonik konsantrasyon değişikliklerinin non-invaziv bir şekilde izlenmesine yönelik önemli bir adım sunmaktadır. Özellikle potasyum ve kalsiyum seviyelerinin tahmini için EKG sinyallerinden zamansal ve frekans tabanlı özelliklerin çıkarılması, daha az invaziv, hızlı ve hasta dostu bir yöntem geliştirilmesine olanak sağlamıştır. Literatürdeki benzer çalışmalarla kıyaslandığında, bu çalışmada önerilen YSA, ensemble yöntemleri ve bulanık mantık sistemlerinin birleştirilmesi, hem doğruluk hem de yorumlanabilirlik açısından avantajlar sunmaktadır (Corsi vd., 2012; Diercks vd., 2004b; Pilia vd., 2017). Bu, hem hiperkalemi hem de hipokalemi riskine sahip bireylerin erken teşhisi ve tedavisi için umut verici bir yaklaşımdır.

Ayrıca, glükoz seviyelerinin EKG sinyallerine dayalı olarak tahmin edilmesi, mevcut literatürde derin öğrenme ve makine öğrenimi modellerinin potansiyelini doğrulayan bir diğer önemli bulgudur (Porumb vd., 2020; Wang vd., 2020; Zanelli vd., 2022). Çalışmada kullanılan zamansal ve frekans tabanlı özelliklerin birleştirilmesi, glükoz seviyelerinin daha doğru tahmin edilmesini sağlamış ve bu durum, diyabet yönetimi için invaziv olmayan bir glikoz izleme çözümünün uygulanabilirliğini desteklemiştir.

Çalışmada kullanılan Ensemble regresyon, regresyon tabanlı FIS ve NN-R kullanılarak modellerin farklı veri setleri için farklı performans seviyelerine sahiptir. Test verilerine göre Ensemble regresyon yöntemlerin başarılı olduğu genel olarak görülmüştür. Ancak doğrulama setlerinde kalsiyum veri setinden beklenen başarı elde edilmemiştir. Bu fark, modellerin geniş bir yelpazede doğru tahminler yapma

yeteneklerini artırmak için geliştirilmesi gerektiğini göstermektedir. Yapay zeka modellerine girdi olarak kullanılan elektrokardiyogram sinyallerinden çıkarılan çok sayıda özellik, iyileştirmenin gerekli olduğunu göstermektedir. Bu çalışma içerisinde, modeli optimize etmek, hesaplama verimliliğini artırmak ve potansiyel olarak performansı iyileştirmek için özellik seçimine öncelik verilmesi gerektiği görülmüştür. En önemli özellikleri vurgulayarak ve gereksiz tekrarları azaltarak sonraki çalışmalar da temel oluşturmuştur.

Model doğruluğu üzerindeki veri setinde aykırı değerlerin etkisi, gelecekteki iyileştirmeler için bir diğer kritik konudur. EKG ölçümleri arasındaki anormallikler veya hastanın öngörülme özelliği, tahmin doğruluğunu etkileyebilmektedir. Modellerin uygulanabilirliğini sağlamak için, bu etkileri azaltma çabaları ana odak noktası olacaktır.

Mevcut araştırmalarda, elektrolit dengesizliklerini teşhis etmek için geleneksel kan testlerinin kullanılması ve EKG gibi biyosinyalleri kullanan invaziv olmayan tekniklerin geliştirilmesi hedeflenmektedir. Bir EKG sinyallerinden morfolojik, frekans ve zaman-frekans özelliklerinin çıkarılması, genel olarak literatürdeki çalışmaların odak konusu olmuştur. Bu çalışma içerisinde, kalsiyum, potasyum ve glukoz seviyelerini tahmin etmenin yanında sınıflandırma modelleri ile anormal durumların tespiti için sınıflandırma performansları da incelenmiştir. Bununla birlikte literatürde, bu teknolojilerin çoğu doğruluk ve sağlamlık açısından iyi bir şekilde değerlendirilmemiştir ve sürekli izleme için invaziv olmayan tekniklerin etkinliği ve uygulanabilirliği konusunda kapsamlı araştırmalar yapılmamıştır.

