

**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKÂ TABANLI ELEKTROKARDİYOGRAFI SİNYALİ  
İLE KAN BASINCI TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Derya KANDAZ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Elektronik Mühendisliği Bilim Dalı**

**OCAK 2023**



**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKÂ TABANLI ELEKTROKARDİYOGRAFİ SİNYALİ  
İLE KAN BASINCI TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Derya KANDAZ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Elektronik Mühendisliği Bilim Dalı**

**Tez Danışmanı: Doç. Dr. Muhammed Kürşad UÇAR**

**OCAK 2023**



Derya KANDAZ tarafından hazırlanan ‘‘Elektrokardiyografi Sinyali İle Yapay Zekâ Tabanlı Kan Basıncı Tespiti’’ adlı tez çalışması 16.01.2023 tarihinde ařağıdaki jüri tarafından oy birliğı/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliğı Anabilim Dalı **Elektronik Mühendisliğı** Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

### Tez Jürisi

**Jüri Başkanı:** **Prof. Dr. Mehmet Recep BOZKURT** .....  
Sakarya Üniversitesi

**Jüri Üyesi:** **Doç.Dr. Muhammed Kürşad UÇAR** (Danışman) .....  
Sakarya Üniversitesi

**Jüri Üyesi:** **Prof. Dr. İhsan PEHLİVAN** .....  
Sakarya Uygulamalı Bilimler Üniversitesi



## **ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ**

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “YAPAY ZEKÂ TABANLI ELEKTROKARDİYOĞRAFİ SİNYALİ İLE KAN BASINCI TESPİTİ” 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. (...../...../2023).

(imza)

Derya KANDAZ





*Türkiye Cumhuriyeti Şehitlerine*



## **TEŐEKKÜR**

Tez konusunun belirlenmesinde, gerekli alıŐma Őartlarının saęlanmasında ve alıŐmalarımın her adımında bana desteęini esirgemeyen danıŐman hocam Sayın Do. Dr. Muhammed KőrŐad UAR'a ve tım hayatım boyunca gerek maddi gerek manevi olarak yanımda olan anneme, babama ve ablalarımaya teŐekkürlerimi sunarım.

Tez alıŐmamı Bilimsel AraŐtırma Projeleri-Lisansüstü Tez Projeleri (LÜTEP) kapsamında destekleyen Sakarya Üniversitesi'ne teŐekkür ederim.

alıŐmamızın gelecekte yapılacak araŐtırmalara ışık tutmasını temenni ederim.

*Derya KANDAZ*



## İÇİNDEKİLER

### Sayfa

<b>ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ</b> .....	<b>v</b>
<b>TEŞEKKÜR</b> .....	<b>ix</b>
<b>İÇİNDEKİLER</b> .....	<b>xi</b>
<b>KISALTMALAR</b> .....	<b>xiii</b>
<b>SİMGELER</b> .....	<b>xv</b>
<b>TABLO LİSTESİ</b> .....	<b>xvii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>xix</b>
<b>ÖZET</b> .....	<b>xxi</b>
<b>SUMMARY</b> .....	<b>xxv</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Amaç ve Kapsam .....	1
1.2. Literatür Araştırması .....	7
1.3. Hedef ve Katkıları .....	9
<b>2. ELEKTROKARDİYOĞRAFI İŞARETLERİ VE İNCELENMESİ</b> .....	<b>11</b>
2.1. Kalp .....	11
2.2. Kardiyak Döngü (Kalp Siklusü).....	12
2.2.1. Ventriküler sistol.....	12
2.2.2. Ventriküler diastol.....	14
2.3. Elektrokardiyogram.....	15
2.4. Kalbin İletim Sistemi ve Elektrokardiyografi İşareti .....	15
2.4.1. Kardiyak aksiyon potansiyeli .....	17
2.5. Elektrokardiyografi İşaretinin Ölçülmesinin Temelleri .....	18
2.6. Elektrokardiyografi İşaretinin Morfolojisi ve Değerlendirilmesi .....	21
<b>3. KAN BASINCI ÖLÇÜMÜNÜN ÖNEMİ VE İNCELENMESİ</b> .....	<b>23</b>
3.1. Kan Basıncı .....	23
3.2. Hipertansiyon ve Hipotansiyon Tanıları .....	24
3.3. Kan Basıncının Düzenlenmesi .....	25
3.3.1. Renin anjiyotensin aldesteron sistemi (RAAS) .....	26
3.4. Kan Basıncı Ölçüm Teknikleri.....	27
3.4.1. Direkt ölçüm teknikleri .....	27
3.4.2. İndirekt ölçüm teknikleri.....	27
3.5. Kan Basıncı Ölçüm Cihazları.....	28
<b>4. ELEKTROKARDİYOĞRAFI İLE KAN BASINCI TESPİT MODELİNİN GELİŞTİRİLMESİ</b> .....	<b>31</b>
4.1. Verilerin Toplanması.....	32
4.2. Elektrokardiyografi Sinyallerinin Önışlemesi.....	32
4.3. Elektrokardiyografi Sinyallerinin Segmentasyonu/Epoklanması .....	33
4.4. Elektrokardiyografi Sinyalinin Filtrelenmesi: Alt Frekans Bantlarına Ayrılması .....	34
4.5. Özellik Çıkarımı.....	38
4.6. Özellik Seçimi .....	40

4.6.1. Spearman korelasyon katsayı algoritması .....	40
<b>5. YAPAY ZEKÂ ALGORİTMALARI ve PERFORMANS DEĞERLENDİRME KRİTERLERİ .....</b>	<b>47</b>
5.1. Yapay Zekâ Algoritmaları .....	47
5.2. Topluluk karar ağacı algoritması: sistolik ve diyastolik kan basıncı tahmini .	49
5.3. Karar ağacı: sistolik ve diyastolik kan basıncı tahmini .....	51
5.4. Gauss süreç regresyonu: sistolik ve diyastolik kan basıncı tahmini.....	52
5.5. Doğrulama Teknikleri: Hold-out Doğrulama .....	53
5.6. Performans Değerlendirme Kriterleri .....	54
<b>6. SONUÇLAR .....</b>	<b>57</b>
6.1. Diyastolik ve Sistolik Kan Basıncı Minimum Süre Tespiti Modeline Dayalı Sonuçlar .....	57
6.2. Elektrokardiyografi Alt Frekans Bantları Ayrımına Dayalı Diyastolik ve Sistolik Kan Basıncı Tahmin Sonuçları .....	81
<b>7. TARTIŞMA VE KARAR .....</b>	<b>105</b>
7.1. Tartışma .....	105
7.2. Güçlü Yönler ve Sınırlamalar .....	110
7.3. Karar .....	110
7.4. Gelecek Çalışmalar .....	111
<b>KAYNAKLAR.....</b>	<b>113</b>
<b>ÖZGEÇMİŞ.....</b>	<b>123</b>

## KISALTMALAR

<b>AAMI</b>	: Medikal Enstrümantasyon Gelişimi Derneği
<b>ACE-ADE</b>	: Anjiyotensin dönüştürücü enzim
<b>AEM</b>	: Akustik emisyon metodu
<b>ARTSENS</b>	: Arteriyel sertlik değerlendirmesi
<b>AV</b>	: Atriyoventriküler
<b>CART</b>	: Sınıflandırma ve regresyon ağaçları
<b>CL</b>	: Ortalama eğri uzunluğu
<b>CM</b>	: Merkezi moment
<b>D</b>	: Düzey
<b>DK</b>	: Değişim katsayısı
<b>DKB</b>	: Diyastolik kan basıncı
<b>DSÖ</b>	: Dünya Sağlık Örgütü
<b>ES</b>	: Epok süresi
<b>EKG</b>	: Elektrokardiyografi
<b>EMD</b>	: Ampirik mod ayrıştırma
<b>GSR</b>	: Gauss süreç regresyonu
<b>IoT</b>	: Nesnelerin interneti
<b>ISO</b>	: Uluslararası Standardizasyon Kuruluşu (The International Organization for Standardization)
<b>IQR</b>	: Çeyrekler arası genişlik (Interquartile Range)
<b>KA</b>	: Karar ağacı
<b>KB</b>	: Kan basıncı
<b>KOKH</b>	: Kök ortalama karesel hata
<b>Maks</b>	: Maksimum
<b>MIV</b>	: Ortalama etki değeri (mean impact value)
<b>Min</b>	: Minimum
<b>OKH</b>	: Ortalama karekök hatası
<b>OMH</b>	: Ortalama mutlak hata
<b>OMYH</b>	: Ortalama mutlak yüzde hatası
<b>ÖS</b>	: Özellik sayısı
<b>ÖY</b>	: Özellik yüzdesi

<b>PPG</b>	: Fotopletismografi
<b>RAAS</b>	: Renin-anjiotensin aldosteron sistemi
<b>SA</b>	: Sinoatriyel
<b>SF</b>	: Şekil faktörü
<b>SH</b>	: Standart hata
<b>SKB</b>	: Sistolik kan basıncı
<b>SNS</b>	: Sempatik sinir sistemi
<b>SVD</b>	: Tekil değer ayrışımı (Singular value decomposition)
<b>SVM</b>	: Destek vektör makineleri (Support vector machine)
<b>TKA</b>	: Topluluk karar ağacı algoritması



## SİMGELER

<b>A</b>	: Hjort parametresi- Aktivite
<b>C</b>	: Hjort parametresi- Karmaşıklık
<b>mmHg</b>	: Basınç birimi ( $1 \text{ Pa} = 7.5006 \times 10^{-3} \text{ mmHg}$ )
<b>E</b>	: Enerji
<b>F<sub>s</sub></b>	: Örnekleme frekansı
<b>G</b>	: Geometrik ortalama
<b>Hz</b>	: Hertz
<b>M</b>	: Hjort parametresi- Hareketlilik
<b>n</b>	: Veri adedi
<b>d<sub>i</sub></b>	: i'ninci veri için parametre sayısı
<b>Pa</b>	: Basınç birimi ( $1 \text{ Pa} = 7.5006 \times 10^{-3} \text{ mmHg}$ )
<b>r<sub>s</sub></b>	: Spearman korelasyon katsayısı
<b>R</b>	: Korelasyon katsayısı
<b>R<sup>2</sup></b>	: Korelasyon katsayısının karesi
<b>s</b>	: Saniye
<b>S</b>	: Standart sapma
<b>t<sub>i</sub></b>	: Tahmin edilen değişken
<b>T</b>	: Periyot sayısı
<b>T25</b>	: %25 kırılmış ortalama
<b>T50</b>	: %50 kırılmış ortalama
<b>TE</b>	: Ortalama teager enerjisi
<b>y<sub>i</sub></b>	: Gerçek değer



## TABLO LİSTESİ

### Sayfa

<b>Tablo 3.1.</b> Kan basıncı sınıfları [84].....	24
<b>Tablo 4.1.</b> QRS bant aralıkları.....	38
<b>Tablo 4.2.</b> Özellikler ait denklemler.....	39
<b>Tablo 4.3.</b> Her bir saniyeye ait özellik setleri için korelasyon düzeyi değerleri. ....	42
<b>Tablo 4.4.</b> Her bir frekans bantındaki EKG kaydı için korelasyon düzeyi değerleri.	43
<b>Tablo 4.5.</b> Minimum sürede DKB tespit modeline dayalı özelliklerin korelasyon düzeyi sıralaması değerleri.....	44
<b>Tablo 4.6.</b> Minimum sürede SKB tespit modeline dayalı özelliklerinin korelasyon düzeyi sıralaması değerleri.....	45
<b>Tablo 5.1.</b> Eğitim ve test veri seti dağılımı. ....	54
<b>Tablo 6.1.</b> 2-saniyelik epok için DKB tahmin sonuçları. ....	60
<b>Tablo 6.2.</b> 4-saniyelik epok için DKB tahmin sonuçları. ....	61
<b>Tablo 6.3.</b> 6-saniyelik epok için DKB tahmin sonuçları.....	62
<b>Tablo 6.4.</b> 8-saniyelik epok için DKB tahmin sonuçları.....	63
<b>Tablo 6.5.</b> 10-saniyelik epok için DKB tahmin sonuçları. ....	64
<b>Tablo 6.6.</b> 12-saniyelik epok için DKB tahmin sonuçları. ....	65
<b>Tablo 6.7.</b> 14-saniyelik epok için DKB tahmin sonuçları. ....	66
<b>Tablo 6.8.</b> 16-saniyelik epok için DKB tahmin sonuçları. ....	67
<b>Tablo 6.9.</b> 18-saniyelik epok için DKB tahmin sonuçları. ....	68
<b>Tablo 6.10.</b> 20-saniyelik epok için DKB tahmin sonuçları. ....	69
<b>Tablo 6.11.</b> 2-saniyelik epok için SKB tahmin sonuçları.....	70
<b>Tablo 6.12.</b> 4-saniyelik epok için SKB tahmin sonuçları.....	71
<b>Tablo 6.13.</b> 6-saniyelik epok için SKB tahmin sonuçları.....	72
<b>Tablo 6.14.</b> 8-saniyelik epok için SKB tahmin sonuçları.....	73
<b>Tablo 6.15.</b> 10-saniyelik epok için SKB tahmin sonuçları.....	74
<b>Tablo 6.16.</b> 12-saniyelik epok için SKB tahmin sonuçları.....	75
<b>Tablo 6.17.</b> 14-saniyelik epok için SKB tahmin sonuçları.....	76
<b>Tablo 6.18.</b> 16-saniyelik epok için SKB tahmin sonuçları.....	77
<b>Tablo 6.19.</b> 18-saniyelik epok için SKB tahmin sonuçları.....	78
<b>Tablo 6.20.</b> 20-saniyelik epok için SKB tahmin sonuçları.....	79
<b>Tablo 6.21.</b> En iyi sonuç veren sürelerle dair SKB ve DKB tahmin sonuçları. ....	80
<b>Tablo 6.22.</b> Ham EKG sinyalleri için SKB sonuçları. ....	85
<b>Tablo 6.23.</b> Üst örneklenmiş EKG sinyalleri için SKB sonuçları. ....	86
<b>Tablo 6.24.</b> QRS1 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	87
<b>Tablo 6.25.</b> QRS2 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	88
<b>Tablo 6.26.</b> QRS3 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	89
<b>Tablo 6.27.</b> QRS4 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	90
<b>Tablo 6.28.</b> QRS5 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	91
<b>Tablo 6.29.</b> QRS6 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	92
<b>Tablo 6.30.</b> QRS7 frekans aralığındaki EKG sinyalleri için SKB sonuçları. ....	93
<b>Tablo 6.31.</b> Ham EKG sinyalleri için DKB sonuçları.....	94

<b>Tablo 6.32.</b> Üst örneklenmiş EKG sinyalleri için DKB sonuçları. ....	95
<b>Tablo 6.33.</b> QRS1 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	96
<b>Tablo 6.34.</b> QRS2 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	97
<b>Tablo 6.35.</b> QRS3 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	98
<b>Tablo 6.36.</b> QRS4 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	99
<b>Tablo 6.37.</b> QRS5 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	100
<b>Tablo 6.38.</b> QRS6 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	101
<b>Tablo 6.39.</b> QRS7 frekans aralığındaki EKG sinyalleri için DKB sonuçları. ....	102
<b>Tablo 6.40.</b> 10 s süre için en iyi sonuç veren frekans bantlarına dair SKB ve DKB tahmin sonuçları. ....	103
<b>Tablo 7.1.</b> Frekans bant aralıkları ile ilişkili literatür çalışmaları. ....	108
<b>Tablo 7.2.</b> Çalışma alanına ilişkin genel literatür taraması. ....	109

## ŞEKİL LİSTESİ

### Sayfa

Şekil 2.1. Kalbin yapısı [69] .....	11
Şekil 2.2. Wiggers Diyagramı [71] .....	13
Şekil 2.3. Kalbin sistol ve diyastol evrelerindeki durumu [73] .....	14
Şekil 2.4. EKG trasesi [75] .....	15
Şekil 2.5. Kalp iletim sistemi elemanları [77] .....	16
Şekil 2.6. Hücredeki iyon konsantrasyonuna karşılık kardiyak aksiyon potansiyeli grafiği [78] .....	17
Şekil 2.7. EKG konfigrasyonu (a) ektremite ve göğüs elektrotlarının yerleşimi (b) vektörel bileşenlerin üç boyutlu düzlemde gösterimi [79].....	19
Şekil 2.8. Elektrokardiyografi işareti morfolojik gösterimi [83] .....	22
Şekil 3.1. Renin anjiyotensin aldosteron sistemi [89].....	26
Şekil 3.2. İndirekt kan basıncı ölçüm sistemi [93] .....	28
Şekil 4.1. Uygulama akış diyagramı .....	31
Şekil 4.2. Birinci kişiye ait günlük örnek veri kaydı. ....	32
Şekil 4.3. Üçüncü kişiye ait EKG ve KB bozulmuş kayıt örneği. ....	32
Şekil 4.4. 4 saniyelik epoklanmış EKG sinyali için örnek veri .....	34
Şekil 4.5. Bant geçiren filtreye ait tasarım örneği. ....	35
Şekil 4.6. $H(z)$ kutup ve sıfır dağılımları. ....	36
Şekil 4.7. $H(z)$ bant geçiren filtre yanıtı. ....	37
Şekil 4.8. Birinci kişiye ait QRS4-5-6-7 frekans bantlarına ait EKG kayıtları.....	37
Şekil 5.1. Kan basıncı test verisi üzerinde karar ağacı yapısı örneği.....	52



## ELEKTROKARDİYOĞRAFI SİNYALİ İLE YAPAY ZEKÂ TABANLI KAN BASINCI TESPİTİ

### ÖZET

Çalışmanın iki ana terimi kan basıncı (KB) ve elektrokardiyografidir (EKG). Kan basıncı, damarlarda dolaşan kanın damar çeperine yaptığı basınç olarak tanımlanır. Bu durum kalbin dolaşım sistemi ile kan pompalanmasından kaynaklı oluşan basınçla ilişkilidir. Kan basıncı genellikle kalp döngüsündeki sistolik ve diyastolik basınç ile ifade edilir. Ayrıca kan basıncı, kan hacmi sempatik sinir sistemi (SNS) ve renin-angiotensin aldosteron sisteminin (RAAS) karşılıklı etkileşimiyle düzenlenmektedir. Bu iki sistem tarafından sebep olunan vazokonstriksiyon, baro refleksi adı verilen iki aktif negatif geri besleme sistemi tarafından modüle edilir. Elektrokardiyografi ise, kalp kasının ve sinirsel iletim sisteminin çalışmasını incelemek üzere kalpte meydana gelen elektriksel faaliyetin kaydedilmesidir. Bu sinyal işareti kalp atımları ile gerçekleşir. Kalp kaslarında aksiyon potansiyel gerçekleştiğinde, kalp kasları kasılır. Böylece kalp tarafından vücudun her tarafına kan pompalanır. Bu aksiyon potansiyelden oluşan akım kalpten tüm vücuda yayılacaktır. Kalbin sistol ve diyastol evrelerinde vücudun farklı bölümlerinde farklı akım dağılımları ile karşılaşılır. Dolayısıyla bir sinyal oluşumu gözlemlenir. Ayrıca bu evrelerde kalbin kasılma ve gevşemesinden kaynaklı damar çeperlerine yapılan basınç ortaya çıkar. Bu durum EKG ve kan basıncı arasındaki ilişkiyi gösteren detaylar arasındadır.

Kan basıncının ölçülmesi ve takibi, kalp ve damar hastalıkları, hipertansiyonun neden olduğu inme, böbrek yetmezliği gibi hastalıkların önlenmesinde büyük önem taşımaktadır. Özellikle kan basıncının normalden yüksek olması olarak adlandırılan hipertansiyon, dünyadaki her iki ölümden birinin sebebi olarak öne çıkmaktadır. Hipertansiyonun teşhis ve tedavisinde kan basıncı takibi temel faktördür.