Bu çalışma ile potasyum kalsiyum ve glukoz seviyelerini izlemek için makine öğrenimi ve elektrokardiyogram kayıtlarının kullanılmasının nasıl uygulanabileceği performans kriterleri ile genelleştirerek diğerlerinden ayrılmaktadır. Ayrıca FIS'in tahmin doğruluğunu artırma potansiyelini de incelemektedir. Metodolojimiz, elektrolit konsantrasyonlarını tahmin etmek için FIS, NN-R ve Ensemble ile EKG sinyallerinden özellik çıkarımını birleştirmiştir. Elbow özellik seçimi işlemi ile en etkili özelliklerin performans değerleri (RMSE ve R^2 korelasyon katsayısı), olumlu bir şekilde artmıştır. Bu çalışma, FIS'in temel elektrolit seviyelerinin sürekli bir şekilde izlenmesi için daha net ve daha etkili bir model sunabileceğini göstererek alana katkıda bulunmaktadır. Bu, mevcut yöntemlerdeki eksiklikleri giderir ve kronik hastalar için evde tanı araçlarının oluşturulmasını desteklemektedir.

Gelecekte çalışmaya arteriyel kan basıncı (ABP) ve fotopletismografi (PPG) gibi diğer fizyolojik sinyaller de dahil edilecektir. Bu verileri birleştirerek modellerin doğruluğunu ve güvenilirliğini artırabilir, böylece hastanın kardiyovasküler durumu ve kan elektrolit seviyeleri arasındaki ilişkiyi daha iyi anlayabiliriz.

Bu araştırma, otomatik olarak, invaziv olmayan tanı yöntemlerinin gelişiminde önemli bir dönüm noktasıdır. Bu çalışmanın sonuçları, özellikle elektrolit seviyelerini düzenli olarak izlemek zorunda olan hastaların yönetimini ve takibini tamamen değiştirebilir. Gelecekteki çalışmalar, daha geniş bir sinyal yelpazesini dahil ederek kullanılan teknikleri genişletecektir. Bu, hasta bakımı ve sağlık hizmetleri sonuçlarını iyileştirmek için daha iyi ve daha güvenilir tahmin modellerinin geliştirilmesine yol açacaktır.



KAYNAKLAR

- American Diabetes Association. (2007). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 30(suppl_1), S42-S47. <https://doi.org/10.2337/dc07-S042>
- American Diabetes Association. (2008). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 31(Supplement_1), S55-S60. <https://doi.org/10.2337/dc08-S055>
- American Diabetes Association. (2009). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 32(Supplement_1), S62-S67. <https://doi.org/10.2337/dc09-S062>
- American Diabetes Association. (2010). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 33(Supplement_1), S62-S69. <https://doi.org/10.2337/dc10-S062>
- American Diabetes Association. (2011). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 34(Supplement_1), S62-S69. <https://doi.org/10.2337/dc11-S062>
- American Diabetes Association. (2012). Diagnosis and Classification of Diabetes Mellitus. *Diabetes Care*, 35(Supplement_1), S64-S71. <https://doi.org/10.2337/dc12-s064>
- Attia, Z., Friedman, P. A., Ladewig, D. J., Satam, G. C., Dugan, J. L., Sepir, Y., Sadot, D., Geva, A., Somers, V. K., Asirvatham, S. J., Ackerman, M. J., Bennet, K. E., Singh, B., & Dillon, J. J. (2018). ECG-based Potassium Measurement is Unaffected by Errors in Blood Potassium Measurement during Hemodialysis. *Journal of Clinical & Experimental Nephrology*, 03(03). <https://doi.org/10.21767/2472-5056.100064>
- Attia, Z. I., DeSimone, C. V., Dillon, J. J., Sapir, Y., Somers, V. K., Dugan, J. L., Bruce, C. J., Ackerman, M. J., Asirvatham, S. J., Striemer, B. L., Bukartyk, J., Scott, C. G., Bennet, K. E., Ladewig, D. J., Gilles, E. J., Sadot, D., Geva, A. B., & Friedman, P. A. (2016). Novel Bloodless Potassium Determination Using a Signal- Processed Single- Lead ECG. *Journal of the American Heart Association*, 5(1), e002746. <https://doi.org/10.1161/JAHA.115.002746>
- Barill, T. (2003). The six second ECG: A practical guidebook to basic ECG interpretation. *Nursecom Educational Technologies*.
- Bocklet, T., Maier, A., Bauer, J. G., Burkhardt, F., & Noth, E. (2008). Age and gender recognition for telephone applications based on GMM supervectors and support vector machines. *2008 IEEE International Conference on Acoustics, Speech and Signal Processing*, 1605-1608. <https://doi.org/10.1109/ICASSP.2008.4517932>