Kan basıncı ölçümlerinde invaziv ve noninvaziv yapılara sahip birçok yöntem kullanılmaktadır. İnvaziv ölçüm sistemleri çoğu zaman hatalı ölçümler ve zaman kaybı gibi sorunlara neden olmaktadır. Noninvaziv modeller ise, donanım ve yazılım maliyetleri gibi birçok soruna neden olmaktadır. Ayrıca bu işlemin stigmamometre, manşon ve kadranlı barometre gibi araçlar ile gerçekleştirilmesi karmaşık ve olumsuz etkilere sebep olmaktadır. Bu tür invaziv yöntemlerin üstesinden gelmek için son zamanlarda literatürde pek çok tahmin yöntemi ileri sürülmüştür. Kan basıncı tahmini üzerine yapılan çoğu araştırma, elektrokardiyogram ve fotopletizmografi (PPG) sinyallerini veya bunların bir kombinasyonunu kullanır. Bu ekipman ihtiyacını beraberinde getirir. Buna ek olarak, bu yöntemlerde görülen ölçüm hataları, süre kısıtları performans açısından verimsizliğe sebep olmaktadır. Giyilebilir biyosensörler, hayati insan belirtilerinin gerçek zamanlı izlenmesi için bir fırsat sağlar, zamanında geri bildirim sağlar, erken teşhis ve tedavi olanakları sağlar. Modern giyilebilir biyosensörler, belirli bir ölçüm prosedürüne tabi olan geleneksel kan basıncı sensörlerinden farklı olarak ilgili sinyalleri gün boyu izler ve cihazı takmaktan başka bir yük oluşturmaz. Bu sinyallerin insan vücudundan güvenilir bir şekilde alınması ve alınan sinyal verilerinin toplanması önemli araştırmaları beraberinde getirmektedir.

Elektronik verilerin güvenli bir şekilde toplanması, doğrulanması ve taşınması, nesnelerin interneti (IoT) ve yapay zekâ teknolojisinin entegrasyonu ile sağlanır. IoT ekipmanının kalitesini etkin bir şekilde garantilemenin zorluğu, beraberinde verilerin güvenilirliğini ve doğruluğunu sağlamanın zorluğunu getirir. Bu durum, makine öğrenme tekniklerine dayalı algoritmaların doğruluğunda büyük önem taşımaktadır. Bu nedenle gelişmiş yapay zekâ tabanlı noninvaziv bir süreçle yönetilebilen yeni teknolojik altyapıya sahip sistolik ve diyastolik kan basıncı ölçüm sistemlerine ihtiyaç vardır. Bu kapsamda, çalışma EKG sinyalinin kullanarak indirekt ölçüm tekniklerinin sebep olduğu sorunları gidermeyi, minimum hesaplama süresi tespiti yapmayı ve frekans bant analizi ile EKG'den edinilen bilgi aralıklarının niteliklerini değerlendirebilmeyi amaçlamaktadır.

Çalışma iki safhadan oluşan bir uygulama sürecine tabidir. İlk safhada kan basıncının minimum sürede hesaplanması hedeflenmiştir. İkinci kısımda ise tespit edilen minimum süre içinde frekans bant analizi ile EKG'nin incelemesinin mümkün kılınarak kan basıncı tespit performansını artırmaktır.

Çalışma IEEE veri tabanından alınan beş bireye ait günlük aktivite sırasında ölçülmüş EKG ve KB kayıtlarını içermektedir. Biri kadın, dördü erkek olan bu bireyler, periferik veya kardiyovasküler hastalığa sahip değildir ve sedanterden düzenli aktivite seviyesine kadar değişen bir aktifliğe sahiptir. Yaşları 21-35 arasında değişmektedir. Veriler 64 Hz örnekleme frekansına sahiptir. Beş katılımcı için ilk gün altı buçuk saat boyunca veri toplanmıştır. Veriler ayrıca dört ay ara ile bir ve ikinci katılımcılar için ve altı ay ara ile birinci katılımcı için toplanmıştır. EKG sinyali öncelikle gürültüden arındırılmıştır. Çalışmanın amacına uygun olacak şekilde her bir sinyal 2-4-6-8-10-12-14-16-18-20 saniyelik epoklara ayrılmıştır. Veri seti girdi bilgisi içermediği için zaman alanında 25 adet öznitelik çıkarımı yapılmıştır. Bu özellikler sıklıkla istatistikte kullanılan tanımlayıcı istatistiksel parametrelerdir. İstatistiğe dayalı özellik çıkarımının amacı farklı perspektiflerden EKG sinyali bilgisini ortaya çıkarmaktır. Bu şekilde bilgi kaybı önlenmektedir. Boyut optimizasyonunu sağlamak için sonraki adımda özellik seçimi yapılmıştır. Bu süreçte ise spearman özellik seçme algoritması kullanılmıştır.

Özellik setleri için üç farklı makine öğrenimi algoritmasına dayalı performans değerlendirmesi yapılmıştır. Her yapılan işlem, hedeflenen her bir süre için gerçekleştirilmiştir. Gömülü sistemlere entegresinin kolay olması sebebiyle gauss süreç regresyonu yapay zekâ algoritması tercih edilmiştir. Bu sürece göre, 16 saniyede en başarılı kan basıncı tahmini gerçekleştirilirken, diğer saniyelerin küçük başarı oranı farkları ile kullanılabilirliği öngörülmüştür. Alt frekans bant analizi sürecine ilişkin 10 saniyelik süre kullanımı tercih edilmiştir. 10 saniye ile daha hızlı sonuçlar elde edilir ve kan basıncı değerlerinin hesaplanmasında ortalama tepe değerler alınarak hata oranının azaltılması sağlanır.

İkinci uygulama sürecinde, 10 saniyelik epoklanmış EKG sinyali kullanılarak frekans bantlarında ayırım gerçekleştirilmiştir. 64 Hz frekansa sahip EKG kaydı için 56 Hz frekans bandında, frekans bant ayırımı yapabilmek için üst örnekleme yapılmıştır. 64 Hz frekans bandındaki bir kayıt, sadece 32 Hz frekans bandı içerisinde bilgi aktarabilir. Üst örnekleme yapılarak yeni veri seti frekansı 128 Hz olarak belirlenmiştir EKG sinyali 5-15 Hz, 5-11 Hz, 8-58.5 Hz, 3-40 Hz, 8-20 Hz, 9-30 Hz ve 2-40 Hz frekans bantlarına ayrılmıştır. Veri seti girdi bilgisi içermediği için zaman alanında 25 adet istatistiksel özellik kullanılmıştır.



İlk uygulama sürecinde 20 süre için toplam 500 adet özellik çıkarılmıştır. İkinci uygulama için ise 9 eş zamanlı EKG sinyalinden toplamda 225 adet özellik çıkarılmıştır. Bununla birlikte minimum düzeyde özelliğin kullanımı ile performansın yüksek oluşu hedeflendiği için bir seçim kriteri söz konusu olmaktadır. Özellik seçimi ile oluşturulacak modellerin performans artırımı için ilişkili özellikleri değerlendirmek önem arz etmektedir. Özellikler arasındaki ilişki düzeyini tespit etmek için spearman korelasyon kat sayısı veya özellik seçme algoritması kullanılmıştır. EKG sinyali ile 11 grup oluşturulmuş ve her bir gruba ait modelin korelasyon değeri hesaplanmıştır. İlişkisi yüksek olan istatistik özellikler belirlenmiştir. Bu adımdan sonra seçilen 11 özellik seti için üç makine öğrenimi algoritmasına dayalı tahmin modelleri oluşturulmuştur.

Çalışmanın ana sorusu "EKG ile KB tespiti için gereken minimum süre nedir?" ve "Minimum sürede hangi frekans bantlarında EKG ile KB tespiti yüksek doğrulukta gerçekleştirilir?" dir. Bu amaçla 2-20 saniye arasında farklı sürelerle sahip sinyaller için modeller geliştirilmiş ve algoritmalar test edilmiştir. Tespit edilen süre zarfında farklı frekans bantlarında EKG sinyal bilgisi alınarak KB tahmin modelleri oluşturulmuş ve performansları test edilmiştir.

Çalışmada önerilen model zaman aşımı açısından literatürdeki çalışmalardan önemli ölçüde farklılık göstermektedir. Her saniye için KB hesaplaması yapılmıştır. Hesaplanan KB değerleri, her adımda benzersiz bir yapı sergilemiştir ve performans artışı göstermiştir. İlk olarak EKG sinyali için istatistiksel girdiler belirlendikten sonra modelin performansının bazı özellikler karşısında düşük olduğu belirlenmiştir. Öte yandan, veri boyutu optimize edilerek gereksiz özellikler kaldırılmıştır. Bu sayede yüksek korelasyon seviyelerine sahip veri setlerinde performans artışı gözlemlenmiştir. Kademeli olarak geliştirilmeye çalışılan bu sistemde periyodik gözlemler tablolar halinde sunulmuş ve yüksek doğruluk oranı ile minimum süre tespiti yapılmıştır.

Karşılaştırma yapılan üç yapay zeka algoritması şunlardır: Gauss süreç regresyonu, karar ağacı ve topluluk karar ağacı algoritması. Bu algoritmalar birbirlerinden farklı çalışma teknikleri bakımından veri seti üzerinde çalışma süreci incelenmiş ve her koşul için performans değerleri karşılaştırılmıştır. Regresyon modellerine ve veri setine sağladıkları uyum sebebi ile kullanımları tercih sebebi olmuştur. Her iki uygulama sürecinde de topluluk karar ağacı algoritması en yüksek performans gösteren algoritma olmuştur. EKG sinyali ile her iki uygulama süreci için 11 grup oluşturulmuş ve minimum süre tespiti için 660, alt frekans bant analizi için 594 olmak üzere toplam 1254 adet model oluşturulmuştur.

1254 adet KB tahmin modelleri belirli performans değerlendirme metrikleri ile değerlendirilmiştir. Bunlar ortalama mutlak yüzde hatası (OMYH), ortalama mutlak hata (OMH), standart hata (SH), ortalama kare hata (OKH), kök ortalama karesel hata (KOKH), korelasyon katsayısı (R) ve korelasyon katsayısının karesi ( $R^2$ ) olmak üzere yedi adettir.

Minimum süre tespiti uygulamasına ilişkin DKB ve SKB tahmin modelleri için OMYH değerleri sırasıyla 2,44 ve 1,92 olarak 16 saniyede tespit edilmiştir. Alt frekans bantı analizine ilişkin DKB ve SKB 10 saniyede 2-40 Hz frekans bandı için OMYH tahmin performans değerleri sırasıyla 1,80 ve 1,36'dır.

Tüm bunlara göre, 10 saniyelik EKG sinyalinin 2-40 Hz frekans bandında yüksek performans oranıyla sistolik ve diyastolik kan basıncı değerlerinin hesaplanabileceği değerlendirilmektedir.



## AI-BASED BLOOD PRESSURE DETECTION WITH ELECTROCARDIOGRAPHY SIGNAL

### SUMMARY

The two main terms of the study are blood pressure (BP) and electrocardiography (ECG). *Blood pressure* is the pressure the circulating blood exerts on the vessel wall. This is related to the pressure caused by the heart's circulatory system and blood pumping. Blood pressure is usually expressed in terms of systolic and diastolic pressure in the cardiac cycle. In addition, blood pressure and volume are regulated by the interaction of the sympathetic nervous system (SNS) and the renin-angiotensin-aldosterone system (RAAS). The vasoconstriction caused by these two systems is modulated by two active negative feedback systems called baroreflexes. Electrocardiography is recording the electrical activity occurring in the heart to study the functioning of the heart muscle and the neurotransmitter system. This signaling occurs with heartbeats. When an action potential occurs in the heart muscle, the heart muscle contracts. Thus, blood is pumped by the heart to all parts of the body. The current formed from this action potential will spread from the heart to the whole body. Different flow distributions are encountered in different parts of the body during the systole and diastole phases of the heart. Therefore, a signal formation is observed. In addition, in these stages, pressure on the vessel walls arises due to the contraction and relaxation of the heart. This is among the details that show the relationship between EKG and blood pressure.

Measuring and monitoring blood pressure is very important in preventing cardiovascular diseases, stroke caused by hypertension, and kidney failure. Hypertension, called higher than normal blood pressure, stands out as the cause of one of every two deaths worldwide. Blood pressure monitoring is the main factor in diagnosing and treating hypertension.

Many methods with invasive and noninvasive structures are used in blood pressure measurements. Invasive measurement systems often need to be corrected, such as erroneous measurements and loss of time. Noninvasive models cause many problems, such as hardware and software costs. In addition, performing this process with instruments such as a stigmamonometer, cuff, and dial barometer causes complex and adverse effects. Many prediction methods have been proposed in the literature recently to overcome such invasive methods. Most research on blood pressure estimation uses electrocardiogram and photoplethysmography (PPG) signals or a combination of these. This brings the need for equipment. In addition, measurement errors and time constraints seen in these methods cause inefficiency in terms of performance. Wearable biosensors provide an opportunity for real-time monitoring of vital human signs, providing timely feedback and enabling early detection and treatment. Unlike traditional blood pressure sensors, which are subject to a specific measurement procedure, modern wearable biosensors monitor the relevant signals throughout the day. They do not create a burden other than wearing the device. Receiving these signals

from the human body reliably and collecting the received signal data brings essential research.

The secure collection, verification, and transport of electronic data are achieved through integrating the Internet of Things (IoT) and artificial intelligence technology. The challenge of effectively assuring the quality of IoT equipment comes with the challenge of ensuring the reliability and accuracy of data. This is important in the accuracy of algorithms based on machine learning techniques. For this reason, there is a need for systolic and diastolic blood pressure measurement systems with a new technological infrastructure that can be managed with an advanced artificial intelligence-based noninvasive process. In this context, the study aims to eliminate the problems caused by indirect measurement techniques by using the ECG signal to determine the minimum computation time and to evaluate the characteristics of the information intervals obtained from the ECG with frequency band analysis.

The study is subject to an implementation process consisting of two phases. In the first phase, it is aimed to calculate blood pressure in a minimum time. In the second part, it is to increase the blood pressure detection performance by enabling the examination of the ECG with frequency band analysis within the minimum time determined.

The study includes ECG and BP recordings of five individuals measured during daily activity from the IEE database. These individuals, one female and four males do not have peripheral or cardiovascular disease and have activity ranging from sedentary to regular activity levels. Their ages range from 21 to 35. The data has a sampling frequency of 64 Hz. Data were collected for six and a half hours on the first day for five participants. Data were also collected for the first and second participants, four months apart, and the first participant, six months apart. The ECG signal is primarily noise-free. In accordance with the purpose of the study, each signal was divided into epochs of 2-4-6-8-10-12-14-16-18-20 seconds. Since the data set does not contain input information, 25 features were extracted in the time domain. These features are descriptive statistical parameters often used in statistics. Statistical feature extraction aims to reveal ECG signal information from different perspectives. In this way, information loss is prevented. In order to achieve size optimization, feature selection was made in the next step. The spearman feature selection algorithm was used in this process. Performance evaluation based on three different machine learning algorithms was made for feature sets. Each transaction was carried out for each targeted period. Gaussian process regression artificial intelligence algorithm is preferred because it is easy to integrate into embedded systems. According to this process, the most successful estimation of blood pressure in 16 seconds was realized, while it was predicted that other seconds could be used with minor success rate differences. A 10-second period was preferred for the lower-frequency band analysis process. Faster results are obtained within 10 seconds, and the average peak values are taken in calculating blood pressure values, thus reducing the error rate.

In the second application process, frequency band separation was performed using a 10-second epoched ECG signal. For the ECG recording with a frequency of 64 Hz, upsampling was performed in the 56 Hz frequency band to distinguish between frequency bands. A 64 Hz frequency band recording can only transmit information within the 32 Hz frequency band. The frequency of the new data set was determined as 128 Hz by upsampling. The ECG signal was divided into frequency bands of 5-15 Hz, 5-11 Hz, 8-58.5 Hz, 3-40 Hz, 8-20 Hz, 9-30 Hz, and 2-40 Hz. . Since the data set did not contain input information, 25 statistical features were used in the time domain.

In the first application process, 500 features were extracted for 20 periods. For the second application, a total of 225 features were extracted from 9 simultaneous ECG signals. However, since it is aimed to use the minimum level of features and high performance, there is a selection criterion. It is essential to evaluate the related features in order to increase the performance of the models to be created by feature selection. Spearman correlation coefficient or feature selection algorithm was used to determine the level of relationship between features. 11 groups were formed with the ECG signal, and the correlation value of the model belonging to each group was calculated. Statistical features with high correlation were determined. After this step, prediction models based on three machine learning algorithms were created for the 11 selected feature sets.

The main question of the study is "What is the minimum time required for BP determination by EKG?" and "Which frequency bands can detect BP with ECG with high accuracy in minimum time?" is For this purpose, models have been developed for signals with different durations between 2-20 seconds and algorithms have been tested. BP prediction models were created by taking ECG signal information in different frequency bands during the determined period, and their performances were tested.

The model proposed in the study differs significantly from the studies in the literature in terms of timeout. KB calculations were made for each second. The calculated BP values showed a unique structure at each step and performance improvement. After first determining the statistical inputs for the ECG signal, it was determined that the model's performance was low compared to some features. On the other hand, unnecessary features are removed by optimizing the data size. In this way, an increase in performance was observed in data sets with high correlation levels. In this system, which was tried to be developed gradually, periodic observations were presented in tables, and minimum time was determined with high accuracy.

The three AI algorithms compared are Gaussian Process Regression, Decision Tree, and Ensemble Decision Tree algorithm. The working process of these algorithms on the data set was examined in terms of different working techniques, and the performance values were compared for each condition. Their use has been the reason for preference due to their compatibility with the regression models and the data set. The EDT algorithm had the highest performance in both implementation processes. With the ECG signal, 11 groups were created for both application processes, and a total of 1254 models were created, 660 for minimum time detection and 594 for lower frequency band analysis.

1254 KB prediction models were evaluated with specific performance evaluation metrics. These are mean absolute percent error (MAPE), mean absolute error (MAE), standard error (SE), mean square error (MSE), root mean square error (RMSE), correlation coefficient (R), and correlation coefficient squared ( $R^2$ ).

MAPE values for the DBP and SBP estimation models for the minimum time determination application were determined as 2.44 and 1.92, respectively, in 16 seconds. The MAPE estimation performance values for the DBP and SBP frequency bands of 2-40 Hz in 10 seconds for the lower frequency band analysis are 1.80 and 1.36, respectively. According to all these, it is evaluated that SBP and DBP values can be calculated with a high-performance ratio of the 10-second ECG signal in the 2-40 Hz frequency band.



# 1. GİRİŞ

## 1.1. Amaç ve Kapsam

Kan basıncının normalden daha yüksek olması hipertansiyon olarak adlandırılmaktadır [1]. Hipertansiyon, günümüzde pek çok insanı etkileyen kalp krizi, böbrek yetmezliği, inme gibi pek çok kardiyovasküler hastalık için bir risk faktörüdür [2-4]. Dünyadaki her iki ölümden birinin sebebi bu hastalıktır [3]. Ancak bununla birlikte Çin'in 31 vilayetinde 1,7 milyon insandan alınan kan basıncı verileri ile pek çok insanın hipertansiyon veya ilerlemiş bir hastalığa sahip olma olasılığı hesaplanmış ve hastalığın teşhisi, kontrolü hakkında metodolojiler geliştirilmiştir [5]. Çin gibi önemli bir nüfusa sahip ülkede yürütülen çalışma ile kan basıncı tespitinin önem seviyesi vurgulanmaktadır.

Hipertansiyonun teşhis ve tedavisinde kan basıncı takibi temel faktördür [2], [3]. Kalp kasları kasıldığı zaman sistolik kan basıncı meydana gelirken, gevşediği zaman diyastolik kan basıncı meydana gelir. Bir diğer deyişle yüksek kan basıncı kanın kan damarlarına yaptığı basınç değerinin normal değerden yüksek olması ile ifade edilebilir [1, 3, 6]. Sistolik ve diyastolik kan basıncı sırasıyla yaklaşık olarak 80 mmHg ve 120 mmHg'dır. Hipertansiyon sistolik kan basıncının 140 mmHg ve diyastolik kan basıncının 90 mmHg üzerinde olması olarak tanımlanır. Kan basıncı normal değer üzerinde bir değere ulaştıysa, kalp daha sıkı çalışmaya başlar. Kalbin bu dengesiz çalışması damarlarda genişlemeye, körlüğe sebep olur. Kalp krizi ile sonuçlanarak pek çok hastalığın ortaya çıkmasının sebebi olur [3]. Kalp diğer tüm organların besinsel ihtiyaçlarını karşıladığı için, kalpteki dengesizlikler dolaylı olarak tüm organları etkiler. Bu durumda, hipertansiyon başta beyin ve böbrekler olmak üzere pek çok organı etkiler [1-3].

Kan basıncı ölçümünde altın standart olarak oskültasyona dayalı metotlar olsa da günümüzde pek çok metot geliştirilmiştir [3-7]. Cıvanın toksik etkilerinde dolayı, Dünya Sağlık Örgütü (DSÖ) tarafından güvenilir elektronik cihazların kullanımı tavsiye edilmektedir [3].

DSÖ'ye göre, hipertansiyonun teşhis algoritması sırasıyla şu şekildedir [3]. (1) Birkaç günlük kan basıncı kayıtları alınmalıdır. (2) Ölçümler, sabah ve akşam olmak üzere günde iki kez alınmalıdır. (3) İki ardışık ölçüm arasında en az bir dakika bulunmalı, sonunda iki ölçümün ortalama değeri kayda alınmalıdır. (4) Ölçümler oturur pozisyonda alınmalıdır. DSÖ tarafından birkaç günlük ölçümlerin yeterli olduğu söylene de bazı çalışmalarda bir haftalık takip tavsiye edilmektedir [8].

Yürütülen çalışmalar ilaç tedavileri ile hipertansiyonun kontrol edilebileceğini göstermektedir [1, 9]. Hipertansiyon hastalarında, hastalığın takibi ve ilaç tedavisi hayati önem taşımaktadır. Bu sebeple hastaların tedavi ve hastalık sürecini özenle takip etmesi gereklidir [1, 3, 9].

Geçmiş yıllarda, kan basıncı ölçüm cihazları geniş çapta kullanılmadığı için, ölçümler sağlık kuruluşlarında yapılmaktaydı. Ancak bununla birlikte, günümüzde kan basıncı ölçüm cihazlarının yaygın çapta kullanımı ile evde ölçüm sistemleri giderek arttı. Bu tür cihazların en önemli özelliği, bireylerin teknik bilgi ihtiyacı duymadan ölçümlerini gerçekleştirebilmesidir [7, 10]. Cihazların kullanımı kolay olsada ölçümlerin doğruluk oranları hayati önem taşımaktadır. Bu sebeple, onaylı cihazların tercih edilmesi tavsiye edilmektedir [10].

Her bir cihaz farklı ölçüm tekniğine ve ölçüm lokasyonuna sahiptir [7]. Ancak DSÖ ölçümlerin oturur pozisyonda üst koldan yapılmasını tavsiye etmektedir [3]. Üst kol ölçümünün bilekten ölçümlerden daha doğru sonuçlar ürettiği bilinir bir gerçektir [3]. Hamile gibi her pozisyonda bulunamayan hastalarda, sonuçlarda ölçüm standartları aşılması sebebi ile önemli değişikliklere rastlanmaktadır [11].

Kan basıncı takibi farklı konumlardan ölçüm alınarak ve farklı metotlar kullanılarak elde edilsede, tüm bunlar aynı tasarım protokollerine maruz kalmaktadır. Literatürde pek çok ölçüm protokolü bulunmaktadır [10]. Tümünün amacı nitelikli ölçüm sistemlerini geliştirmektir. The International Organization for Standardization (ISO) [12], the European Society of Hypertension International Protocol (ESH-IP) [13-15], the Association for the Advancement of Medical Instrumentation (AAMI)[16] standartları bu protokollerden yalnızca birkaçıdır.



Noninvaziv brakial kan basıncı (KB) ölçümü, hipertansiyon tanısında birincil yöntemdir [17, 18]. Ancak bu ölçüm halk sağlığı için önemli sorunlar yaratmaktadır. Her yıl Amerika eyaletlerinde yaklaşık bir milyon insanın kan basıncı ölçümü normal kan basıncı değerinin 5 mmHg aşağısında veya yukarısında ölçülmektedir. Bunun sonucu olarak ekstra maliyetlerle birlikte pek çok insan yanlış tedavinin yan etkilerine maruz kalmıştır [17]. Bu sebeple doğru kan basıncı ölçüm metotlarını belirlemek büyük önem arz etmektedir. Literatürde oskültasyon yöntemleri, pletismografi, tonometri ve osilometrik yöntemler gibi pek çok kan basıncı tahmin metodu mevcuttur [7, 10]. Manşonlu cihazlar uzun yıllar boyunca üretilse de, yeni hedef, hastayı rahatsız etmeyen kan basıncı ölçümünü gerçekleştirmektir [10, 19]. PPG ve elektrokardiyografi sinyallerine dayalı sinyal işleme ve yapay zekâ tabanlı noninvaziv metotlar kan basıncı ölçümü için günümüz teknolojik medikal uygulamaları için vaat edici tekniklerdir [8, 19, 20].

Kan basıncı ölçümlerinde invaziv ve noninvaziv yapılara sahip birçok yöntem kullanılmaktadır. İnvaziv ölçüm sistemleri çoğu zaman hatalı ölçümler ve zaman kaybı gibi sorunlara neden olmaktadır. Ancak noninvaziv modeller, donanım ve yazılım maliyetleri gibi sorunlara neden olmaktadır. Literatürdeki birkaç makalede bu sorunların görüldüğünden bahsedilirse, genetik algoritma kullanılarak sinir ağı ile tasarlanan modelin başlangıç durumları optimize edilmeye çalışılmış ancak bu durum zaman ve donanım maliyeti açısından sorunlara yol açmış ve doğruluk oranında sadece küçük bir değişikliğe neden olmuştur. Böyle karmaşık ve uzun uygulama süreci kişi için kullanım sebebi olamamaktadır.

Kan basıncı ölçümlerinin insan yaşamına etkisi bu kadar önemliyken, bu sistemlerin geliştirilmesi araştırmacılar için büyük önem taşımaktadır. Kan basıncı ölçüm modelleri için her çalışma farklı bir metodoloji uygular. Bu çalışma, birbirlerine üstünlükleri bakımından farklılık gösteren çalışmalar arasında farklı bir yaklaşımla yerini almaktadır. Şu ana kadar kan basıncı ölçüm süresinin belirlenmesine yönelik bir çalışmaya rastlanmamıştır. Bu nedenle çalışma özgün bir model sunmaktadır. Derin öğrenme algoritmalarında görülen karmaşık matematiksel ifadeler yerine makine öğrenmesi tekniklerine dayalı bir model geliştirilmiştir.

Ayrıca literatür taramasında elde edilen bulgular, tasarlanan modelin diğer modellere göre daha yüksek doğruluk oranına sahip olduğunu göstermektedir.

Modelin tasarım aşamasında Sinyal işleme, spektrum analizi, özellik çıkarma uygulamaları ve morfolojik filtreler birçok alanda kullanılmaktadır. Bu çalışmada, sinyal bölütleme ve öznitelik seçimi yapılmıştır. Bu süreçler sadece biyotıp, tıp ve görüntü işleme gibi alanlarda değil, aynı zamanda mühendislik ve ticaretle de gerçekleştirilmiştir. Farklı alanlarda çeşitli metodolojilerle uygulamaları vardır. Tabatabaei, Aasi ve Jafari açısız temaslı yataklardaki kusurları tespit etmek için akustik emisyon yöntemi (AEM) ile sinyal analizi gerçekleştirdi [21]. Yazarlar, AEM ile elde edilen sinyaller üzerinde ampirik mod ayrıştırma (EMD) algoritması ile özellik çıkarımı uygulamışlardır. EMD, lineer olmayan ve durağan olmayan sinyalleri farklı çözünürlüklere sahip bileşenlere ayırarak analiz etmek için kullanılır [22]. Yazarlar bu yöntemi kullanarak sinyallerden zaman ve frekans alanı özelliklerini çıkarıyormuş gibi içsel mod fonksiyonlarını çıkardılar ve bu fonksiyonları Hilbert dönüşümü ile analitik bir ifadeye dönüştürerek rulmanlardaki kusurları tespit edebilecek bir model oluşturdular. Ancak farklı yazarlar tarafından elektrosensefalografi (EEG) sinyallerinin nöbet ve nöbetsiz olarak sınıflandırılmasında aynı uygulama süreci uygulanmıştır [22]. EEG sinyalleri, EMD yöntemiyle içsel mod işlevlerine ayrıştırılır. Bu fonksiyonlar analitik bir ifadeye dönüştürülmüş ve sinyallerin bant genişliği özelliklerinden çıkarılmıştır. Modelin sonunda makine öğrenme tekniklerine dayalı sınıflandırma modeli oluşturulmuştur. Benzer uygulama sürecine sahip iki makale, farklı sorunlara kesin çözümü uygulamıştır. Yine bir başka çalışmada, Y. Zhang ve Z. Wang, PPG sinyallerinden KB tespiti için 21 zaman domeni özelliklerini çıkardı [23]. Ortalama etki değeri (MIV) ile boyut optimizasyonunu sağladılar. Her bir özelliğin sinyalleri üzerindeki etki faktörünü hesaplayarak yüzeysel bir etki ile 8 öznitelik çıkarmışlardır. Son kullanılan makine öğrenme tekniği olan sinir ağları başlangıç koşullarını Genetik Algoritma ile optimize ederek yeni bir model oluşturdu. Aynı araştırma konusuna sahip olan bu çalışma, modelini spesifik bir yaklaşımla oluşturmuştur [23].

Ancak kullanılan öznitelik sayısının yüksek olduğu düşünüldüğünde optimizasyon algoritmalarının kullanılması kan basıncı tespitinin doğruluğunda sadece minimal bir

değişikliğe neden olmakta ve donanım maliyeti açısından pahalı olacağı düşünülmektedir. Bu da tasarımın iyi bir model sunmadığını açıkça göstermektedir.

Makine öğrenimi algoritmalarının geliştirilmesi, aynı problem için yenilikçi modeller oluşturmayı mümkün kılar. Çalışmanın metodolojisi, bu tür süreçler ele alınarak adım adım sunulmaktadır. İlk olarak, sinyallerin verimli bir şekilde kullanılabilmesi için sinyal işleme uygulanır. Literatürde sinyal işlemeye dayalı pek çok çalışma vardır. Bunlar noninvaziv yapıda olduğu için tercih edilmektedir. Bazı çalışmalar oskültatuar ve osilometrik dalga formları ve periferik sinyalleri kullanmaktadır [24]. Bunlara ek olarak konuşmaya dayalı ölçüm metotlarına da ulaşılabilir. Bu çalışmalar sinyal işleme ve makine öğrenme algoritmalarını kan basıncı tahmini için farklı tekniklerle kullanmıştır. Fotopletismografi (PPG) ve elektrokardiyografi (EKG), ölçümü kolay olan bir grup biyomedikal sinyaldir. EKG başucu monitörlerinde ve holterde kolayca ölçülebilir. Diğer yandan PPG sinyalleri şimdilerde akıllı bilekliklerde kullanılmaktadır. Bu sebeple EKG ve PPG'ye dayalı kan basıncı tahmin çalışmalarına ilgi literatürde giderek artmıştır [11, 19, 20]. Bu çalışmada EKG sinyalinin ölçüm kolaylığı sağlaması sebebi ile kullanımı tercih sebebi olmuştur. Sinyal işleme çalışmaları dijital filtreleme, özellik çıkarımı, özellik seçimi ve makine öğrenmeye dayalı regresyon adımlarını içerir [20, 25, 26]. Derin öğrenme algoritmalarında özellik çıkarma ve seçme işlemleri derin öğrenme metotları ile gerçekleştirilmektedir [27]. Sinyal işleme sürecinin başarısı tasarım adımlarına bağlıdır. Özellik çıkarımında sıklıkla sinyallerin standart özellikleri dikkate alınır [23, 24, 28]. Ancak bununla birlikte, sinyallerin standart özelliklerini incelemek yerine istatistiksel özelliklerini incelemek hem hata oranını azaltacak hem de gözden kaçan bilgileri yakalamaya yardım edecektir [29-31]. Bu çalışma da literatürdeki standart özelliklerden farklı olarak 25 adet istatistiksel özellik çıkarılmıştır.

Derin öğrenme metotları özellik çıkarma ve seçme işlemlerini içerse de eğitim periyotları oldukça uzundur [20, 22, 27]. Klasik makine öğrenme algoritmaları ile kıyaslandığında, derin öğrenmenin başarı oranı kısmen yüksektir. Bu çalışma sinyal işleme proseslerini optimize ederek klasik makine öğrenme algoritmalarına dayalı bir metot önermektedir.

Gauss Süreç Regresyonu (GSR), Topluluk Karar Ağacı (TKA) ve Karar Ağacı (KA) algoritmaları versetine yüksek uyum sağlamaları sebebi ile çalışmada kullanılmıştır [32-34].

Özellik seçim algoritmaları kan basıncı tahmin çalışmalarında nadiren kullanılmaktadır. Klasik makine öğrenme algoritmalarının tercih edildiği çalışmalarda, model performansı özellik seçim algoritmaları kullanılarak yükseltilmiştir [35-37]. Spearman korelasyon katsayısına dayalı özellik seçim algoritması, sergilediği yüksek performanstan dolayı kullanılmıştır.

Literatürde makine öğrenmesi tabanlı kan basıncı tahminine dayalı çalışmalar derin öğrenme modellerine dayalı çalışmaların bir adım ötesinde olduğu görünmektedir [20, 22, 38].

EKG ve PPG sinyalleri ile geliştirilen kan basıncı tahmin modellerinde model performans değerleri,  $0,84 < R < 0,95$ ,  $3,36 < OMH < 5,48$ ,  $0,78 < KOKH < 13,83$ 'dir. Oskültatuar ve osilometrik dalga formları ile gerçekleştirilen bir çalışmada, model performansları  $-0,9 < OMH < 11,032$ ,  $0,423 < R < 0,948$ 'dir.

Literatürde modeller geliştirilse de modellerin ne kadar süre içinde ölçülebilir olduğu ve hangi frekans aralığında daha verimli çalıştığı hakkında yeterli bilgi yoktur. Çalışma, sistolik ve diyastolik kan basıncını EKG sinyali ile tahmin etmek için gereken minimum EKG sinyali süresini belirlemeyi amaçlamaktadır. Çalışmada ilk olarak EKG sinyali 2, 4, 6, 8, 10, 12, 14, 16, 18 ve 20 saniyelik periyotlara bölünerek on farklı veri seti oluşturulmuştur. Daha sonra, zaman alanındaki her bir epoktan 25 öznitelik çıkarılmıştır. Spearman öznitelik seçim algoritması yardımıyla ilgili öznitelikler seçilmiş ve makine öğrenmesi algoritmaları yardımıyla kan basıncı değerleri tahmin edilmiştir. Çıkan sonuçlara göre, tespit edilen minimum süre belirli frekans aralıklarında değerlendirilerek performans gözetimi sağlanmıştır. Buna göre minimum sürede belirli frekans aralığında iyileştirilmiş performans ile sistem modellemesi gerçekleştirilmiştir.

## 1.2. Literatür Araştırması

Yapay zekânın uygulanması olan makine öğrenimi, patolojik teşhis, hasta izleme ve tedaviye yardımcı olma özellikleriyle tıpta bir paradigma kayması yaratır [39]. Makine öğrenimi algoritmaları kullanılarak hipertansiyonun uygun ve zamanında tedavisi için biyomedikal sinyaller ve kan basıncı arasındaki ilişki üzerine çok sayıda çalışma yürütülmektedir [12]. Tipik bir biyomedikal sinyal işleme sistemi, ilgilenilen biyolojik sistemi, biyomedikal sistemin aktivitesini yakalamak için kullanılan sensörleri ve sinyalleri analiz etmek ve ilgili sinyalden istenen bilgiyi çıkarmak için uygun metodolojiyi çıkarma sürecini içerir. Bu çalışmada incelenen biyomedikal sinyal, kalbin elektriksel aktivitelerini gösteren EKG sinyalidir.

Son teknolojik gelişmeler, giyilebilir biyosensörleri günlük kullanıma uygun hale getirdi. Giyilebilir biyosensörler, hayati insan belirtilerinin gerçek zamanlı izlenmesi için bir fırsat sağlar, zamanında geri bildirim sağlar, erken teşhis ve tedavi olanakları sağlar [40, 41]. Modern giyilebilir biyosensörler, belirli bir ölçüm prosedürüne tabi olan geleneksel kan basıncı sensörlerinden farklı olarak ilgili sinyalleri gün boyu izler ve cihazı takmaktan başka bir yük oluşturmaz. Bu sinyallerin insan vücudundan güvenilir bir şekilde alınması ve alınan sinyal verilerinin toplanması önemli araştırmaları beraberinde getirmektedir [42-44]. Elektronik verilerin güvenli bir şekilde toplanması, doğrulanması ve taşınması, nesnelerin interneti (IoT) ve yapay zekâ teknolojisinin entegrasyonu ile sağlanır [45-47]. IoT ekipmanın kalitesini etkin bir şekilde garantilemenin zorluğu, beraberinde verilerin güvenilirliğini ve doğruluğunu sağlamanın zorluğunu getirir [48, 49]. Bu durum, makine öğrenme tekniklerine dayalı algoritmaların doğruluğunda büyük önem taşımaktadır. Farhad Ahmed et. IoT terminalleriyle üretilen veri kümelerinin tıbbi senaryoları tam olarak kapsayamayacağını ve akıllı teşhisin önemli ölçüde azalacağını belirtmektedir [50]. Bununla birlikte, şu anda IoT'de, tıbbi görüntü verilerinin ve çok dalga biçimli verilerin yüksek güvenilirlikte elde edilmesine olanak sağlayan gelişmeler kaydedilmektedir [51]. Bu tür cihazlardan gerçek yaşam koşullarında iyi sonuçlar alınmaktadır. Yüzeysel Temporal Arter Tonometri tabanlı cihaz [52], PPG optik sensör [53], ARTSENS (Noninvaziv Tarama için Arteriyel Sertlik Değerlendirmesi) brakial arter basıncı için basınç [54], hacim kompanzasyonu ilkesine dayalı bir kan

basıncı tahmincisi [55] ve Modülasyonlu Manyetik Kan İmzası mekanizması [56] noninvasiv kan basıncı izleme için geliştirilmiş ölçüm sistemlerinden bazılarıdır.

Geleneksel olarak EKG sinyalleri, sinyallerin morfolojik özellikleri çıkarılarak model oluşturma sürecine başlanır [57-59]. Bu yaklaşımlardan farklı olarak, EKG sinyallerindeki bilgileri temsil etmek için karmaşıklık analizi kullanarak sistolik, diastolik ve ortalama kan basıncı tahmin modelleri oluşturan araştırmalar da mevcuttur [60]. Bu kişiler karmaşıklığı modelleyebilmek için sinyal hareketliliği, sinyal karmaşıklığı, fraktal boyut, entropi ve otokorelasyon olmak üzere 5 adet metrik kullanmışlardır. Karmaşıklık analizi ile ettikleri özellikler ile 30 s'de ve 0,3-50 Hz frekans bandında çalışan bir sınıflandırma tahmin modeli tasarlamışlardır. Ancak sistolik kan basıncı (SKB) ve diastolik kan basıncı (DKB) için sırasıyla KOKH değerleri 10,97 ve 19,34 olarak tespit edilmiş, bu da modelin doğruluk bakımından yetersiz, analitik olarak karmaşık ifadelerle yer açtığını göstermektedir.

Kan basıncı tahmini üzerine yapılan çoğu araştırma, elektrokardiyogram ve PPG sinyallerini veya bunların bir kombinasyonunu kullanır. Bu duruma örnek olarak bir çalışmada EKG ve PPG dalgalarının tepe, tepe-tepe, ortalama ve şekil faktörü gibi grafiksel değerleri elde edilmiş ve özellik olarak kullanmışlardır [61]. Tekrarlayan sinir ağı algoritma modeli ile regresyon modeli oluşturularak kök ortalama karesel hata (KOKH) değerleri SKB ve DKB için sırasıyla 3,63 ve 1,48 olarak hesaplanmıştır. Bu durum ekipman ihtiyacını da beraberinde getirir. PPG sinyal ölçümlerinin alınması birçok tekniğin kullanılmasını gerektirir [62-64]. Bu tekniklerin doğru kullanımı, PPG sinyallerinin doğru bir şekilde ölçülmesini gerektirir. Bu nedenle, kan basıncı ölçümü için PPG sinyallerinin kullanılması doğru bir seçenek değildir [65,66]

Kan basıncı ölçümünün doğruluğunu ve modelin genelliğini iyileştirmek amacıyla kan basıncını tahmin etmek için bir diğer çalışma destek vektör makinesi (SVM) ve rastgele orman (random forest) regresyon tahmin modeli oluşturmuştur [67]. İnsan vücudunun özelliklerini girdi parametresi olarak kullanmış ve genetik algoritma ile parametre optimizasyonu uygulamışlardır.