- Bukhari, H. A., Sánchez, C., Ruiz, J. E., Potse, M., Laguna, P., & Pueyo, E. (2022). Monitoring of Serum Potassium and Calcium Levels in End-Stage Renal Disease Patients by ECG Depolarization Morphology Analysis. *Sensors*, 22(8), 2951. <https://doi.org/10.3390/s22082951>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chiu, I.-M., Cheng, C.-Y., Chang, P.-K., Li, C.-J., Cheng, F.-J., & Lin, C.-H. R. (2022a). *One-Class Machine-Learning Model to Screen for Dysglycemia Using Single Lead ECG in ICU, toward Noninvasive Blood Glucose Monitoring*. MATHEMATICS & COMPUTER SCIENCE. <https://doi.org/10.20944/preprints202208.0098.v1>
- Chiu, I.-M., Cheng, C.-Y., Chang, P.-K., Li, C.-J., Cheng, F.-J., & Lin, C.-H. R. (2022b). Utilization of Personalized Machine-Learning to Screen for Dysglycemia from Ambulatory ECG, toward Noninvasive Blood Glucose Monitoring. *Biosensors*, 13(1), 23. <https://doi.org/10.3390/bios13010023>
- Chiu, I.-M., Wu, P.-J., Zhang, H., Hughes, J. W., Rogers, A. J., Jalilian, L., Perez, M., Lin, C.-H. R., Lee, C.-T., Zou, J., & Ouyang, D. (2024). *Serum Potassium Monitoring using AI-enabled Smart Watch Electrocardiograms*. Cardiovascular Medicine. <https://doi.org/10.1101/2024.05.08.24307064>
- Coifman, R. R., & Wickerhauser, M. V. (1992). Entropy-based algorithms for best basis selection. *IEEE Transactions on Information Theory*, 38(2), 713-718. <https://doi.org/10.1109/18.119732>
- Coresh, J., Selvin, E., Stevens, L. A., Manzi, J., Kusek, J. W., Eggers, P., Van Lente, F., & Levey, A. S. (2007). Prevalence of Chronic Kidney Disease in the United States. *JAMA*, 298(17), 2038. <https://doi.org/10.1001/jama.298.17.2038>
- Corsi, C., Cortesi, M., Callisesi, G., De Bie, J., Napolitano, C., Santoro, A., Mortara, D., & Severi, S. (2017). Noninvasive quantification of blood potassium concentration from ECG in hemodialysis patients. *Scientific Reports*, 7(1), 42492. <https://doi.org/10.1038/srep42492>
- Corsi, C., DeBie, J., Napolitano, C., Priori, S., Mortara, D., & Severi, S. (2012). *Validation of a novel method for non-invasive blood potassium quantification from the ECG*. 39, 105-108.
- Diercks, D. B., Shumaik, G. M., Harrigan, R. A., Brady, W. J., & Chan, T. C. (2004a). Electrocardiographic manifestations: Electrolyte abnormalities. *The Journal of Emergency Medicine*, 27(2), 153-160. <https://doi.org/10.1016/j.jemermed.2004.04.006>
- Diercks, D. B., Shumaik, G. M., Harrigan, R. A., Brady, W. J., & Chan, T. C. (2004b). Electrocardiographic manifestations: Electrolyte abnormalities. *The Journal of Emergency Medicine*, 27(2), 153-160. <https://doi.org/10.1016/j.jemermed.2004.04.006>