Derin öğrenme tekniklerine dayalı artık (residual) ağ ve uzun-kısa süreli bellek kullanılarak geliştirilen EKG sinyali ile kan basıncı tahmin modeli oluşturulmuş

uygulamalar da vardır [68]. Ancak derin öğrenme tekniklerinin kullanımı günümüz yüksek donanımlı bilgisayarlarının kısmi yerlerde kullanımı uygulamanın kullanımını kısıtlamaktadır.

Bu çalışma ise EKG sinyallerinden istatistiksel öznitelikler çıkarılarak oluşturulan veri seti ile kan basıncı tahmini yapmayı amaçlamaktadır.

### **1.3. Hedef ve Katkılar**

Gerçek hayattaki durumlarda, araçlarda, evde veya hastanelerde kan basıncı yalnızca bağımsız bir kan basıncı cihazı ile ölçülebilir. Öte yandan modern teletıp, hastanın göğsüne takılan elektrotlarda biyosensörlerin geliştirilmesine izin vererek kan basıncı ölçümünün elde edilmesini sağlar. Önerilen yöntem, giyilebilir sensör teknolojisi ile klinik durumlardan askeri ortamlara kadar değişen kullanım alanları sunmaktadır. Ayrıca çeşitli sensörleri insan vücuduna bağlama ihtiyacını azaltmak için uygun bir metodoloji geliştirilmiştir. Geliştirilen model, yapay zekâ tabanlı EKG sinyallerine dayalı olarak sistolik ve diyastolik kan basıncını tahmin süresini belirlemeyi amaçlamaktadır. Literatürde EKG ile kan basıncını tespit eden birçok çalışma olmasına rağmen, ne kadar süreyle kan basıncının ölçülebileceğine ve frekans bantlarında incelenmesine dair bir çalışma bulunmaması yönüyle büyük önem arz etmektedir.






## 2. ELEKTROKARDİYOĞRAFI İŞARETLERİ VE İNCELENMESİ

### 2.1. Kalp

Kalp, göğüs boşluğunun merkezinde iki akciğer arasında bulunan müsküler yapıda olan bir organdır. Temel görevi kanı pompalamaktır. Kalp dokusunun çeşitli tabakaları bir araya gelerek iki üst kısımda ve iki alt kısımda olmak üzere dört odacığı oluşturmaktadır. Üst kısımdaki odacıklar sağ ve sol atriyum, alt kısımdaki odacıklar sağ ve sol ventrikül olarak adlandırılmaktadır. Atriyumlar ventriküllere göre daha küçük bir yapıya sahiptir. Ayrıca atriyumlar vücuttan ya da akciğerlerden gelen kanı alırken, ventriküller büyük fizyolojik yapısı sayesinde vücutta kan dolaşımını sağlamaktadır. Sağ atriyum ve sağ ventrikül birbirinden triküspit kapak; sol atriyum ve sol ventrikül mitral kapak ile ayrılmaktadır. Triküspit kapak üç kapakçıktan oluşurken, mitral kapak iki kapakçıktan oluşur. Aortun sol ventrikülden çıkış kısmında yarım ay şeklinde üç adet kapakçık bulunmaktadır ve semilunar kapak olarak adlandırılmaktadır. Kalbin yapısı Şekil 2.1’de görsel olarak verilmiştir.



Şekil 2.1. Kalbin yapısı [69]

Kalbin çalışması kasılma ve gevşeme hareketleri ile gerçekleşmektedir. Bu sayede kirli kan sağ atriyum ve ventrikül tarafından akciğerlere pompalanırken, temiz kan sol atriyum ve ventrikül tarafından arterler üzerinden vücuttaki hücrelere pompalanır. Vücuttaki hücrelerin ihtiyaç duyduğu oksijen miktarına bağlı olarak kalpte üretilen elektriksel uyarılar (impuls) kalbin kasılma ve gevşemesini değişen zaman aralıklarında belirli ritimlerde gerçekleştirir. Kalbin kasılması ve gevşemesi, duygusal faktörler, dehidrasyon, bazı tıbbi durumlar gibi pek çok faktör tarafından etkilenmektedir. Sağlıklı bir kalp, dinlenirken dakikada yaklaşık 60 kez atabilir. Ancak bu dakikada 100 veya daha fazla kalp atımı olarak değişebilir.


## **2.2. Kardiyak Döngü (Kalp Siklusu)**

Kardiyak döngü, bir insanın nefes alması ile başlayan döngüsünün ömrünün sonu ile bitmesi olarak tanımlanabilir. Ancak tıbbi olarak kalbin belirli bir düzenle kasılıp gevşemesi kardiyak döngü ya da kalp siklusu olarak tanımlanır. Kalp kasıldığında kan pompalarken, gevşediğinde kanla dolar. Kasılma ve gevşeme sırasıyla sistol ve diyastol olarak nitelendirilmektedir. Sistol ve diyastollerden oluşan bu döngüye kalp siklusu veya kardiyak döngüsü olmak üzere farklı isimlendirmeler yapılabilmektedir. Her kardiyak döngü ya da kalp atımı döngüsünün tamamlanması 0,8 saniye sürmektedir [70].

Kardiyak döngü sırasında meydana gelen pek çok olay vardır. Wiggers diyagramı, kan basıncı, aort basıncı, ventriküler basınç ve hacim, atriyal basınç, elektrokardiyogram gibi parametrelerin kardiyak döngü boyunca değişimini gösterir. Bu sayede vücutta kalbin çalışmasının ne tür etkiler yarattığı gözlemlenir. Şekil 2.2’de kalbin sistol ve diyastol evrelerinde gerçekleşen olayların değişimi verilmiştir. Ayrıca sistol ve diyastol evreleri alt başlıklar halinde açıklanmıştır.

### **2.2.1. Ventriküler sistol**


Vena kava ile oksijensiz kan sağ atriya ulaşır. Atriya’daki basınç triküspit kapakçıkları açmaya yetecek kadar basınca sahip oluncaya dek sağ atriyum kan ile dolar. Artan basınçtan dolayı triküspit ve mitral kapakçıklar açıldığı zaman sağ atriya’daki kan pasif bir şekilde ventrikülleri doldurmaya başlar.



**Şekil 2.2.** Wiggers Diyagramı [71]

Ventriküllerdeki kan yaklaşık %70'e ulaşır. Sonrasında atriyum ventriküllere giden kan hacmini artırmaya zorlar. Ventriküldeki basınç atriyumdaki basıncı geçtiği anda mitral ve triküspit kapakçıklar kapanır ve ilk kalp atımı sesi duyulur. Sonra basınç artışı devam ederken aort ve pulmoner arterlere kan iletilir. Gönderilen kan hacminin artırılmaya çalışıldığı durumda atriyumun kasılması ile atriyal sistol oluşur (Şekil 2.3). Sağ ventrikül kasılır, bu durum ventrikül sistolü olarak adlandırılır [72]. Normalde sistol durumunda ventriküllerin içindeki kanın tamamı arterlere iletilmez. Bu iletim oranına ventriküllerin ejeksiyon fraksiyonu denir [72]. Bu oran kalbin performansı hakkında bilgi vermesi bakımından önem arz etmektedir.

Bunlara ek olarak, sistol iki evre içinde incelenebilir: izovolümetrik kasılma ve ejeksiyon. İzovolümetrik kasılma sol ventrikül basıncının hacimde değişme olmaksızın artması olarak ifade edilir. Sol ventrikül basıncı aort basıncını aştığı zaman aort kapağı açılır ve sonrasında sol ventrikül hacmi düşmeye başlar, bu evre ventrikül ejeksiyonu olarak adlandırılır. Ventrikül ejeksiyonunda aort kapağının basınç farkı ile kapanması sonucu sona erer.



**Şekil 2.3.** Kalbin sistol ve diyastol evrelerindeki durumu [73]


### **2.2.2. Ventriküler diyastol**

Kalbin gevşeme dönemi olan diyastol, sistol ile kan atımı sona erdikten sonra ventriküllerde gevşemenin başlaması ile oluşan evredir. Ventrikül hacmi henüz değişmeden gevşeme başlaması sebebiyle basınç düşmeye başlar. Ventriküller içindeki basınç aort ve pulmoner arterlerin basıncının altına düştüğü an basınç farkı sebebi ile aort ve pulmoner kapaklar kapanır, bu sırada ikinci kalp sesi duyulur. Sonrasında basınç düşmeye devam eder, mitral kapaklar açılarak tekrardan atriyumlardaki kan ventriküllere boşalır ve bu durum döngü şeklinde devam eder (Şekil 2.3).

Bunlara ek olarak, diyastol evresi dört safhada incelenebilir: izovolümetrik gevşeme, erken diyastolik dolun, dinlenme (diyastaz) ve atriyal dolun. Sistol evresinde ejeksiyonun sona ermesi ile aort kapağı kapanır ve mitral kapak açılana kadar ventrikül hacminde bir değişiklik olmaksızın basınç düşer ve ventrikül basıncı atriyum basıncı altına düştüğünde izovolümetrik gevşeme sona erer. Oluşan basınç farkı sebebi ile mitral kapak açılır ve ventriküller dolmaya başlar. Ventriküller dolarken basınç farkı da giderek azalır. Basınç ventriküller ve atriyumlar arasında dengelendiğinde mitral kapaktan kan akışını neredeyse durur. Bu durum dinlenme evresi (diyastaz) olarak tanımlanır. Diyastolün sonunda atriyumlarda kalan küçük bir kan hacmi ventriküllere geçmeye zorlanarak atriyum kasılmasına sebep olur. Bu da atriyum kasılma evresi olarak tanımlanır. Sonrasında ise sistol evresi başlayarak döngü sağlanır.

### 2.3. Elektrokardiyogram

Elektrokardiyogram, kalp kasının ve sinirsel iletim sisteminin çalışmasını incelemek üzere kalpte meydana gelen elektriksel faaliyetin kaydedilmesidir [74]. Kalbin sağlıklı olup olmadığını ağrısız ve hızlı bir şekilde tespit etmek için kullanılmaktadır. Ölçülen değerler özel olarak hazırlanmış olan trase olarak adlandırılan bir kâğıda aktarılır. Standart bir EKG trasesi, gerçek zamanlı kayıt sırasında saniyede 25 mm hızla hareket eder. Bu yazdırılan EKG'ye bakıldığında yatay ekseninde 25 mm'lik bir mesafenin 1 saniyeyi temsil ettiği anlamına gelir. EKG trasesi küçük ve büyük karelerden oluşur. Her bir küçük kare (1 mm x 1 mm) zaman ekseninde 40 ms'yi temsil ederken, genlik bakımından 0,1 mV'a karşılık gelir.



Şekil 2.4. EKG trasesi [75]


### 2.4. Kalbin İletim Sistemi ve Elektrokardiyografi İşareti

Kalbin her kasılması sinoatriyal düğümde ortaya çıkan elektriksel uyarılar (impuls) ile gerçekleşir. Kan hacmi ve kasılma kuvvetine ek olarak kalp görevini gerçekleştirebilmek için bu döngülerin bir düzene sahip olması gereklidir [74, 76]. Bu düzen, elektrokardiyogram adı verilen cihaz kullanılarak gözlenebilen kalp dokularındaki bir dizi kompleks elektrofizyolojik olaya dayanmaktadır.

Normal bir kalp döngüsü için gerekli en önemli olaylar, atriyumların ve ventriküllerin ritmik olarak kasılması ve gevşemesidir. Kalp çalışan hücre ve özel sinir benzeri hücre olmak üzere iki tip hücreden meydana gelir [74]. Çalışan hücreler, atriyum ve ventriküllerin kas veya miyokardiyumunu ifade ederken, özelleşmiş hücreler

sinoatriyal (SA) düğümü, atriyoventriküler (AV) düğümü, his demetleri, purkinje liflerini içermektedir [74, 76].

Bu hücreler, miyokard boyunca elektriksel uyarıları başlatır, iletir, kalp döngü ritmini düzenler. Şekil 2.5’de bu tip hücre yapılarının kalpteki konumları gösterilmiştir.



**Şekil 2.5.** Kalp iletim sistemi elemanları [77]

Dürtüleri başlatmak için elektriksel darbeleri kendiliğinden başlatma yeteneğine sahip özel hücreler vardır. Bu herhangi bir hormondan veya sinirden bağımsızdır ancak gerçek ateşleme hızları, sempatiklerin artması ve parasempatiklerin hızlarını düşürmesiyle otonomlardan etkilenebilmektedir [74]. Her kardiyak döngü sinoatriyal düğüm tarafından kendiliğinden üretilen ve daha sonra sinir benzeri iletken dokuların geri kalanı boyunca ve miyokardiyal hücelere yayılan bir dürtü ile başlar.

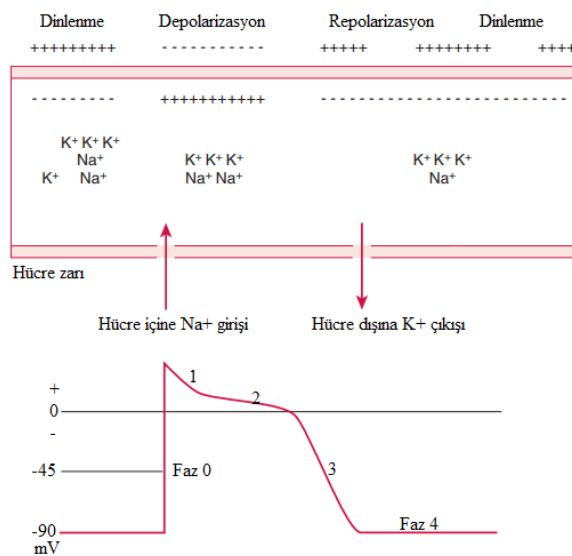
Kalbin atriyumlarının kanla dolması ile kardiyak döngü başlamaktadır. Bu süreçte kalbin %75’i kanla dolar. Bu da atriyum ve ventrikül arasında basınç farkının oluşmasına sebep olur [70]. Basınç farkı sinoatriyal düğümlerin atriyoventriküler düğümleri uyarması ile kapakçıkların açılarak kanın ventriküle aktarımı sağlanır. Aktarma esnasında atriyumların kasılması P dalgasının oluşumunu sağlar ve bu oluşum gerçekleşmezse atriyumlarda bir hastalığın var olduğu düşünülebilir. Kapakçıklardan geçen kan ilk olarak septuma gider ve Q dalgası oluşur.

Septumdan gelen uyarı ventrikül kaslarını uyararak kanın tamamıyla sol ve sağ ventriküllere gelmesi beklenir ve bu sırada R ve S dalgaları gözlemlenir [70]. Kan tam olarak ventriküllere geçtiğinde kapakçıklar kapanır ve tüm kan aort ve pulmoner venler ile vücuda pompalanır, ventrikül diyastolünün meydana geldiği bu kısımda son dalga olan T dalgası oluşur.

Kalbin iletim sisteminin daha iyi anlaşılabilmesi için öncelikle hücrelerde elektriksel potansiyel farkların nasıl oluştuğu bilinmelidir. Bu da aksiyon potansiyeli olarak tanımlanmaktadır, alt başlıkta detaylı olarak açıklanmıştır.

### 2.4.1. Kardiyak aksiyon potansiyeli

Kalp kasılabilir hücre yapılarına sahiptir. Bu hücrelerin görevlerini yapabilmesi için elektriksel dürtü ya da uyarılar gerekir. Bu dürtü hücre içi ve dışı arasında potansiyel fark ile oluşur. Normal koşullarda hücre içinde negatif iyonlar, hücre dışında ise pozitif iyonlar baskındır. Hücrenin bu normal durumu dinlenme olarak tanımlanmaktadır. Kardiyak aksiyon potansiyeli, bir hücrenin elektriksel zar potansiyelinin aniden yükselip alçalması ile oluşur. Aksiyon potansiyeli genliği ve süresi her zaman sabit olmakla birlikte sinir hücrelerinde uyarının şiddetinin artması ile aksiyon potansiyel frekansı artmaktadır [78]. Ancak çalışmada kalp kası hücreleri incelenmekte olup genlik ve zamanda değişme bu hücre tipinde meydana gelmemektedir. Şekil 2.6'da kardiyak aksiyon potansiyeli değişimi beş ayrı faz dahilinde hücre iç ve dış iyon değişimi eşliğinde ifade edilmiştir.



**Şekil 2.6.** Hücredeki iyon konsantrasyonuna karşılık kardiyak aksiyon potansiyeli grafiği [78]

Faz 4, hücre içi iyon dengesi negative ağırlıkta olup -90 mV seviyesindedir. Hücre bu evrede dinlenme durumundadır. Faz 0'da ise Na<sup>+</sup> kanalları açılır ve hücre içine Na<sup>+</sup> akışı sağlanır. Hücre içi iyon konsantrasyonu negative durumdan pozitif duruma geçmiştir, bu da depolarizasyon olarak tanımlanır. Faz 1'de aksiyon potansiyeli tepe değerine ulaştığında Na<sup>+</sup> kanalları kapanır, K<sup>+</sup> kanalları açılır. Hücre dışına K<sup>+</sup> akışı artar. Hücre içi potansiyel hücre dışına göre hala pozitif değerde olduğu için bu olay hızlı depolarizasyon olarak tanımlanır. Faz 2'de K<sup>+</sup> kanalları kapanır, K<sup>+</sup> iyon seviyesi azalırken Ca<sup>2+</sup> kanallarının açılması ile Ca<sup>2+</sup> geçirgenliği artar. Faz 3 evresinde Ca<sup>2+</sup> kanalları kapanır ve K<sup>+</sup> kanalları açılır, hücre negatif iyon konsantrasyonuna geçmiş olur. Hücre içi iyon konsantrasyonu potansiyel fark sebebi ile negatif olur ve bu duruma da repolarizasyon denir. Hücrenin pozitif durumdan negative duruma geçişi olarak da tanımlanabilir. Son olarak faz 4 evresinde hücre başlangıçtaki -90 mV potansiyel düzeye geri döner.

## **2.5. Elektrokardiyografi İşaretinin Ölçülmesinin Temelleri**

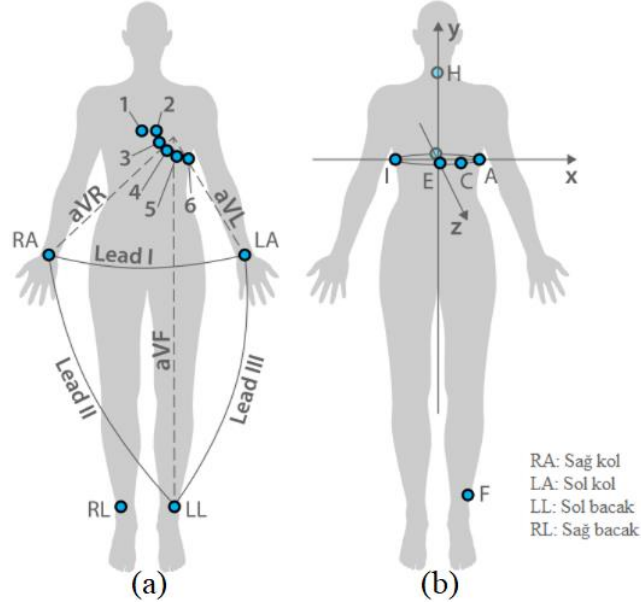
Kalp kası yaklaşık 10<sup>10</sup> adet hücreden oluşmaktadır. Bu hücreler, depolarizasyon ve repolarizasyon evrelerinde farklı elektriksel aktivitelere sahiptir. Her bir hücrenin elektriksel aktivitesi ise vektörler ile tanımlanır. Vektör, elektriksel dürtünün yön ve genlik bakımından temsil edildiği bileşke güç yönü olarak tanımlanabilir. Kardiyak vektörlerin toplamı kalbin elektriksel aktivitesini temsil eder. Kalbin elektriksel aktivitesi vücut yüzeyine yerleştirilen elektrotlar ile kaydedilmektedir.