- Dillon, J. J., DeSimone, C. V., Sapir, Y., Somers, V. K., Dugan, J. L., Bruce, C. J., Ackerman, M. J., Asirvatham, S. J., Striemer, B. L., Bukartyk, J., Scott, C. G., Bennet, K. E., Mikell, S. B., Ladewig, D. J., Gilles, E. J., Geva, A., Sadot, D., & Friedman, P. A. (2015). Noninvasive potassium determination using a mathematically processed ECG: Proof of concept for a novel “blood-less, blood test”. *Journal of Electrocardiology*, 48(1), 12-18. <https://doi.org/10.1016/j.jelectrocard.2014.10.002>
- Du, K., Li, J., Huang, Z., Song, H., Zhang, Y., Zhang, Y., & Mei, Z. (2024). A Non-invasive Blood Glucose Detection System Based on Photoplethysmogram with Multiple Near-infrared Sensors. *IEEE Journal of Biomedical and Health Informatics*, 1-10. <https://doi.org/10.1109/JBHI.2024.3443317>
- Dubosson, F., Ranvier, J.-E., Bromuri, S., Calbimonte, J.-P., Ruiz, J., & Schumacher, M. (2018). The open D1NAMO dataset: A multi-modal dataset for research on non-invasive type 1 diabetes management. *Informatics in Medicine Unlocked*, 13, 92-100. <https://doi.org/10.1016/j.imu.2018.09.003>
- Duffy, N., & Helmbold, D. (2002). [No title found]. *Machine Learning*, 47(2/3), 153-200. <https://doi.org/10.1023/A:1013685603443>
- Dylewski, J. F., & Linas, S. (2018). Variability of Potassium Blood Testing: Imprecise Nature of Blood Testing or Normal Physiologic Changes? *Mayo Clinic Proceedings*, 93(5), 551-554. <https://doi.org/10.1016/j.mayocp.2018.03.019>
- Evans, K. J., & Greenberg, A. (2005). Hyperkalemia: A Review. *Journal of Intensive Care Medicine*, 20(5), 272-290. <https://doi.org/10.1177/0885066605278969>
- Fellah Arbi, K., Soulimane, S., Saffih, F., & Bechar, M. A. (2022). Non-Invasive Method for Blood Glucose Monitoring Using ECG Signal. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4068462>
- Fisch, C. (1973). Relation of Electrolyte Disturbances to Cardiac Arrhythmias. *Circulation*, 47(2), 408-419. <https://doi.org/10.1161/01.CIR.47.2.408>
- Fleiss, J. L., & Cohen, J. (1973). The Equivalence of Weighted Kappa and the Intraclass Correlation Coefficient as Measures of Reliability. *Educational and Psychological Measurement*, 33(3), 613-619. <https://doi.org/10.1177/001316447303300309>
- Frohnert, P. P., Gluliani, E. R., Friedberg, M., Johnson, W. J., & Tauxe, W. N. (1970). Statistical Investigation of Correlations Between Serum Potassium Levels and Electrocardiographic Findings in Patients on Intermittent Hemodialysis Therapy. *Circulation*, 41(4), 667-676. <https://doi.org/10.1161/01.CIR.41.4.667>
- Gavala, A., & Myrianthefs, P. (2017). Comparison of point-of-care versus central laboratory measurement of hematocrit, hemoglobin, and electrolyte concentrations. *Heart & Lung*, 46(4), 246-250. <https://doi.org/10.1016/j.hrtlng.2017.04.003>
- Gong, Z., Tang, Z., Qin, Z., Su, X., & Choi, C. (2024). Electrocardiogram identification based on data generative network and non-fiducial data processing. *Computers in Biology and Medicine*, 173, 108333. <https://doi.org/10.1016/j.combiomed.2024.108333>

- Guo, H., Wu, H., & Li, Z. (2023). The Pathogenesis of Diabetes. *International Journal of Molecular Sciences*, 24(8), 6978. <https://doi.org/10.3390/ijms24086978>
- Gusev, M., Poposka, L., Spasevski, G., Kostoska, M., Koteska, B., Simjanoska, M., Ackovska, N., Stojmenski, A., Tasic, J., & Trontelj, J. (2020). Noninvasive Glucose Measurement Using Machine Learning and Neural Network Methods and Correlation with Heart Rate Variability. *Journal of Sensors*, 2020, 1-13. <https://doi.org/10.1155/2020/9628281>
- Halperin, M. L., & Kamel, K. S. (1998). Potassium. *The Lancet*, 352(9122), 135-140. [https://doi.org/10.1016/S0140-6736\(98\)85044-7](https://doi.org/10.1016/S0140-6736(98)85044-7)
- Hernández Mesa, M., Pilia, N., Dössel, O., & Loewe, A. (2019). Influence of ECG Lead Reduction Techniques for Extracellular Potassium and Calcium Concentration Estimation. *Current Directions in Biomedical Engineering*, 5(1), 69-72. <https://doi.org/10.1515/cdbme-2019-0018>
- Hernández Mesa, M., Pilia, N., Dössel, O., Severi, S., & Loewe, A. (2018). Effects of Serum Calcium Changes on the Cardiac Action Potential and the ECG in a Computational Model. *Current Directions in Biomedical Engineering*, 4(1), 251-254. <https://doi.org/10.1515/cdbme-2018-0061>
- Hill, N. R., Fatoba, S. T., Oke, J. L., Hirst, J. A., O'Callaghan, C. A., Lasserson, D. S., & Hobbs, F. D. R. (2016). Global Prevalence of Chronic Kidney Disease – A Systematic Review and Meta-Analysis. *PLOS ONE*, 11(7), e0158765. <https://doi.org/10.1371/journal.pone.0158765>
- Huang, N. E., & Shen, S. S. P. (2014). *Hilbert–Huang Transform and Its Applications* (2. bs, C. 16). WORLD SCIENTIFIC. <https://doi.org/10.1142/8804>
- Huang, N. E., Wu, Z., Long, S. R., Arnold, K. C., Chen, X., & Blank, K. (2009). ON INSTANTANEOUS FREQUENCY. *Advances in Adaptive Data Analysis*, 01(02), 177-229. <https://doi.org/10.1142/S1793536909000096>
- Jha, V., Garcia-Garcia, G., Iseki, K., Li, Z., Naicker, S., Plattner, B., Saran, R., Wang, A. Y.-M., & Yang, C.-W. (2013). Chronic kidney disease: Global dimension and perspectives. *Lancet (London, England)*, 382(9888), 260-272. [https://doi.org/10.1016/S0140-6736\(13\)60687-X](https://doi.org/10.1016/S0140-6736(13)60687-X)
- Johnson, A. E. W., Pollard, T. J., Shen, L., Lehman, L. H., Feng, M., Ghassemi, M., Moody, B., Szolovits, P., Anthony Celi, L., & Mark, R. G. (2016). MIMIC-III, a freely accessible critical care database. *Scientific Data*, 3(1), 160035. <https://doi.org/10.1038/sdata.2016.35>
- Katsarou, A., Gudbjörnsdottir, S., Rawshani, A., Dabelea, D., Bonifacio, E., Anderson, B. J., Jacobsen, L. M., Schatz, D. A., & Lernmark, Å. (2017). Type 1 diabetes mellitus. *Nature Reviews Disease Primers*, 3(1), 17016. <https://doi.org/10.1038/nrdp.2017.16>
- Lenis, G., Pilia, N., Loewe, A., Schulze, W. H. W., & Dössel, O. (2017). Comparison of Baseline Wander Removal Techniques considering the Preservation of ST Changes in the Ischemic ECG: A Simulation Study. *Computational and Mathematical Methods in Medicine*, 2017, 1-13. <https://doi.org/10.1155/2017/9295029>

- Lenis, G., Pilia, N., Oesterlein, T., Luik, A., Schmitt, C., & Dössel, O. (2016). P wave detection and delineation in the ECG based on the phase free stationary wavelet transform and using intracardiac atrial electrograms as reference. *Biomedical Engineering / Biomedizinische Technik*, 61(1), 37-56. <https://doi.org/10.1515/bmt-2014-0161>
- Levey, A. S., Coresh, J., Balk, E., Kausz, A. T., Levin, A., Steffes, M. W., Hogg, R. J., Perrone, R. D., Lau, J., & Eknoyan, G. (2003). National Kidney Foundation Practice Guidelines for Chronic Kidney Disease: Evaluation, Classification, and Stratification. *Annals of Internal Medicine*, 139(2), 137. <https://doi.org/10.7326/0003-4819-139-2-200307150-00013>
- Levey, A. S., Eckardt, K.-U., Tsukamoto, Y., Levin, A., Coresh, J., Rossert, J., Zeeuw, D. D. E., Hostetter, T. H., Lameire, N., & Eknoyan, G. (2005). Definition and classification of chronic kidney disease: A position statement from Kidney Disease: Improving Global Outcomes (KDIGO). *Kidney International*, 67(6), 2089-2100. <https://doi.org/10.1111/j.1523-1755.2005.00365.x>
- Li, J., Ma, J., Omisore, O. M., Liu, Y., Tang, H., Ao, P., Yan, Y., Wang, L., & Nie, Z. (2023). Noninvasive Blood Glucose Monitoring Using Spatiotemporal ECG and PPG Feature Fusion and Weight-Based Choquet Integral Multimodel Approach. *IEEE Transactions on Neural Networks and Learning Systems*, 1-15. <https://doi.org/10.1109/TNNLS.2023.3279383>
- Li, J., Tobore, I., Liu, Y., Kandwal, A., Wang, L., & Nie, Z. (2021). Non-invasive Monitoring of Three Glucose Ranges Based On ECG By Using DBSCAN-CNN. *IEEE Journal of Biomedical and Health Informatics*, 25(9), 3340-3350. <https://doi.org/10.1109/JBHI.2021.3072628>
- Lin, C.-S., Lee, Y.-T., Fang, W.-H., Lou, Y.-S., Kuo, F.-C., Lee, C.-C., & Lin, C. (2021). Deep Learning Algorithm for Management of Diabetes Mellitus via Electrocardiogram-Based Glycated Hemoglobin (ECG-HbA1c): A Retrospective Cohort Study. *Journal of Personalized Medicine*, 11(8), 725. <https://doi.org/10.3390/jpm11080725>
- Lin, C.-S., Lin, C., Fang, W.-H., Hsu, C.-J., Chen, S.-J., Huang, K.-H., Lin, W.-S., Tsai, C.-S., Kuo, C.-C., Chau, T., Yang, S. J., & Lin, S.-H. (2020). A Deep-Learning Algorithm (ECG12Net) for Detecting Hypokalemia and Hyperkalemia by Electrocardiography: Algorithm Development. *JMIR Medical Informatics*, 8(3), e15931. <https://doi.org/10.2196/15931>
- Lin, Y., Tsai, H., Li, C., Chen, C., Liu, C., & Lee, W. (2023). Estimation of Blood Glucose Level of Human by Measuring Key Parameters in Electrocardiogram. *2023 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 01-06. <https://doi.org/10.1109/I2MTC53148.2023.10175995>
- Liu, M., Xu, C., Luo, Y., Xu, C., Wen, Y., & Tao, D. (2018). Cost-Sensitive Feature Selection by Optimizing F-Measures. *IEEE Transactions on Image Processing*, 27(3), 1323-1335. <https://doi.org/10.1109/TIP.2017.2781298>
- Luz, E. J. D. S., Schwartz, W. R., Cámara-Chávez, G., & Menotti, D. (2016). ECG-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine*, 127, 144-164. <https://doi.org/10.1016/j.cmpb.2015.12.008>