Biraz geçmişe gidildiğinde elektrokardiyogramın Einthoven tarafından 1901 yılında keşfi ile günümüze kadar geldiği ve hala aynı ölçüm tekniklerinden yararlanıldığına ulaşılmaktadır. Einthoven kalbin bir elektriksel aktiviteye sahip olduğunu ve bunun vücuda yerleştirilen elektrotlar ile kaydedilebileceğini keşfetmiştir. Gümüş elektrot ile aldığı ölçümlerden kalbin ritmik atımına karşı dalga şekillerinin meydana geldiğini ve bu dalga şekillerinde sapmaların oluştuğunu gözlemlenmiştir. Einthoven oluşan bu dalga şekillerini P, Q, R, S ve T olarak isimlendirmiştir. Sonrasında ise Einthoven ve diğer çalışma arkadaşları bu dalgaların kalbin aksiyon potansiyelindeki değişimle ilişkilendirerek ölçümlerini daha anlamlı hale getirmişlerdir.

EKG işaretinden kalbin elektriksel aktiviteleri vektörel yaklaşımla belirlenebileceği keşfedilmiş, bu sayede üç boyutlu vektör bileşenleri ile, kalbin ön ve yatay izdüşümü hakkında bilgi elde edilir. Ekstremitelerdeki derivasyonları ön izdüşüm hakkında bilgi



verirken, prekordiyal derivasyonlar yatay düzlem hakkında bilgi verir. EKG ölçümünde genellikle 12 elektrot kullanılır. Bu elektrotlar ekstremitelerde ve prekordiyal derivasyonları göstermekte olup kalbin çalışması hakkında bilgi vermektedir. Şekil 2.7’de elektrotların uzuvlar ve göğüs için konumlandırılışı ve incelenen düzlem hakkında bir görsel verilmiştir.



**Şekil 2.7.** EKG konfigürasyonu (a) ekstremitelerde ve göğüs elektrotlarının yerleşimi (b) vektörel bileşenlerin üç boyutlu düzlemde gösterimi [79]

Ekstremitelerde derivasyonları kendi içinde ikiye ayırılır: unipolar ve bipolar. Unipolar derivasyonlar DI, DII ve DIII, bipolar derivasyonlar aVR, aVL ve aVF olarak tanımlanır. Unipolar derivasyon ölçümleri kol ve bacaklara elektrotlar bağlanarak alınır. Derivasyonların bağlantıları açıklanmadan önce sağ ayak potansiyel toprak olarak kabul edildiği belirtilmelidir ki bunun sebebi potansiyel genliğinde olan çok küçük değişim ve konumunun kalbe çok uzak olmasıdır. Ancak günümüzde böyle bir kabul mevcut değildir, sağ bacak toprağa değil yardımcı bir amplifikatörün çıkışına bağlanır. Vücut üzerindeki ortak mod voltajı iki adet yüksek değerde direnç tarafından algılanarak ters çevrilir, güçlendirilir ve sağ bacağı amplifikatörün geri beslemesi ile geri bağlanır. Bu durum EKG’deki sinyal bozulmalarını giderir, bireyi etkin bir şekilde topraklar. Bu sebeple derivasyonların üç uzuv kapsamında tanımı yapılacaktır. 1.derivasyon, sağ kol-sol kol arasındaki potansiyel farkı; 2.derivasyon sağ kol-sol bacak arasındaki potansiyel farkı; 3.derivasyon sol kol-sol bacak arasındaki potansiyel farkı gösterir. Bunlara ek olarak yükseltilmiş derivasyonlar vardır. Bipolar derivasyon

olarak da tanımlanan bu derivasyonlar aVR (sağ kol), aVL (sol kol), aVF (sol bacak) olmak üzere üç adettir.

Bunlar haricinde göğüs çevresinden alınan prekordiyal derivasyonlar vardır (V1, V2, V3, V4, V5, V6) [74, 76, 80]. Bu şekilde kaydedilen derivasyonlar sırasıyla traseye aktarılır.

Daha iyi anlamak için kalbin çalışma prensibini hatırlamak gereklidir. Kalp kaslarında aksiyon potansiyel gerçekleştiğinde, kalp kasları kasılır. Böylece kalp tarafından vücudun her tarafına kan pompalanır. Bu aksiyon potansiyelden oluşan akım kalpten tüm vücuda yayılacaktır. Vücudun farklı bölümlerinde farklı akım dağılımları ile karşılaşılır. Dolayısıyla bu sinyal vücuda yapıştırılmış yüzey elektrotları ile ölçülebilecektir. Farklı elektrotlardan farklı potansiyel dalga şekilleri ve genlikleri kaydedilebilir. Oluşan bu sinyaller kalpteki depolarizasyon ve repolarizasyon olaylarına göre pozitif ya da negatif potansiyel fark gösterirler. Eğer depolarizasyon dalgası pozitif bir elektroda doğru ilerliyorsa pozitif potansiyel, pozitif elektrottan uzaklaşıyorsa negatif potansiyel kaydedilmektedir. Sinoatriyal düğümünden çıkan uyarının atriyumlarda banchman demetleri ve internodal yollarla iletimi depolarizasyonu göstermekte bu da pozitif yönde oluşan P dalgasını göstermektedir. Repolarizasyon dalgası pozitif elektroda yaklaşıyorsa negatif potansiyel, uzaklaşıyorsa pozitif potansiyel görülür. Buna örnek ise T dalgasının oluşumu verilebilir. Purkinje lifleri ile taşınan ileti kalp kası hücreleri (miyokardiyum) boyunca iyon konsantrasyonuna bağlı olarak repolarizasyon dalgası oluşturur. Bu da negatif potansiyelde T dalgası oluşumunu gösterir.

Bu durumda elektrotların hangi uzuvlarda pozitif ya negatif olduğu bilinmelidir. DI için sağ kola negatif, sol kola pozitif elektrot bağlanır. DII için sağ kol negatif, sol bacak pozitif elektroda bağlanır. DIII ise sol kol negatif sol bacak pozitif elektroda bağlanır. Yükseltilmiş bipolar (çift kutuplu) derivasyonlar için bir uzuv daha eklenmektedir. aVR, sağ kol pozitif, sol kol ve bacak negatif; aVL sol kol pozitif, sağ kol ve sol bacak negatif; aVF sol bacak pozitif, sol kol ve sağ kol negatif elektrotlara bağlanır [78].

Göğüs derivasyonları sırasıyla konumları şu şekildedir: V1 kırmızı renk elektrot sağ 4.interkostal aralık, V2 sarı elektrot sol 4.interkostal aralık, V3 yeşil elektrot V2 ve V4 elektrotları arası, V4 kahverengi elektrot midklaviküler hatta 5.interkostal aralık, V5

siyah elektrot anterior aksiller hatta 5.interkostal aralık ve V6 midaksiler hatta 5.interkostal aralık olarak konumları tanımlanmaktadır (Avrupa ülkelerinde renkler genelde bu şekilde kabul edilmektedir fakat değişkenlik gösterebileceği unutulmamalıdır) [78].


Son olarak alınan değerlerin belirli düzlemde değerlendirilmesi gerekmektedir. Her bir elektrottan alınan potansiyel bileşen kardiyak potansiyeli olarak nitelendirilmekte ve insan vücudunun ön yüzüne yansıtılması ile kardiyak vektör oluşmaktadır. Yansıtılan vektörler tarafından oluşturulan iki eksen arasında 60 derecelik bir açı vardır. Bu kavram Willen Einthoven adlı Hollandalı bir fizyolog tarafından bulunmuş ve Einthoven üçgeni olarak adlandırılmıştır [76].

## **2.6. Elektrokardiyografi İşaretinin Morfolojisi ve Değerlendirilmesi**

EKG sinyali 0,05-100 Hz ve 1-10 mV dinamik frekans aralığında oluşmaktadır. EKG sinyali P, Q, R, S, T harfleri ile etikenlenmiş beş vadi ve tepecik tarafından karakterize edilmektedir [76, 81]. Bazı durumlarda U adlı bir diğer tepe noktası kullanılır. Bu harflerin oluşumu kardiyak döngü ile ilişkilendirilebilir. Atriyumların depolarizasyonu, ventriküllerin depolarizasyonu ve ventriküllerin repolarizasyonu ile gerçekleşen bu reaksiyon sırasındaki elektriksel aktivite EKG kayıtlarında bazı dalgalara sebep olur. Şekil 2.8'de bu dalgalara gösterimi ifade edilmiştir.

Sinoatriyal düğüm kalbin pacemaker hücreleri olarak anılmaktadır. Pacemaker ileti üreten olarak nitelendirilirse iletinin olduğu hücre olduğu çıkarımı yapılabilir. Ayrıca iletinin bu düğümde oluşması hücrenin kendi kendine iletisini oluşturduğu yani bir otomatisite hücresi olduğu anlamına gelir. Normal hücreler komşu hücreler ile iyon alışverişinde bulunarak bir potansiyel fark oluştururken sinoatriyal düğümdeki hücreler kendi iletilerini kendi oluşturan özel bir yapıya sahiptir. SA düğümünden çıkan bu uyarılar sağ ve sol atriya banchman ve internodal yollar üzerinde atriyoventriküler düğüme iletimi gerçekleşir. Buna atriyum depolarizasyonu denmektedir. Atriyum depolarizasyonunda potansiyel farkın oluşturduğu dalga şekli P olarak gösterilmektedir. AV düğüme gelen ileti burada saniyenin onda biri kadar bekletilir. Bunun sebebi ise atriyum ve ventriküllerin aynı anda kasılmasını engellemektir. AV düğümünden çıkan ileti ilk olarak sağ ve sol his demetlerine gelerek sağ ve sol ventrikülleri kasılması için uyarmaktadır. Septum boyunca ileti ilerlemiş ve artık purkinje liflerine geldiğinde ileti kalp kası hücrelerine gelmiştir.

Kalp kası hücrelerinin depolarizasyonu gerçekleşmiş ve yeni bir potansiyel bileşke vektörü oluşmuştur. Bu süreçte ventrikül depolarizasyonu gerçekleşmiş olup Q, R ve S dalgaları oluşmuştur. Genelde bu üç dalga QRS kompleksi olarak ele alınır. 0,04-0,10s genişliğe sahiptir. Son olarak ventrikül repolarizasyonu gerçekleşir. Ventriküllerin tekrardan depolarize olması için dinlenme potansiyeline geçtikleri süreçtir. Kardiyak döngünün bu fazı hızlı olmakla birlikte QRS kompleksini takip eden bir T dalgası görülür. T dalgası 0,10 ve 0,25 saniye aralığında, genliği ekstremite derivasyonlarında 5 mm (0.5 mv), göğüs derivasyonlarında 15 mm (1,5 mv) den azdır [82].



**Şekil 2.8.** Elektrokardiyografi işaret morfolojik gösterimi [83]

Şekil 2.8'e bakıldığında normal sinüs ritminde yani kalbin normal bir atımında, P-R aralığı 0,12 ila 0,2 saniye aralığındadır. Atriyumların depolarizasyonundan itibaren uyarının ventriküllere iletilmesine kadar geçen süreyi ifade etmektedir. PR segmenti ise atriyumların depolarizasyonu sonrasında ventriküllerin depolarizasyonuna kadar geçen elektriksel aktivitenin olmadığı bekleme süresini ifade eder. QRS kompleksi 0,04 ila 0,12 saniye, aralığındadır ve ventrikül depolarizasyonunu ifade eder. Q-T aralığı kadın ve erkekler için değişken bir süreye sahiptir. Erkeklerde 0,45 s'den az, kadınlarda 0,47s'den az sürede ventrikül depolarizasyonu ile repolarizasyonu için geçen zamanı tanımlar. RR aralığı ise kalp atımı hakkında bilgi verir. Kalbin normal atımı dakikada 60-100 arasında değişmektedir.

### **3. KAN BASINCI ÖLÇÜMÜNÜN ÖNEMİ VE İNCELENMESİ**

#### **3.1. Kan Basıncı**

Kan basıncı, ventriküllerden gelen kanın arter çeperlerine yaptığı basınç olarak tanımlanır. Bu durum kalbin dolaşım sistemi ile kan pompalanmasından kaynaklı oluşan basınçla ilişkilidir. Kan basıncı genellikle kalp döngüsündeki sistolik ve diyastolik basınç ile ifade edilir. Ventriküllerin kasılması sonucu kanın yüksek basınçla aorta gönderilmesi ile maksimum basınç düzeyi elde edilirken, ventriküller gevşediğinde ise arterlerdeki basınç minimum seviyeye iner. Bu olay sırasıyla sistolik ve diyastolik basıncın oluşumunu tanımlar. Ayrıca sistolik basınç, bir kalp atışı sırasındaki maksimum basınçken, diyastolik basınç iki kalp atımı arasındaki minimum basınçtır olarak da denilebilir. Birimi mmHg (milimetre cıva)'dır. Kan basıncı haricinde bir de arteryel kan basıncı vardır. Arteryel kan basıncı ise isminden de anlaşılacağı üzere kanın damar çeperinin belirli bir birimlik alanına uyguladığı basınçtır.

Kan basıncı kardiyak döngüsü sırasında meydana gelen olaylardan, kan hacminden ve akışkanlığından, damar elastikiyetinden doğrudan etkilenebilmektedir ve hastanın duygusal durumu ve ilişkili sağlık veya hastalık durumuna göre değişmektedir. Damarlarda akan kan hacmi artarsa eğer kanın damar çeperinde yeni bir basınç oluşur ve basınç artar. Eğer kan hacmi azalır doğru orantılı olarak kan basıncıda düşer. Yetişkin bir bireyde kan hacmi 5000 mL'dir. Bu değer göz önüne alınarak değerlendirme yapılabilir. Damarlarda meydana gelen daralma veya gevşeme kan dolaşımı sırasında eğer daralma varsa ekstra bir basınç artışına, gevşeme varsa basınç azalışına sebep olmaktadır. Bu duruma arterioskleroza (damar sertliği) sahip hastalarda rastlanabilir. Damarlar elastikiyetini kaybettiği için kan basıncı artışı meydana gelmektedir. Bunlara ek olarak kardiyak döngü boyunca sistol ve diyastol evrelere etki eden kanın akışkanlığındaki ya da yoğunluğundaki değişim, kalbin çalışmasını hızlandırıcı ya da yavaşlatıcı etki yaratacağı için vücuda pompalanan kan hacmi kan basıncını etkileyecektir. Kan basıncını anlatılan tüm bu faktörler etkilediğinde ana faktörler periferik vasküler direnç ve kardiyak çıkışıdır.

Periferik vasküler direnç, damar çapı, damar uzunluğu gibi etkenlerin damarlar üzerinde kan akışına karşı gösterdiği dirençtir ve bu direnç kan basıncının belirlenmesinde büyük rol oynamaktadır.

Kan basıncı kadın-erkek, yaş düzeyi, ırk gibi parametrelere göre değişkenlik gösterir. Bir araştırmaya göre kan basıncı seviyelerine göre kan basıncı kategorilere ayrılmıştır [84]. Bu kategori ve kan basıncı değerleri Tablo 3.1'de ifade edilmiştir. Bu tablo 18 yaş ve üzerindeki yetişkinler için oluşturulmuştur. Normal dinlenme durumunda kan basıncı, bir yetişkinde yaklaşık 120 mmHg (16 kPa) sistolik ve 80 mmHg (11 kPa) diyastoliktir ve "120/80 mmHg" olarak belirtilir. Küresel olarak, yaşa göre standardize edilmiş ortalama kan basıncı, 1975'ten günümüze kadar yaklaşık olarak aynı kalmıştır. Erkeklerde 127/79 mmHg ve kadınlarda 122/77 mmHg olarak değerlendirilmektedir ancak bu ortalama veriler önemli ölçüde farklı bölgesel eğilimleri maskeleymektedir.

**Tablo 3.1.** Kan basıncı sınıfları [84]

Sınıf	Sistolik/Diyastolik Kan Basıncı (mmHg)
Normal	< 120/80
Hipertansiyon öncesi evre	120-139 / 80-89
Safha 1 Hipertansiyon	140-159 / 90-99
Safha 2 Hipertansiyon	160-179 / 100-109
Safha 3 Hipertansiyon	≥ 180/110

Kan basıncı dengede tutmak ne yazık ki mümkün değildir. Vücutta bu dengeyi düzenleyen mekanizmalar vardır ancak bu sistemlerde sorun olduğunda kan basıncından kaynaklı hastalığın tedavisi için kan basıncını takip etmek büyük önem taşır. Bu sebeple ilk olarak hangi tür hastalıkların oluşabileceğini ve denge mekanizmalarının nasıl çalıştığını anlamak, sonrada ölçüm tekniklerine bilmek gereklidir.

### 3.2. Hipertansiyon ve Hipotansiyon Tanıları

Kan basıncının normal seviyeden düşük olması hipotansiyon, normal düzeyden yüksek olması hipertansiyon ve normal düzeyde olması normotansiyon olarak adlandırılmaktadır [85].

Hipertansiyon ve hipotansiyon ani ve uzun süreli olabileceği gibi kişide bazı hastalıklara sebep olabilir. Uzun süreli devam eden hipertansiyon pek çok hastalık için risk teşkil etmektedir. Bunlar felç, kalp hastalıkları ve böbrek rahatsızlıkları başta olmak üzere pek çok hastalığı içine almaktadır [86]. Uzun dönemli hipertansiyon, uzun dönemli hipotansiyondan daha yaygın bir hastalıktır. Hipotansiyon tıpta bir hastalık olarak tanımlanmasada kişilerde uzun dönemli varlığı tedavi gerektirebilmektedir. Hipertansiyon ise kalbin daha hızlı kan pompalamasına sebep olduğu için ciddi sonuçlar doğurabilmektedir. Bu tür sonuçların önüne geçebilmek ya da hastalığın tedavi sürecinde kan basıncının süreli takibi çok büyük önem taşımaktadır.

### **3.3. Kan Basıncının Düzenlenmesi**

Kan basıncı, kan hacmi sempatik sinir sistemi (SNS) ve renin-anjiyotensin aldosteron sisteminin (RAAS) karşılıklı etkileşimiyle düzenlenmektedir [87]. Bu iki sistem tarafından sebep olunan vasokonstriksiyon, barorefleks adı verilen iki aktif negatif geri besleme sistemi tarafından module edilir [87].

Açık bir şekilde ifade edilirse, vaso tıpta kan damarını ifade ederken, vasokonstriksiyon ise kan damarlarında meydana gelen daralmayı ifade eder. Bu daralma kan basıncı ve kan hacminde değişikliklere sebep olmaktadır. Vücudun bu değişimleri düzenlemesi için barorefleks adı verilen homeostatik mekanizma devreye girer. Bu mekanizma ise kan basıncı seviyesini sabit tutmakla görevlidir. Yüksek kan basıncında kalp atım hızını düşürmek için negatif geri besleme sağlayarak kan basıncını normal seviyede tutmayı başarmaktadır.

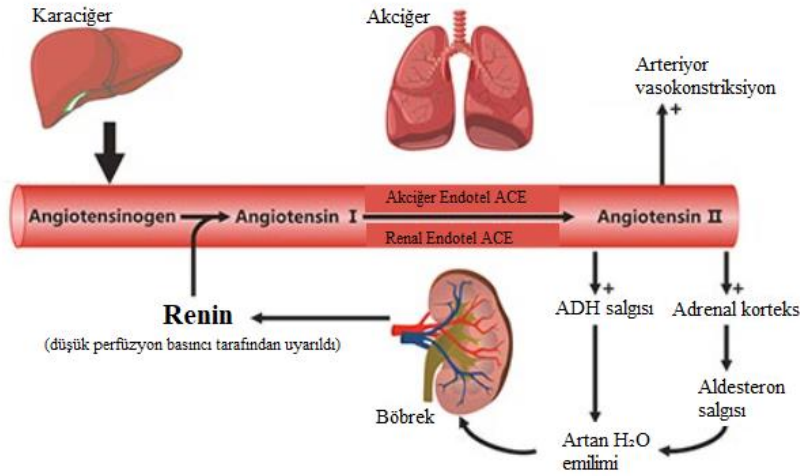
Kardiyopulmoner refleksler, periferik venokonstriksiyonu ve kardiyak ön yükü ve atım hacmini korumak için venöz dönüşü ayarlayarak kardiyak dolumundaki anlık değişikliklere yanıt verir [87].