- Mammone, A., Turchi, M., & Cristianini, N. (2009). Support vector machines. *WIREs Computational Statistics*, 1(3), 283-289. <https://doi.org/10.1002/wics.49>
- Marcus, Y., Eldor, R., Yaron, M., Shaklai, S., Ish- Shalom, M., Shefer, G., Stern, N., Golan, N., Dvir, A. Z., Pele, O., & Gonen, M. (2020). Improving blood glucose level predictability using machine learning. *Diabetes/Metabolism Research and Reviews*, 36(8), e3348. <https://doi.org/10.1002/dmrr.3348>
- McIntosh, B. W., Vasek, J., Taylor, M., Le Blanc, D., Thode, H. C., & Singer, A. J. (2018). Accuracy of bedside point of care testing in critical emergency department patients. *The American Journal of Emergency Medicine*, 36(4), 567-570. <https://doi.org/10.1016/j.ajem.2017.09.018>
- Metze, F., Ajmera, J., Englert, R., Bub, U., Burkhardt, F., Stegmann, J., Muller, C., Huber, R., Andrassy, B., Bauer, J. G., & Littel, B. (2007). Comparison of Four Approaches to Age and Gender Recognition for Telephone Applications. *2007 IEEE International Conference on Acoustics, Speech and Signal Processing - ICASSP '07*, IV-1089-IV-1092. <https://doi.org/10.1109/ICASSP.2007.367263>
- Moghaddamnia, S., Peissig, J., Schmitz, G., & Effenberg, A. O. (2013). A simplified approach for autonomous quality assessment of cyclic movements. *2013 18th International Conference on Digital Signal Processing (DSP)*, 1-5. <https://doi.org/10.1109/ICDSP.2013.6622672>
- Mondal, H., Biri, S. K., Pipil, N., & Mondal, S. (2024). Accuracy of a Non-Invasive Home Glucose Monitor for Measurement of Blood Glucose. *Indian Journal of Endocrinology and Metabolism*, 28(1), 60-64. https://doi.org/10.4103/ijem.ijem_36_23
- Opitz, D., & Maclin, R. (1999). Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, 11, 169-198. <https://doi.org/10.1613/jair.614>
- Pearson, E. R. (2019). Type 2 diabetes: A multifaceted disease. *Diabetologia*, 62(7), 1107-1112. <https://doi.org/10.1007/s00125-019-4909-y>
- Periz, L. A., & Sanmartín, E. (1997). *500 cuestiones que plantea el cuidado del enfermo renal*. <https://www.semanticscholar.org/paper/500-cuestiones-que-plantea-el-cuidado-del-enfermo-Periz-Sanmart%C3%ADn/4c8a769b2df5c7f5995b29069bb2269578425421>
- Perotte, A., Ranganath, R., Hirsch, J. S., Blei, D., & Elhadad, N. (2015). Risk prediction for chronic kidney disease progression using heterogeneous electronic health record data and time series analysis. *Journal of the American Medical Informatics Association*, 22(4), 872-880. <https://doi.org/10.1093/jamia/ocv024>
- Peterson, L. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883. <https://doi.org/10.4249/scholarpedia.1883>
- Pilia, N., Doessel, O., Lenis, G., & Loewe, A. (2017, Eylül 14). *ECG as a Tool to Estimate Potassium and Calcium Concentrations in the Extracellular Space*. *2017 Computing in Cardiology Conference*. <https://doi.org/10.22489/CinC.2017.265-080>

- Pilia, N., Mesa, M. H., Dossel, O., & Loewe, A. (2019). ECG-based Estimation of Potassium and Calcium Concentrations: Proof of Concept with Simulated Data. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2610-2613. <https://doi.org/10.1109/EMBC.2019.8857634>
- Pilia, N., Nagel, C., Lenis, G., Becker, S., Dössel, O., & Loewe, A. (2021). ECGdeli—An open source ECG delineation toolbox for MATLAB. *SoftwareX*, 13, 100639. <https://doi.org/10.1016/j.softx.2020.100639>
- Pilia, N., Severi, S., Raimann, J. G., Genovesi, S., Dössel, O., Kotanko, P., Corsi, C., & Loewe, A. (2020). Quantification and classification of potassium and calcium disorders with the electrocardiogram: What do clinical studies, modeling, and reconstruction tell us? *APL Bioengineering*, 4(4), 041501. <https://doi.org/10.1063/5.0018504>
- Porumb, M., Stranges, S., Pescapè, A., & Pecchia, L. (2020). Precision Medicine and Artificial Intelligence: A Pilot Study on Deep Learning for Hypoglycemic Events Detection based on ECG. *Scientific Reports*, 10(1), 170. <https://doi.org/10.1038/s41598-019-56927-5>
- Priori, S. G., Blomström-Lundqvist, C., Mazzanti, A., Blom, N., Borggrefe, M., Camm, J., Elliott, P. M., Fitzsimons, D., Hatala, R., Hindricks, G., Kirchhof, P., Kjeldsen, K., Kuck, K.-H., Hernandez-Madrid, A., Nikolaou, N., Norekvål, T. M., Spaulding, C., & Van Veldhuisen, D. J. (2015). 2015 ESC Guidelines for the management of patients with ventricular arrhythmias and the prevention of sudden cardiac death: The Task Force for the Management of Patients with Ventricular Arrhythmias and the Prevention of Sudden Cardiac Death of the European Society of Cardiology (ESC) Endorsed by: Association for European Paediatric and Congenital Cardiology (AEPC). *European Heart Journal*, 36(41), 2793-2867. <https://doi.org/10.1093/eurheartj/ehv316>
- Romagnani, P., Remuzzi, G., Glassock, R., Levin, A., Jager, K. J., Tonelli, M., Massy, Z., Wanner, C., & Anders, H.-J. (2017). Chronic kidney disease. *Nature Reviews Disease Primers*, 3(1), 17088. <https://doi.org/10.1038/nrdp.2017.88>
- Sánchez, J. L. C., Camarero, A. R. A., Pérez, M. C., Sota, M. M. Á., Llamazares, C. V., Roldán, C. H., Viadero, R. M., & Nates, R. A. (2007). HYPERKALAEMIA AND HAEMODIALYSIS PATIENTS: ELECTROCARDIOGRAPHIC CHANGES. *Journal of Renal Care*, 33(3), 124-129. <https://doi.org/10.1111/j.1755-6686.2007.tb00057.x>
- Sarnak, M. J., Levey, A. S., Schoolwerth, A. C., Coresh, J., Culleton, B., Hamm, L. L., McCullough, P. A., Kasiske, B. L., Kelepouris, E., Klag, M. J., Parfrey, P., Pfeffer, M., Raij, L., Spinosa, D. J., & Wilson, P. W. (2003). Kidney Disease as a Risk Factor for Development of Cardiovascular Disease: A Statement From the American Heart Association Councils on Kidney in Cardiovascular Disease, High Blood Pressure Research, Clinical Cardiology, and Epidemiology and Prevention. *Circulation*, 108(17), 2154-2169. <https://doi.org/10.1161/01.CIR.0000095676.90936.80>
- Schaefer, T. J., & Wolford, R. W. (2005). Disorders of Potassium. *Emergency Medicine Clinics of North America*, 23(3), 723-747. <https://doi.org/10.1016/j.emc.2005.03.016>