Normal şartlar altında, her bir barorefleks sistemi, homeostazı korumak için basınç veya hacimde karşı artış ve düşüşler sağlayarak SNS çıktısını hemen değiştirebilir. SNS hipertansiyonda uygunsuz bir şekilde aktif olduğu için hipertansiyonun tüm formlarında izin verici bir rolü vardır. Baroreflekslerin SNS ve renin-anjiyotensin-aldosteron sistemi üzerinde uyguladığı negatif geri besleme mükemmel olsaydı hipertansiyon oluşmazdı.

SNS ve RAAS aktivitesinde uzun süreli artışlar doğrudan daha fazla kardiyak hipertrofi ve arteriyel sertleşmeyi kolaylaştırarak kalp ve damar sistemi üzerinde devam eden zararlı etkiler yaratır [87]. Bu etkiler kronik hipertansiyon ve hedef organ hasarlarına sebep olmaktadır. Ortostatik hipotansiyon ve barorefleks yetmezliği de bu hasarlara ek olarak sayılabilir. Bu tür bütünlük bir sistemin tamamıyla karşılıklı döngü içinde gerçekleşmesi, çıktılarının birbiri ile ilişkisini ortaya koymaktadır ve kayda değer bir değerlendirme sunmaktadır.

### 3.3.1. Renin anjiyotensin aldosteron sistemi (RAAS)

Renin anjiyotensin aldosteron sistemi, kan basıncının vücuttaki dengesini düzenleyen bir mekanizmadır [88]. Kan basıncı düştüğünde böbreklerdeki jukstaglomerüler hücreye ulaşan NaCl seviyesi düşer, bu da jukstaglomerüler hücrelerin renin salgımasına sebep olur. Aynı zamanda karaciğerde anjiyotensinojen enzimi üretilir. Anjiyotensinojen enzimi üretildiğinde pasifken renin salgısının uyarımı ile aktif hale geçer ve anjiyotensin I oluşur (Şekil 3.1).



Şekil 3.1. Renin anjiyotensin aldosteron sistemi [89]

Anjiyotensin I daha sonra akciğer ve böbreklerden salgılan anjiyotensin dönüştürücü enzim (ACE-ADE) ile anjiyotensin II'ye dönüştürülür [88]. Anjiyotensin II kan basıncının artmasını sağlayacak vasokonstriksiyonu oluşturur. Bununla birlikte artan kan basıncını azaltmak için böbrek tübüllerinden kana Na<sup>+</sup> ve H<sub>2</sub>O geri emilimini artırır. Anjiyotensin II aynı zamanda böbrek üstü bezlerinde (adrenal korteks) aldosteron salınımını uyarır. Böylece kan basıncı normal seviyeye dönmüş, kan basıncı homeostatığı sağlanmış olur.



### **3.4. Kan Basıncı Ölçüm Teknikleri**


Kan basıncı, sağlık uzmanlarının bir hastanın sağlığını değerlendirirken kullandığı hayati belirtilerden biridir. Geçmişten günümüze pek çok farklı yöntemle tespit edilmeye çalışılmıştır.

#### **3.4.1. Direkt ölçüm teknikleri**

Direkt ölçüm tekniği, kan basıncı ölçümü için arterin içine bir kateter konularak uygulanmaktadır. Özellikle anjiyografide, ameliyathanelerde hastanın yakından takibinin önem arz ettiği durumlarda bu ölçüm tekniğinden yararlanılmaktadır.

#### **3.4.2. İndirekt ölçüm teknikleri**

Atardamar bir aneroid ölçer veya bir cıva tüplü tansiyon aleti ile sol kol sıkıştırıldığında atardamarındaki sesler için bir stetoskop aracılığıyla oskültasyon (dinleme) yoluyla kan basıncı noninvaziv bir şekilde ölçülür [86]. Bu teknik 1905 yılında Dr. Korotkoff tarafından keşfedilmiştir [90]. Koldaki kan akışı durana dek kola sarılan manşonla basınç uygulanır. Sonrasında uygulanan basınç yavaşça azaltılır ve kan akışı başlar. Stetoskopta ilk duyulan sese karşılık manometrede okunan değer sistolik kan basıncına karşılık gelirken, azaltılmaya devam edilen basınçta ikinci duyulan sese karşılık gelen değer diyastolik kan basıncıdır. Şekil 3.2'de kan basıncı ölçüm sistemi görsel olarak verilmiştir. Oskültasyonla işitilen bu nabız sesleri korotkoff sesi olarak tanımlanmıştır. Oskültasyon, klinikte noninvaziv kan basıncı ölçümleri için hala altın doğruluk standardı olarak kabul edilmektedir [91]. Ancak bununla birlikte, yarı otomatik yöntemler, büyük ölçüde potansiyel cıva toksisitesi hakkındaki endişeler nedeniyle yaygın hale geldi, kullanım kolaylığı ve ayaktan kan basıncına uygulanabilirlik veya evde kan basıncı ölçümleri de bu eğilimi etkilemiştir [85, 92].



**Şekil 3.2.** İndirekt kan basıncı ölçüm sistemi [93]

### 3.5. Kan Basıncı Ölçüm Cihazları

**Cıvalı Cihazlar:** Ölçümler genelde cıvalı stigmomanometre ile yapılır. Manometrelerde cıva sütunu göz seviyesinde olmalı ve basınç uygulanmadığı sırada cıva düzeyi mmHg olarak okunmalı ve basınç uygulanırken sütun oynamaması gereklidir. Buna alternatif bir yöntem yoktur ancak cıvanın çevreye verdiği zarar sebebi ile birçok ülkede kullanımı yasaktır. Cıva tüplü tansiyon aletlerine yönelik erken otomatikleştirilmiş alternatifler genellikle ciddi şekilde hatalı ancak uluslararası standartlara göre onaylanmış modern cihazlar, iki okuma yöntemi arasında ortalama 5 mmHg veya daha az bir fark ortaya çıkarmaktadır ve 8 mmHg'den daha az bir standart sapma elde edilmektedir [92]. Bu yarı otomatik yöntemlerin çoğu, osilometri kullanılarak kan basıncı ölçülür [85].

Bunlara ek olarak mekanik bir sorun haricinde kalibrasyon gerekmemektedir. Göreceli büyüklük belirlenmesi ve kullanıcının eğitime gerek duyması dezavantajları arasındadır.

**Aneroid Cihazlar:** Aneroid sıvısız anlamına gelir. Cıva ya da cıva bu cihazlarda bulunmamaktadır. Ancak cıvalı cihazlar gibi oskültatuvar yöntemine dayalı ölçüm yapılır, manşete tutturulmuş bir stetoskop ve borulu bir komparatöre tutturulmuş bir stetoskop ile ölçüm yapılır. Manşet basıncını gösterge basıncına dönüştürmek için gösterge kafasının mekanik bir parçası vardır. Hatalı okumaları önlemek için cihazın yeniden kalibre edilmesi gerekir.

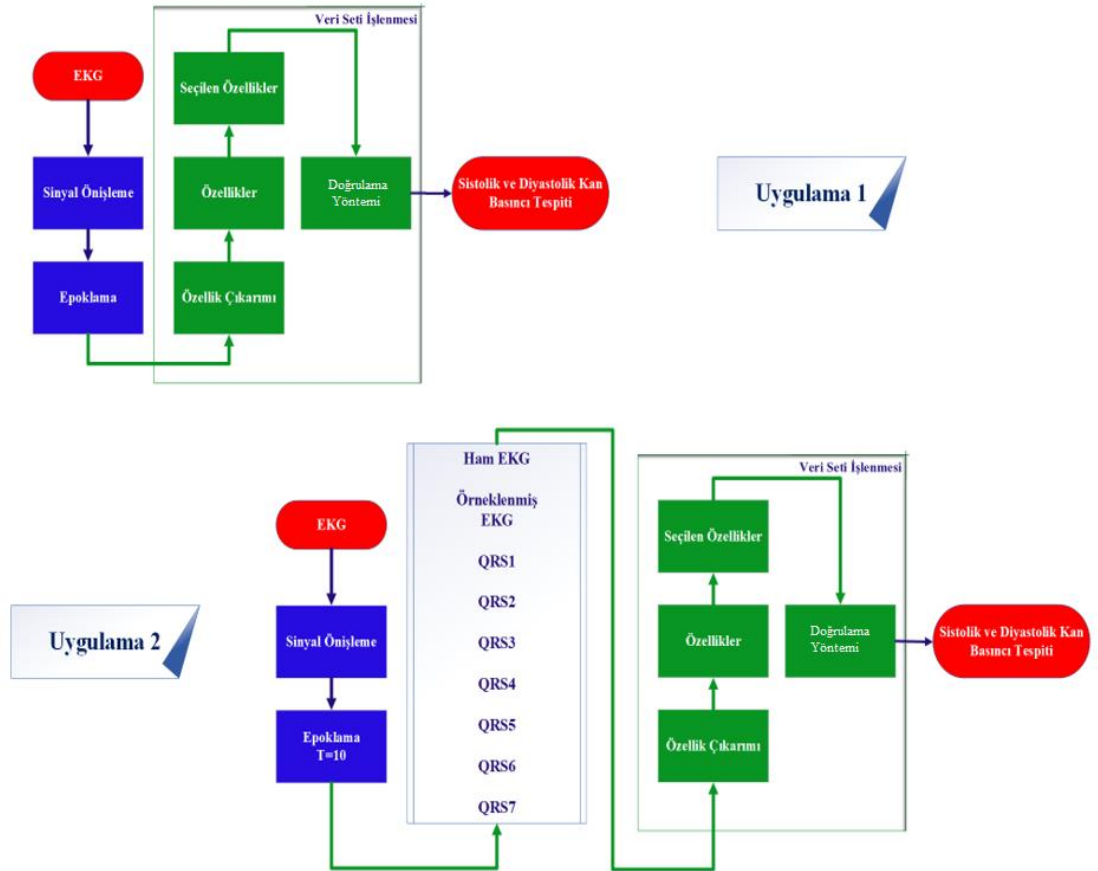
İbre sıfırda mı, ibrenin camı sağlam mı, rakamlar okunuyor mu, manşon sağlam mı, hortum sağlam mı, şişerken veya inerken hava kaçağı oluyor mu? Bu tür sorunların var olup olmaması kontrol gereksinimini ortaya çıkarmaktadır. Bazı araştırmalara göre evdeki ölçümlerde %30, eczanelerde %34 hata oranında kan basıncı aneroid cihazlar ile ölçülmüştür [94, 95].

Elektronik Cihazlar: Teknolojik olarak en gelişmiş yapıda tasarlanan cihazlardır. Sensör yardımı ile atardamardaki dalgalanmalar ölçülerek monitörde kan basıncı değerleri okunur. Ölçülen kan basıncı doğruluğundan emin olunmamakla birlikte cıvalı tansiyon aletleri ile doğruluğu tespit edilir. Ancak bu aletler gelişmiş teknolojik yapısı sayesinde aritmi saptama, hafıza kapasitesi, küçük boyutları, tarih ve saat kaydetme bakımında büyük kolaylıklar sağlamaktadır.



#### 4. ELEKTROKARDİYOĞRAFI İLE KAN BASINCI TESPİT MODELİNİN GELİŞTİRİLMESİ

Kan basıncı tahmini için temel yaklaşım Şekil 4.1’de gösterilmektedir. Akış diyagramında verilen süreç adım adım uygulanmıştır. İlk olarak EKG sinyalleri IEEE açık kaynaklı veri paylaşım platformundan temin edilmiştir [96, 97]. Alınan veri setinde gözlemlenen hatalar için filtreleme işlemi uygulanmıştır. İşlenen sinyaller için ilk hedef minimum sürede kan basıncını en iyi tahmin edebilecek modeli oluşturmaktır. Bu modelde tespit edilen süre için daha iyi bir doğruluk oranının tespit edilebileceği öngörüsü ile yeni bir yaklaşım ileri sürülmüştür. Bu yaklaşım ile sinyallerin farklı frekans bantlarında incelenerek en iyi süre tespiti yapabilecek model geliştirilmiştir. Bu modele dayalı uygulanan işlemler ayrıntılı olarak adım adım bölümler halinde sunulmaktadır.




Şekil 4.1. Uygulama akış diyagramı

#### 4.1. Verilerin Toplanması

Bu çalışmada, IEEE veri tabanı paylaşım platformu tarafından sunulan açık kaynaklı veri seti kullanılmıştır [96, 97]. Veri setinde EKG, PPG ve kan basıncı kayıtları bulunmaktadır. Bu kayıtlar beş genç bireyden alınmıştır.


Biri kadın, dördü erkek olan bu bireyler, periferik veya kardiyovasküler hastalığa sahip değildir ve sedanterden düzenli aktivite seviyesine kadar değişen bir aktifliğe sahiptir. Yaşları 21-35 arasında değişmektedir. Veriler 64 Hz örnekleme frekansına sahiptir. Beş katılımcı için ilk gün altı buçuk saat boyunca veri toplanmıştır. Veriler ayrıca dört ay ara ile bir ve ikinci katılımcılar için ve altı ay ara ile birinci katılımcı için toplanmıştır. Bu bireylere ait bir EKG örneği Şekil 4.1’de verilmiştir.



Şekil 4.2. Birinci kişiye ait günlük örnek veri kaydı.

#### 4.2. Elektrokardiyografi Sinyallerinin Önışlemesi

Verilerin toplanması sırasında meydana gelen teknik sorunlar veri setinde dengesiz sonuçlar yaratmaktadır. İlk gün boyunca yaklaşık bir saatlik bir blok için ikinci katılımcının verilerinde eksiklik mevcuttur.



Şekil 4.3. Üçüncü kişiye ait EKG ve KB bozulmuş kayıt örneği.

Ayrıca üçüncü ve beşinci katılımcıların yaklaşık 30 dakikalık kan basıncı ölçümü yapılmamıştır (Şekil 4.3). Bu sebeplerden dolayı veri setinde kullanılacak bozulmuş ya da teknik sorunlar nedeniyle eksik olan kan basıncı ve EKG sinyalleri için silme işlemi yapılmıştır.

### **4.3. Elektrokardiyografi Sinyallerinin Segmentasyonu/Epoklanması**

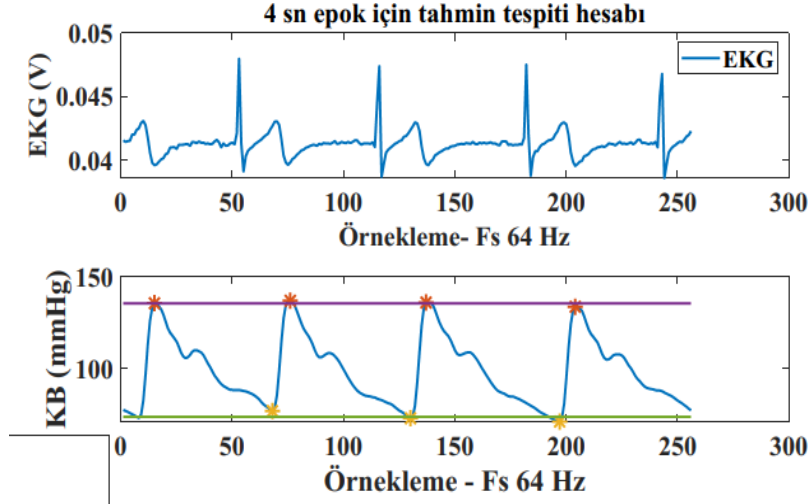
EKG sinyalini epoklamadaki temel amaç, her bir gizli durumla (veri setine bakıldığında farkedilmeyen, detaylı analiz gerektiren) ilişkili veri dağılımını tanımlayan parametrelerin yanında her bir zaman aralığındaki gözlenemeyen durumları ortaya çıkarmaktır. Zaman serileri ayırık zaman segmentlerine bölünerek epoklama gerçekleştirilmektedir.

64 Hz frekansa sahip EKG sinyali, kan basıncı tahmin modelini oluşturabilmek amacıyla 2-4-6-8-10-12-14-16-18-20 saniyelik epoklara bölünmüştür. Tasarlanan algoritma yapısı gereği sinyal üzerinde en az 6 tepe noktası bulunması gerekmekte bunun için de 8 saniyelik sürenin yeterli olduğu görülmektedir. Ancak bununla birlikte alınan sinyallerde yaşanabilecek aksaklıklar öngörülerek 10 saniyelik sinyal kan basıncı tespitini yapabilecek minimum süre olarak tespit edilmiştir. Sinyaller kan basıncı tahmin modellerini üretmek için 10 saniyelik epoklara bölünmüştür. Bunun sebebi en kısa sürede yüksek bilgi içeren sinyaller ile kan basıncı tahmin modelini geliştirmektir. 10 saniyelik EKG sinyali, yeni bir değer tahmin etmek için yeterli olduğu gözlemlenmiştir. 10 saniyelik epoklama işleminden sonra diyastolik ve sistolik kan basıncı modelleri için 12406 adet epok elde edilmiştir.

Sistolik ve diyastolik kan basıncı sinyalleri her bir periyod için hesaplanmıştır. Birinci katılımcı için 4 saniyelik epoklanan EKG ve kan basıncı sinyalleri Şekil 4.4'de verilmiştir.

Şekil 4.4 4 saniyelik EKG kaydı için eş zamanlı kan basıncı sinyallerini içermektedir. Kan basıncı sinyali 4 saniyelik epoklama için 4 adet minimum ve maksimum nokta içermektedir.

Kan basıncı sinyalinin minimum noktalarının ortalaması diyastolik kan basıncı değerini ifade ederken, maksimum noktaların ortalaması sistolik kan basıncını ifade etmektedir. Kan basıncı ve EKG sinyallerinin benzer karakteristiği Şekil 4.4'de sunulmaktadır.



Şekil 4.4. 4 saniyelik epoklanmış EKG sinyali için örnek veri

#### 4.4. Elektrokardiyografi Sinyalinin Filtrenmesi: Alt Frekans Bantlarına Ayrılması

Temel filte tipleri alçak geçiren, yüksek geçiren, band geçiren, band durduran olmak üzere dört kategoride sınıflandırılabilir. Bu tip filtrelerin her biri spesifik dijital sinyal işleme (DSP) uygulamalarında kullanılmaktadır. Her bir filtrenin kullanıcıya sunduğu imkanlar doğrultusunda istenen filtre tasarımı gerçekleştirilir. Çalışmada istenen durum EKG'nin belirli frekans bileşenleri kullanılarak kan basıncı tahmini yapabilmektir. Bu durumda EKG'de yalnızca belirli frekans aralığının geçirilmek istenmesi bant geçiren filtre tipinin kullanımını gerektirir. Dijital filtre seçimi için ise iki seçenek vardır: sonsuz dürtü yanıtı (FIR) ve sonlu dürtü yanıtı (IIR). Bu filtre tiplerinden uygulama için IIR filtre tipi tercih edilmiştir. IIR tip filtre, FIR filtresine göre çok daha küçük frekans bantlarında filtre tasarım imkânı sunar. Ayrıca IIR filtre, yalnızca giriş ve çıkış ifadelerine bağlı değildir. Bu ifadelerin geçmiş giriş ve çıkış değerlerine de bağlıdır. Transfer fonksiyonu pay polinomunun payda polinomuna oranı olarak tanımlanmakta ve sınırsız dürtü cevabına sahiptir. Bu sebeple filtre tasarımı daha az sayıda hesaplama gerektirir ancak doğrusal faz kolay bir şekilde elde edilemez. IIR filtresi kararlılığın sağlanması için transfer fonksiyonu payda polinomunun kökleri ya da transfer fonksiyonunun kutupları birim çember içinde olacak şekilde tasarlanır.