- Slovic, C. (2002). ABC of clinical electrocardiography: Conditions not primarily affecting the heart. *BMJ*, 324(7349), 1320-1323. <https://doi.org/10.1136/bmj.324.7349.1320>
- Sörnmo, L., & Laguna, P. (2005). *Bioelectrical signal processing in cardiac and neurological applications*. Elsevier Academic Press.
- Ståhle, L., & Wold, S. (1989). Analysis of variance (ANOVA). *Chemometrics and Intelligent Laboratory Systems*, 6(4), 259-272. [https://doi.org/10.1016/0169-7439\(89\)80095-4](https://doi.org/10.1016/0169-7439(89)80095-4)
- Szerlip, H. M., Weiss, J., & Singer, I. (1986). Profound Hyperkalemia Without Electrocardiographic Manifestations. *American Journal of Kidney Diseases*, 7(6), 461-465. [https://doi.org/10.1016/S0272-6386\(86\)80185-8](https://doi.org/10.1016/S0272-6386(86)80185-8)
- Tibshirani, R., Walther, G., & Hastie, T. (2001). Estimating the Number of Clusters in a Data Set Via the Gap Statistic. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 63(2), 411-423. <https://doi.org/10.1111/1467-9868.00293>
- Van Mieghem, C., Sabbe, M., & Knockaert, D. (2004). The Clinical Value of the ECG in Noncardiac Conditions. *Chest*, 125(4), 1561-1576. <https://doi.org/10.1378/chest.125.4.1561>
- Walczak, S., & Cerpa, N. (1999). Heuristic principles for the design of artificial neural networks. *Information and Software Technology*, 41(2), 107-117. [https://doi.org/10.1016/S0950-5849\(98\)00116-5](https://doi.org/10.1016/S0950-5849(98)00116-5)
- Wang, L., Mu, Y., Zhao, J., Wang, X., & Che, H. (2020). IGRNet: A Deep Learning Model for Non-Invasive, Real-Time Diagnosis of Prediabetes through Electrocardiograms. *Sensors*, 20(9), 2556. <https://doi.org/10.3390/s20092556>
- Webster, A. (2002). Recognising signs of danger: ECG changes resulting from an abnormal serum potassium concentration. *Emergency Medicine Journal*, 19(1), 74-77. <https://doi.org/10.1136/emj.19.1.74>
- Webster, A. C., Nagler, E. V., Morton, R. L., & Masson, P. (2017). Chronic Kidney Disease. *The Lancet*, 389(10075), 1238-1252. [https://doi.org/10.1016/S0140-6736\(16\)32064-5](https://doi.org/10.1016/S0140-6736(16)32064-5)
- Wiktorowicz, K. (2023). T2RFIS: Type-2 regression-based fuzzy inference system. *Neural Computing and Applications*, 35(27), 20299-20317. <https://doi.org/10.1007/s00521-023-08811-7>
- Yasin, O. Z., Attia, Z., Dillon, J. J., DeSimone, C. V., Sapir, Y., Dugan, J., Somers, V. K., Ackerman, M. J., Asirvatham, S. J., Scott, C. G., Bennet, K. E., Ladewig, D. J., Sadot, D., Geva, A. B., & Friedman, P. A. (2017). Noninvasive blood potassium measurement using signal-processed, single-lead ecg acquired from a handheld smartphone. *Journal of Electrocardiology*, 50(5), 620-625. <https://doi.org/10.1016/j.jelectrocard.2017.06.008>
- Zanelli, S., Ammi, M., Hallab, M., & El Yacoubi, M. A. (2022). Diabetes Detection and Management through Photoplethysmographic and Electrocardiographic Signals Analysis: A Systematic Review. *Sensors*, 22(13), 4890. <https://doi.org/10.3390/s22134890>
- Zelenkov, Y. (2023). Optimization of the Regression Ensemble Size. *Informatics and Automation*, 22(2), 393-415. <https://doi.org/10.15622/ia.22.2.6>

ÖZGEÇMİŞ

Ad-Soyad : Sebahattin BABUR

ÖĞRENİM DURUMU:

- **Lisans** : 2011, Marmara Üniversitesi, Teknik Eğitim Fakültesi, Elektronik ve Haberleşme Öğretmenliği
- **Lisans** : 2016, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği
- **Yüksek lisans** : 2016, Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği

MESLEKİ DENEYİM:

- 2013-2014 Teknik Satış Mühendisliği, Beckhoff Otomasyon Ltd.Şti.
- 2015-2019 Öğretim Görevlisi, İstanbul Gedik Üniversitesi, Meslek Yükseokulu
- 2019-2023 Öğretim Görevlisi, Türk-Alman Üniversitesi
- 2021-2023 TÜBİTAK 1512 desteği üzerinden Start-Up firma kuruldu. SAMINSIGHT Yazılım ve Tic. Ltd.Şti.
- 2023-Devam Yapay Zeka ve Makine Öğrenmesi Takım Lideri, Figes Mühendislik A.Ş.

TEZDEN TÜRETİLEN ESERLER:

- Babur, S., Moghaddamnia, S., Bozkurt, M.R. (2021). A Machine Learning Approach to Predict the Sepsis Status: Analyzing the Connection Between Relevant Laboratory Values and Other Physiological Measurements Obtained in Intensive Care Unit. In: Badnjevic, A., Gurbeta Pokvić, L. (eds) CMBEBIH 2021. CMBEBIH 2021. IFMBE Proceedings, vol 84. Springer, Cham. https://doi.org/10.1007/978-3-030-73909-6_19
- Babur, S., Moghaddamnia, S. & Bozkurt, M.R. Estimation of Blood Calcium and Potassium Values from ECG Records. Measurement Science Review, 2024, Slovak Academy of Sciences, vol. 24 no. 5, pp. 158-173. <https://doi.org/10.2478/msr-2024-0022>