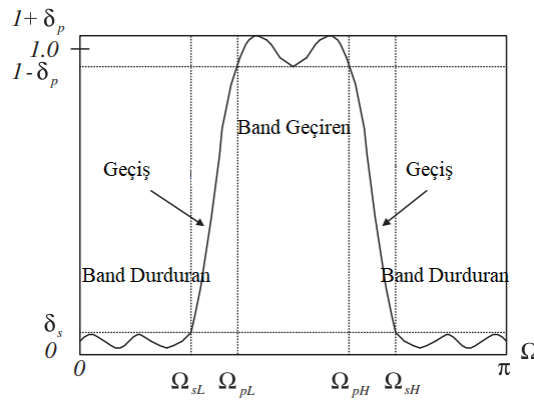
Bu kapsamda, gürültü temizliği ve istenen frekans bileşenlerini elde edebilmek için IIR-Chebyshev Tip II Bant Geçiren Filtre uygulanmıştır. Filtre aralıkları farklı olmakla birlikte tüm filtre türleri IIR-Chebyshev Type II Bant-Geçiren Filtre'dir.



Bant geçiren aralık, filtre yanıtının genlik kazancının olduğu frekans bandıdır. Bant durduran kısımda ise belirli frekans bileşenleri içinde olan giriş sinyalinin (EKG'nin) zayıflatıldığı kısımdır.

Şekil 4.5'de bant geçiren filtre tasarım örneği verilmiştir.  $\Omega_{pL}$  ve  $\Omega_{sL}$  sırasıyla alçak geçiren kesim frekansı ve alçak frekans bant durduran kesim frekansıdır.

$\Omega_{pH}$  ve  $\Omega_{sH}$  ise sırasıyla yüksek geçiren kesim frekansı ve yüksek frekans band durduran kesme frekanslarıdır. Bu parametreler doğrultusunda dijital filtrenin frekans aralıkları belirlenir. Filtre tasarımında öncelikle bu örnekte verilmiş parametreler hesaplanır ve sonrasında dijital filtre tasarımı gerçekleştirilir.



Şekil 4.5. Bant geçiren filtreye ait tasarım örneği.

Dijital filtreler temel bazı metotlar ile gerçekleştirilirler. Kaskat, paralel, direkt-I ve direkt-II formlarda yazılarak transfer fonksiyonları ile tanımlanabilirler. Yüksek dereceli fonksiyonlar için kaskat transfer fonksiyonunun kullanımı tercih edilmektedir. IIR filtresi (4.1'deki fark denklemi kullanılarak tanımlanır. Fark denklemi ile giriş ve çıkış değerleri arasındaki ilişki belirtilmiştir.

$$y(n) = b_0 * x(n) + b_1 * x(n - 1) + \dots + b_M * x(n - M) - a_1 * y(n - 1) - \dots - a_N * y(n - N) \quad (4.1)$$

Denklem (4.1'in z-dönüşümü alınarak IIR filtre tranfer fonksiyonu elde edilir (4.2).

$$H(z) = \frac{Y(z)}{X(z)} = \frac{b_0 + b_1 z^{-1} + \dots + b_M * z^{-M}}{1 + a_1 * z^{-1} + \dots + a_N * z^{-N}} \quad (4.2)$$

$b_i$  ve  $a_j$  sırasıyla transfer fonksiyonunun pay ve payda katsayılarıdır. Verilen denklemler doğrultusunda filtre analitik olarak tanımlanır.


Uygulama, Tablo 4.1’de verilen frekans bant aralıkları referans alınarak EKG sinyalleri tahmin modellerine hazır hale getirilmiştir. Örnek olarak 5-15 Hz frekans bandı için filtre tasarım örneği verilmiştir. Şekil 4.5’de verilen ifadeler için 128 Hz örnekleme frekansında alçak geçiren 5 Hz, yüksek geçiren 15 Hz frekans, alçak frekans bant durduran frekans 4,5 Hz ve yüksek frekans bant durduran frekans 15,5 Hz’dir. Bu ifadelere göre, tasarlanan transfer fonksiyonu kaskat yapıda transfer fonksiyonlarının çarpımı ile analitik ifadesi verilebilir. İlk olarak,  $n = 2$  için ayrık zaman transfer fonksiyonu hesaplanır.

$$H_1(z) = \frac{z^2 + 1,164 \cdot 10^{41}z + 4,19110^{81}}{z^2 + 8,108 \cdot 10^{40}z + 4,13810^{81}} \quad (4.3)$$


Transfer fonksiyonu kutupları 1,-1,9443, 1 iken sıfırları 1, -1,4682, 0,9873’tür. Bu bakımdan  $H_1(z)$  sıfır ve kutupları birim çemberin içinde olması sebebiyle kararlıdır. Tasarlanmış filtrenin transfer fonksiyonu kaskat yapıda transfer fonksiyonlarının çarpımı ile ifade edilir.

$$H(z) = H_1(z) \times H_2(z) \times \dots \times H_N(z) \quad (4.4)$$

Denklem (4.4’e göre 58 adet transfer fonksiyonunun çarpımı ile transfer fonksiyonu elde edilir. Transfer fonksiyonunun kutup-sıfır dağılımı Şekil 4.6’da verilmiş ve bu şekle göre kutup-sıfır dağılımı birim çember üzerinde olduğu için filtrenin kararlı olduğu tespit edilir. Ayrıca filtre yanıtı ise Şekil 4.7’de verilmiştir.

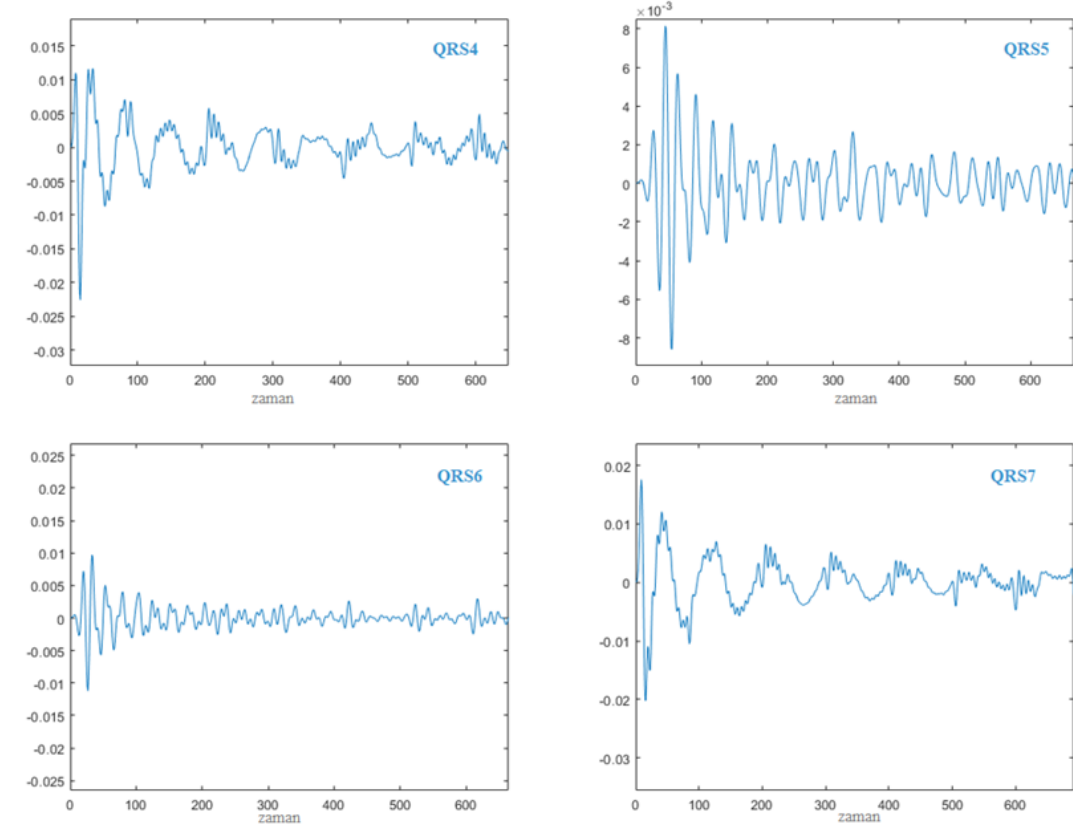


Şekil 4.6.  $H(z)$  kutup ve sıfır dağılımları.



**Şekil 4.7.**  $H(z)$  bant geçiren filtre yanıtı.

Tasarlanan filtre artık EKG sinyaline uygulanır. Tablo 4.1’de verilen bant aralıklarına göre EKG sinyali dijital filtre yardımıyla temizlenir ve alt frekans bantlarına ayrılır. İlk gün birinci kişiye ait EKG sinyali, QRS4-5-6-7 bant aralıkları için tasarlanmış filtrelere yanıtları Şekil 4.8’de verilmiştir.



**Şekil 4.8.** Birinci kişiye ait QRS4-5-6-7 frekans bantlarına ait EKG kayıtları

Filtreleme adımından sonra, filtrelenmemiş, üst örnekleme yapılmış ve filtrelenmiş yedi adet frekans bant sinyali ile toplam dokuz eş zamanlı EKG sinyali üretilmiştir. 7 adet alt frekans bant aralığı Tablo 4.1’de verilenler doğrultusunda elde edilmiştir.

**Tablo 4.1.** QRS bant aralıkları.

İsim	Frekans Bant Aralığı (Hz)
QRS1	5-15
QRS2	5-11
QRS3	8-58,5
QRS4	3-40
QRS5	8-20
QRS6	9-30
QRS7	2-40

#### 4.5. Özellik Çıkarımı

Özellik çıkarımı, ham veri setindeki bilgileri korurken işlenebilecek sayısal özelliklere dönüştürme sürecini ifade eder. Yapay zekâ algoritmalarını direkt veri setine işlemek yerine daha iyi modellerin oluşumu için özellik çıkarımı yapılır. Sinyal ve görüntülerde özellik olmaması verilerin karmaşıklığını daha da fazla ortaya koymaktadır. Bu tip verilerde kullanıcının seçimine bağlı olarak farklı özellik çıkarım teknikleri uygulanır. Bu çalışmada ise EKG sinyallerini daha anlamlı kılmak ve tahmin modellerini yüksek doğrulukta oluşturabilmek için 25 adet istatistiksel parametre özellik olarak kullanılmıştır.

Şu ana kadar yapılan tüm işlemler sonucu uygulama 1'e dair toplam 20 adet süreye ilişkin EKG sinyalinden 500 adet özellik çıkarılmıştır. Uygulama 2'de ise 9 adet eş zamanlı EKG sinyalinden 225 adet özellik çıkarılmıştır.

Bu özellikler sıklıkla istatistikte kullanılan tanımlayıcı istatistiksel parametrelerdir. Bu parametreler genellikle basıklık, medyan, ortalama, standart sapma ve lokasyon gibi bilgileri veri seti için tanımlar. İstatistiğe dayalı özellik çıkarımının amacı farklı perspektiflerden EKG sinyali bilgisini ortaya çıkarmaktır. Bu şekilde bilgi kaybı önlenmektedir.

Uygulama süresince kullanılan istatistiksel parametreler Tablo 4.2 ve Tablo 4.'de açıkça ifade edilmiştir. Belirlenen özelliklere ait ifadeler ayrıntılarıyla belirtilmiştir.

**Tablo 4.2.** Özellikler ait denklemler.

Numara	Özellikler	Denklem
1	Basıklık	$x_{kur} = \frac{\sum_{i=1}^n (x(i) - \bar{x})^4}{(n-1)S^4}$
2	Çarpıklık	$x_{ske} = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
3	*Çeyrekler Arası Açıklık	$IQR = iqr(x)$
4	Varyans Katsayısı	$DK = (S / \bar{x})100$
5	Geometrik Ortalama	$G = \sqrt[n]{x_1 + \dots + x_n}$
6	Harmonik Ortalama	$H = n / \left( \frac{1}{x_1} + \dots + \frac{1}{x_n} \right)$
7	Aktivite- Hjort Parametresi	$A = S^2$
8	Mobilite- Hjort Parametresi	$M = S_1^2 / S^2$
9	Karmaşıklık- Hjort Parametresi	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
10	* Maksimum	$x_{max} = \max(x_i)$
11	Medyan	$x = \begin{cases} x_{n+1/2} & x: \text{tek} \\ \frac{1}{2} * (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & x: \text{çift} \end{cases}$
12	* Ortalama Mutlak Sapma	$MAD = mad(x)$
13	* Minimum	$x_{min} = \min(x_i)$
14	* Merkezi Momentler	$CM = moment(x, 10)$
15	Ortalama	$x = \frac{1}{n} * \sum_{i=1}^n x_i = \frac{1}{n} * (x_1 + \dots + x_n)$
16	Ortalama Eğri Uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n  x_i - x_{i-1} $
17	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
18	Ortalama Karakök Değeri	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n  x_i ^2}$
19	Standart Hata	$S_{\bar{x}} = S / \sqrt{n}$
20	Standart Sapma	$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
21	Şekil Faktörü	$SF = X_{rms} / \left( \frac{1}{n} \sum_{i=1}^n \sqrt{ x_i } \right)$
22	* Tekil değer ayrışımı	$SVD = svd(x)$

**Tablo 4.2. (Devamı) Özelliklere ait denklemler.**

23	* %25 kırpılmış ortalama	$T25 = trimmean(x, 25)$
24	* %50 kırpılmış ortalama	$T50 = trimmean(x, 50)$
25	Ortalama Teager enerjisi	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$

\* simgesi Matlab ile hesaplanan ifadeleri belirtir.  
 $S^2$ : x sinyalinin varyansı  $S_1^2$ : x sinyalinin 1. türevinin varyansı  
 $S_2^2$ : x sinyalinin 2. türevinin varyansı

#### 4.6. Özellik Seçimi

Bir diğer adıyla boyut optimizasyonu olan özellik seçimi, gürültülü ve gereksiz özellikleri kaldırmak için uygulanan bir tekniktir. Yüksek boyutlu özellikler ile çalışırken, gereksiz veya ilişki düzeyi düşük özellikler bu teknikler kullanılarak ayrıştırılır [38]. Böylece sistem üzerindeki hesaplama karmaşıklığı, iş yükü azalır ve performans gözetimi daha az özellik ile belirlenmiş olur. Bunlara ek olarak, gürültülü ve istenmeyen özelliklerin kaldırılması hem hesaplama yükünü azaltma hem de tahmin doğruluğunu artırma bakımından makine öğrenme ve derin öğrenme tekniklerine dayalı modellerin performansına katkı sunduğu bazı çalışmalarda belirtilmiştir [31].

Özellik vektörü boyut optimizasyonu ve değersiz özelliklerin ayrıştırılması sınıflandırma ve regresyon algoritmaları için çok büyük öneme sahiptir. Bu bakımdan literatürde özellik seçim algoritmaları belirli gruplara ayrılmıştır: Denetimli, yarı denetimli ve denetimsiz. Bu çalışmada ise performans değerlerine bağlı olarak boyut optimizasyonu için spearman korelasyon özellik seçim algoritması tercih edilmiştir.

##### 4.6.1. Spearman korelasyon katsayı algoritması

Spearman korelasyon katsayısı ( $r_s$ ), DKB ve SKB etiketli veri setinde özelliklerin korelasyon seviyelerin ifade etmek için kullanılan istatistiksel bir metottür. Bu katsayı -1 ve 1 arasında değer alır. 1 veriler arasındaki değer mükemmel bir uyuma sahip olduğunu gösterirken, -1 uyumun mevcut olmadığı bilgisini vermektedir.

9 eş zamanlı EKG sinyalinden toplamda 225 adet özellik çıkarılmıştır. Ancak bununla birlikte minimum düzeyde özelliğin kullanımı ile performansın yüksek oluşu hedeflendiği için bir seçim kriteri söz konusu olmaktadır. Özellik seçimi ile oluşturulacak modellerin performans artırımı için ilişkili özellikleri değerlendirmek önem arz etmektedir. Özellikler arasındaki ilişki düzeyini tespit etmek için spearman

korelasyon kat sayısı kullanılmıştır. 225 özellik ve diyastolik ve sistolik kan basıncı değerleri arasında ilişki düzeyi Tablo 4.3 ve Tablo 4.4’de verilmiştir. Tablo 4.3 her bir zaman aralığına ait korelasyon düzeylerini gösterirken, Tablo 4.4 alt frekans bantlarına ait özellik setlerinin ilişkisini belirtmektedir. Korelasyon düzeyi yüksek olması veri setinin çıkartılan özellikler ile benzer bir ilişkiye sahip olduğunu göstermektedir. Ayrıca bu özelliklerin tahmin algoritması için iyi bir seçenek olduğu görülmektedir.

Spearman korelasyon kat sayısı ( $r_s$ ), n adet veri, i veri sayısı ve  $d_i$ , i’nci veri için parameter farkı olmak üzere

$$r_s = 1 - 6 \sum_{i=1}^n \frac{d_i^2}{n(n^2 - 1)} \quad (4.5)$$

şeklinde hesaplanarak ifade edilir.

İkinci uygulama safhasında korelasyon düzeylerine bağlı olarak özellikler sıralanmıştır (Tablo 4.5-Tablo 4.6). Örnek olarak verilen bu iki tablo ile korelasyon düzeyinin seçilen özellikler üzerinde yorumlaması yapılabilmektedir. Her iki tabloya ait detaylar altında açıklanmıştır.

**Tablo 4.3.** Her bir saniyeye ait özellik setleri için korelasyon düzeyi değerleri.

Bilgi		Çıkarılan Özellik Setleri için Spearman Korelasyon Katsayısı																								
Saniye	KB	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1
2	SKB	0,12	0,02	0,02	0,09	0,66	0,22	0,18	0,09	0,09	0,10	0,06	0,23	0,06	0,23	0,15	0,22	0,22	0,22	0,22	0,00	0,03	0,22	0,18	0,15	0,02
	DKB	0,12	0,02	0,02	0,09	0,66	0,22	0,18	0,09	0,09	0,10	0,06	0,23	0,06	0,23	0,15	0,22	0,22	0,22	0,22	0,00	0,03	0,22	0,18	0,15	0,02
4	SKB	0,17	0,02	0,04	0,18	0,65	0,24	0,21	0,18	0,18	0,48	0,14	0,26	0,09	0,23	0,16	0,24	0,24	0,24	0,24	0,02	0,08	0,24	0,19	0,20	0,00
	DKB	0,17	0,02	0,04	0,18	0,65	0,24	0,21	0,18	0,18	0,48	0,14	0,26	0,09	0,23	0,16	0,24	0,24	0,24	0,24	0,02	0,08	0,24	0,19	0,20	0,00
6	SKB	0,20	0,03	0,06	0,26	0,67	0,24	0,22	0,26	0,26	0,18	0,20	0,26	0,10	0,22	0,17	0,24	0,24	0,24	0,24	0,03	0,12	0,24	0,19	0,22	0,00
	DKB	0,20	0,03	0,06	0,26	0,67	0,24	0,22	0,26	0,26	0,18	0,20	0,26	0,10	0,22	0,17	0,24	0,24	0,24	0,24	0,03	0,12	0,24	0,19	0,22	0,00
8	SKB	0,21	0,04	0,06	0,30	0,68	0,24	0,22	0,30	0,30	0,36	0,25	0,26	0,11	0,22	0,17	0,24	0,24	0,24	0,24	0,02	0,14	0,24	0,20	0,23	0,01
	DKB	0,21	0,04	0,06	0,30	0,68	0,24	0,22	0,30	0,30	0,36	0,25	0,26	0,11	0,22	0,17	0,24	0,24	0,24	0,24	0,02	0,14	0,24	0,20	0,23	0,01
10	SKB	0,21	0,04	0,07	0,34	0,68	0,24	0,22	0,34	0,34	0,07	0,30	0,26	0,11	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,16	0,24	0,20	0,23	0,01
	DKB	0,21	0,04	0,07	0,34	0,68	0,24	0,22	0,34	0,34	0,07	0,30	0,26	0,11	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,16	0,24	0,20	0,23	0,01
12	SKB	0,22	0,04	0,07	0,37	0,69	0,24	0,22	0,37	0,37	0,27	0,34	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,18	0,24	0,21	0,24	0,02
	DKB	0,22	0,04	0,07	0,37	0,69	0,24	0,22	0,37	0,37	0,27	0,34	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,18	0,24	0,21	0,24	0,02
14	SKB	0,22	0,04	0,08	0,39	0,92	0,24	0,22	0,39	0,39	0,11	0,38	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,19	0,24	0,21	0,24	0,02
	DKB	0,22	0,04	0,08	0,39	0,92	0,24	0,22	0,39	0,39	0,11	0,38	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,19	0,24	0,21	0,24	0,02
16	SKB	0,23	0,04	0,08	0,39	<b>0,93</b>	0,24	0,23	0,39	0,39	0,10	0,41	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,20	0,24	0,22	0,24	0,02
	DKB	0,23	0,04	0,08	0,39	<b>0,93</b>	0,24	0,23	0,39	0,39	0,10	0,41	0,26	0,12	0,21	0,17	0,23	0,24	0,24	0,24	0,02	0,20	0,24	0,22	0,24	0,02
18	SKB	0,23	0,04	0,08	0,41	0,70	0,24	0,23	0,41	0,41	0,51	0,44	0,26	0,12	0,21	0,18	0,23	0,24	0,24	0,24	0,01	0,22	0,24	0,22	0,24	0,02
	DKB	0,23	0,04	0,08	0,41	0,70	0,24	0,23	0,41	0,41	0,51	0,44	0,26	0,12	0,21	0,18	0,23	0,24	0,24	0,24	0,01	0,22	0,24	0,22	0,24	0,02
20	SKB	0,23	0,04	0,08	0,41	0,70	0,24	0,23	0,41	0,41	0,12	0,46	0,26	0,13	0,21	0,18	0,23	0,24	0,24	0,24	0,02	0,22	0,24	0,22	0,24	0,02
	DKB	0,23	0,04	0,08	0,41	0,70	0,24	0,23	0,41	0,41	0,12	0,46	0,26	0,13	0,21	0,18	0,23	0,24	0,24	0,24	0,02	0,22	0,24	0,22	0,24	0,02



**Tablo 4.4.** Her bir frekans bantındaki EKG kaydı için korelasyon düzeyi değerleri.

Bant Aralığı	KB	25	24	23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1
Ham_EKG	SKB	0,12	0,06	0,02	0,11	0,33	0,38	0,05	0,11	0,11	0,20	0,04	0,39	0,12	0,30	0,14	0,33	0,38	0,38	0,38	0,27	0,19	0,38	0,15	0,03	0,05
	DKB	0,12	0,06	0,02	0,11	0,33	0,38	0,05	0,11	0,11	0,20	0,04	0,39	0,12	0,30	0,14	0,33	0,38	0,38	0,38	0,27	0,19	0,38	0,15	0,03	0,05
Üst_Örneklenmiş	SKB	0,06	0,07	0,04	0,11	0,33	0,38	0,05	0,11	0,11	0,16	0,04	0,39	0,25	0,31	0,18	0,33	0,38	0,38	0,38	0,27	0,19	0,38	0,16	0,00	0,00
	DKB	0,06	0,07	0,04	0,11	0,33	0,38	0,05	0,11	0,11	0,16	0,04	0,39	0,25	0,31	0,18	0,33	0,38	0,38	0,38	0,27	0,19	0,38	0,16	0,00	0,00
QRS_1	SKB	0,12	0,15	0,18	0,32	<b>0,52</b>	0,32	0,09	0,32	0,32	0,04	0,00	0,33	0,36	0,32	0,10	0,24	0,32	0,00	0,32	0,01	0,32	0,00	0,31	0,14	0,20
	DKB	0,26	0,02	0,03	0,07	<b>0,34</b>	0,07	0,24	0,07	0,07	0,22	0,00	0,07	0,09	0,07	0,00	0,05	0,07	0,01	0,07	0,00	0,07	0,00	0,07	0,01	0,10
QRS_2	SKB	0,17	0,17	0,11	0,30	0,47	0,30	0,09	0,30	0,30	0,07	0,00	0,30	0,28	0,31	0,02	0,30	0,30	0,02	0,30	0,00	0,32	0,00	0,32	0,02	0,13
	DKB	0,23	0,09	0,08	0,08	0,31	0,08	0,23	0,08	0,08	0,09	0,00	0,08	0,07	0,08	0,02	0,10	0,08	0,02	0,08	0,00	0,09	0,01	0,09	0,01	0,05
QRS_3	SKB	0,07	0,08	0,09	0,39	0,48	0,39	0,14	0,39	0,39	0,23	0,00	0,32	0,20	0,31	0,06	0,27	0,38	0,01	0,39	0,00	0,15	0,00	0,12	0,30	0,20
	DKB	0,14	0,06	0,09	0,20	0,32	0,20	0,21	0,20	0,20	0,14	0,00	0,14	0,11	0,16	0,03	0,09	0,20	0,01	0,20	0,00	0,09	0,01	0,08	0,14	0,05
QRS_4	SKB	0,14	0,30	0,31	0,36	0,49	0,36	0,10	0,36	0,36	0,17	0,00	0,30	0,18	0,35	0,29	0,27	0,36	0,01	0,36	0,00	0,34	0,01	0,35	0,18	0,09
	DKB	0,22	0,06	0,04	0,15	0,33	0,15	0,22	0,15	0,15	0,08	0,00	0,11	0,03	0,15	0,07	0,10	0,15	0,01	0,15	0,01	0,15	0,00	0,16	0,03	0,04
QRS_5	SKB	0,16	0,37	0,29	0,24	<b>0,51</b>	0,24	0,17	0,24	0,24	0,00	0,00	0,26	0,23	0,19	0,37	0,24	0,23	0,01	0,24	0,02	0,14	0,01	0,12	0,33	0,31
	DKB	0,18	0,10	0,07	0,08	<b>0,35</b>	0,08	0,19	0,08	0,08	0,00	0,00	0,05	0,06	0,08	0,11	0,05	0,08	0,00	0,08	0,00	0,09	0,01	0,09	0,12	0,08
QRS_6	SKB	0,13	0,32	0,31	0,35	0,50	0,35	0,15	0,35	0,35	0,34	0,00	0,31	0,24	0,30	0,29	0,26	0,35	0,02	0,35	0,01	0,21	0,01	0,17	0,21	0,18
	DKB	0,22	0,05	0,03	0,16	0,34	0,16	0,21	0,16	0,16	0,18	0,00	0,11	0,09	0,17	0,06	0,09	0,16	0,02	0,16	0,01	0,16	0,02	0,16	0,04	0,01
QRS_7	SKB	0,14	0,11	0,13	0,35	0,47	0,35	0,10	0,35	0,35	0,01	0,00	0,28	0,21	0,34	0,07	0,24	0,35	0,01	0,35	0,00	0,36	0,01	0,37	0,11	0,08
	DKB	0,22	0,10	0,13	0,15	0,32	0,15	0,22	0,15	0,15	0,01	0,00	0,07	0,03	0,16	0,08	0,12	0,15	0,02	0,15	0,01	0,17	0,01	0,18	0,09	0,06

Veri setleri için regresyondaki uyum kalitesini değerlendirmek regresyon modellerinin oluşturulması bakımından büyük öneme sahiptir. Ayrıca gerçek ve tahmin edilen değer arasında bir uyumun var olup olmadığını hesaplamak veri seti ile kolayca uyum sağlayan regresyon tahminlerinin kullanılmasına olanak sağlar. Ancak bazen yüksek tespit edilen korelasyon değerine rağmen kabul edilen analitik ya da istatistiksel bir ifade ile uygun regresyon modelleri oluşturulamamakta ya da tek bir ifade yetersiz kalabilmektedir. Bunun yerine veri gruplarında özellik çıkarımı yapmayı tercih eden veya çoklu muhtemel çözümleri (pek çok analitik ifadeyi birlikte kullanan) deneyen araştırmacı vardır. Bu direkt olarak temel bir yöntemin kullanımını araştırmacıya sağlamak yerine yalnızca regresyon tahmin modelinin doğruluğunu tahmin etmede değişken hakkında bir ipucu vermektedir. Aksi takdirde burada elde edilen sonuçlar direkt olarak bir yöntem dahilinde değerlendirilerek regresyon modellerini tek bir değişken üzerinden hesaplamak kişiyi yanıltacaktır. Bu uygulamada ise istatistiksel pek çok formül özellik ya da değişken olarak veri setinde kullanılmıştır.

**Tablo 4.5.** Minimum sürede DKB tespit modeline dayalı özelliklerin korelasyon düzeyi sıralaması değerleri.

<i>Ham</i>	<i>Üst Örneklenmiş</i>	<i>QRS1</i>	<i>QRS2</i>	<i>QRS3</i>	<i>QRS4</i>	<i>QRS5</i>	<i>QRS6</i>	<i>QRS7</i>
14	14	21	21	21	21	21	21	21
8	4	25	25	19	25	19	25	25
4	8	19	19	7	19	25	19	19
9	9	16	10	20	3	2	16	3
7	7	1	16	17	9	11	12	5
20	20	13	3	18	7	24	5	12
21	21	3	24	22	20	3	7	9
10	10	14	5	9	17	5	20	7
12	12	5	23	12	18	12	17	20
6	6	9	14	16	22	7	18	17
16	13	12	12	25	12	20	22	18
5	5	17	9	2	5	17	3	22
3	11	18	7	14	14	18	9	23
11	16	22	20	13	10	22	14	10
25	3	7	17	5	16	1	13	24
13	17	20	18	10	11	9	10	2
17	18	10	22	23	24	23	11	11
18	22	23	13	3	23	13	24	14
22	24	24	1	24	1	14	2	1
24	25	2	8	1	2	10	23	13
1	19	8	11	11	13	4	8	8
19	15	4	2	8	8	6	4	16
15	23	15	4	4	6	8	1	4
2	2	11	6	15	4	16	6	6
23	1	6	15	6	15	15	15	15

Tablo 4.6 ve Tablo 4.6’de EKG ve DKB/SKB arasındaki en iyi korelasyon hesabı ham ve üst örneklenmiş sinyal için 14 numaralı özellik olurken, QRS1, QRS2 ... QRS7 için en iyi korelasyon düzeyi 21 numaralı özellik için ölçülmüştür. Bu demek oluyorki merkezi moment ile ham ve üst örneklenmiş EKG sinyalleri ile DKB arasındaki ilişkiyi ya da tanımlanabilecek analitik ifadeyi en iyi açıklayacak özelliklerden ilkinin merkezi moment olduğudur. Aynı şekilde QRS1, QRS2 ... QRS7 frekans bantlarındaki EKG sinyalleri ile DKB/SKB arasındaki ilişkiyi en iyi açıklayacak özelliklerden ilkinin şekil faktörü olduğudur.

**Tablo 4.6.** Minimum sürede SKB tespit modeline dayalı özelliklerinin korelasyon düzeyi sıralaması değerleri.

<i>Ham</i>	<i>Üst Örneklenmiş</i>	<i>QRS1</i>	<i>QRS2</i>	<i>QRS3</i>	<i>QRS4</i>	<i>QRS5</i>	<i>QRS6</i>	<i>QRS7</i>
14	14	21	21	21	21	21	21	21
8	4	13	5	17	17	24	7	3
4	8	14	3	18	18	11	20	5
9	9	17	12	22	22	2	17	7
7	7	18	10	7	7	1	18	20
20	20	22	17	20	20	23	22	17
21	21	7	18	9	9	14	9	18
10	10	20	22	14	3	7	16	22
12	12	12	7	12	12	20	24	9
6	6	9	20	2	5	17	14	12
16	13	5	9	10	23	18	23	14
5	5	3	14	16	24	22	12	10
3	11	10	13	1	14	10	11	13
11	16	1	24	13	11	13	10	25
25	3	23	25	5	10	9	13	23
13	17	24	1	19	2	12	5	24
17	18	2	23	3	13	19	2	2
18	22	25	19	23	16	25	1	19
22	24	11	16	24	25	5	3	1
24	25	19	8	25	19	3	19	11
1	19	16	2	11	1	6	25	16
19	15	6	11	8	8	8	8	8
15	23	8	4	4	4	4	6	4
2	2	15	6	15	6	15	4	6
23	1	4	15	6	15	16	15	15

Bu özellikleri tanımlamak gerekirse merkezi moment, rastgele bir değişkenin ortalamaya göre momenti alınarak hesaplanırken, şekil faktörü ise değişkenin diğer değişkenlerden bağımsız bir büyüklük ile tanımlanmasıdır.



## 5. YAPAY ZEKÂ ALGORİTMALARI VE PERFORMANS DEĞERLENDİRME KRİTERLERİ

### 5.1. Yapay Zekâ Algoritmaları

Dünya etrafında bilgisayarlar her gün sürekli olarak 2,5 quintrilyon veri yakalayıp depolamaktadır (2,5 kentrilyon = 2500 katrilyon) [98]. Hastaneler, bilimsel labratuvarlar, bankalar vb. pek çok yer veri depolayan bilgisayarlara sahiptir. Bilim, bilgisayarların muazzam miktarlarda veri depolamasından yararlanmaktadır. İlk olarak biyolojide DNA birimlerinde genleri analiz etmekle başlayan süreç astronomide dijital teleskopların kullanımı ile kapsamlı bir hal almıştır [99]. Depolanmış verilerdeki bu büyük patlama iyi bilinmektedir ancak bu tür veri depolarının faydalı bir şekilde kullanımı herkesi zorlayan kısımdır. Çok boyutlu ve karmaşık veriler ile insan faydalı bilgi çıkarımı yapamayacaktır. Basite indigeyebildiğimiz durumlarda tablo ve grafiklerle verileri analiz edebilirken karmaşık ve büyük verisetlerinde insan becerisi yetersiz kalmaktadır [98, 99]. Örneğin iki boyutlu bir veri setini grafik üzerinde gözlemlemek ve çıkarımlar yapmak kolayken, bu durum üç, dört ve daha büyük boyutta veri setleri için daha zorlu hale gelmektedir. Öyleyse öncelikle yapılması gereken iki şey vardır. İlki veri seti boyutunu azaltmak (bizim beynimiz problemle başa çıkabilene kadar), ikincisi ise yüksek boyutlu problemlerin zor olmadığını bilen bilgisayarları kullanmaktır ve büyük veri dosyaları ile ilgilenirken sıkılmamaktır. Aslında makine öğrenme algoritmaları ile veri setleri analiz edilir. Yazılım programlarının çoğunda bu algoritmalar kullanılmaktadırlar. Biyometrik tanımlama, hastalık tespiti, istenmeyen e-posta gibi sistemlerin çoğunda makine öğrenme tekniklerinden yararlanılmaktadır.

Çalışmada yer alan EKG ve kan basıncı verileri bahsedilen veri depolarının yalnızca çok küçük bir kısmıdır. Makine öğrenme teknikleri kullanmadan bu verilerden anlamlı ifadeler bulmak ne yazıkki çok zordur. Bu nedenle bir makinenin verileri öğrenmesi gereklidir. Öğrenme tecrübelerle gerçekleşebilir. Öğrencileri yeni koşullara uyum sağlamaya ve yeni problemler için çıkarımlar ile çözümler sunmaya teşvik eder.

Öğrenme sürecinin insandan farklı olabileceği düşünülemez. Bu süreç hatırlama, uyum sağlama ve genelleme olarak ayrılabilir.

Şu şekilde özetlenirse insanın yaşadığı son olay (veri) hatırlanır, bu olay sonucu gerçekleşen durum bilinir (hatırlama). Ancak bu olay tekrar yaşandığında aynı duruma rastlanılmaz, tekrar denenir ve aynı durumla sonuçlanır (her olaya karşı uyum sağlama) [98]. Bu durumda rastlanılan olaylara karşı benzerlik ve farklılıklar değerlendirilerek genelleme yapılır ve bir karar verilir. Yapay zekâ için öğrenme sadece bu tanımla değerlendirilemez ve muhakemede bulunma, mantıksal çıkarımlarda bulunma gibi teknikler kullanılmaktadır. Öğrenme sürecinde verisetinde girdiler bulunmaktadır. Bu girdiler özellik olarak nitelendirilmektedirler. Öğrenilmesi istenen soruya yönelik en yakın araştırma soruları denebilir. Bu çalışmadaki sorun ise en genel anlamı ile EKG ile kan basıncını tespit edebilmektir. Öyleyse EKG sinyali girdileri gereklidir (girdi=özellik). Bu girdiler işaret ve görüntü verilerinde ne yazıkki yoktur, bu sebeple istatistiksel 25 adet girdili bir EKG ve kan basıncı veri seti oluşturulmuştur. Burada kullanılan özelliklerin belirlenmesi de probleme en iyi çözümü sunması bakımından çok önemlidir. Peki bilgisayar EKG ve kan basıncı arasındaki ilişkiyi bu 25 girdi bakımından değerlendirerek bize nasıl bir tespit sunar? Bu tür sorulara farklı muhtemel cevaplar verilebilir, bu da farklı makine öğrenme tekniklerinin kullanımını gerektirir. EKG verisetinde özelliklere ait farklı kan basıncı tespitleri farklı cevaplar sunar. İşlenen verisetinde karşılaşılan farklı cevaplar farklı algoritmaları kullanmak için bir yol sunacaktır.

Denetimli öğrenme: Cevaplı ya da etiketli bir eğitim seti için algoritmalar tüm muhtemel girişlere düzgün bir şekilde cevap verir.

Denetimsiz öğrenme: Doğru ya da etiketli cevaplar elde edilememektedir. Algoritma veriseti girdileri arasındaki benzerlikleri değerlendirerek ortak girdileri kategorileştirir.

Pekiştirmeli öğrenme: Çevresine duyarlı bir öğrenme tekniği olan bu algoritma yapılan hatalardan dolayı cezalandırma ve doğru yapılanlar için ödüllendirme mekanizması ile çalışmaktadır.

Üç tür makine öğrenme sınıfına göre algoritmaların veri seti parametrelerine bağlı olarak seçilmesi gereklidir. Verisetinde her bir kişiye ait EKG işaretine karşılık kan basıncı değeri vardır. Bu da denetimli bir mekanizmanın mevcut olduğunu gösterir.

EKG ve kan basıncı verilerinden daha doğru çıkarımlar yapabilmek ve aralarındaki korelasyon düzeyine göre EKG ile kan basıncını tespit edebilmek için makine öğrenme algoritmalarının yapısal uygunluğu değerlendirilmelidir.

Çalışmada kullanılan makine öğrenme algoritmaları Topluluk Karar Ağacı, Karar Ağacı ve Gauss Süreç Regresyonu olmak üzere üç adettir. Bu modeller iyi bir performansa, basit bir yapıya ve regresyon problemlerinde yaygın bir kullanıma sahiptir [100].

## **5.2. Topluluk karar ağacı algoritması: sistolik ve diyastolik kan basıncı tahmini**

Sınıflandırma ve regresyon ağaçları (CART) Breinman et. al. ve diğerleri tarafından geliştirilen makine öğrenme teknikleridir [101]. Veri setindeki eğitim örneklemindeki değişim, söz konusu teknikte bir dengesizliğe neden olur [102]. Bu nedenle çalışmada topluluk karar ağacı (TKA) tekniği tercih edilmiştir. Ayrıca çalışma verilerinin çıktı değerlerinin doğrusal olmayan yapısı bu yöntemin kullanılmasında için iyi bir neden sunmuştur. Tek bir karar ağacı yapısından türetilen performans değerini artırmak için birkaç karar ağacı yapısı birleştirilerek oluşturulmuştur [103]. Topluluk karar ağacı algoritması için dört yöntem vardır: güçlendirme (bagging), rastgele orman (random forest), yükseltme (boosting), uyarlanabilir (adaboost) [102]. Çalışmada SKB ve DKB tahmini için TKA kullanıldı. Bu model, bootstrap adlı istatistiksel bir yöntemle dayalı olarak tasarlanmıştır [101, 104].

Topluluk karar ağacı oluşturulmadan önce tek bir karar ağacı algoritma modelinin nasıl oluşturulduğu ve nasıl topluluk halinde kullanıldığı anlaşılmalıdır. Tek bir ağaç yapısı regresyon problemlerinde entropi değerinin düşük, bilgi kazancının yüksek olması koşulu ile tasarım gerçekleştirilir. Topluluk karar ağacı regresyon algoritmasında ise pek çok karar ağacı yapısı belirli koşullar altında bir araya getirilerek oluşturulur. Uygulamada veri seti için uygun olan güçlendirme (bagging) tekniği kullanılmıştır.

Güçlendirme algoritmasının kullanımının sebebi karar ağaçlarının yüksek varyansa sahip modeller olmasıdır. Eğitim veri setindeki küçük bir değişim tamamıyla farklı bir karar ağacı modeli ile sonuçlanır. Bu durumu engellemek için topluluk karar ağaçlarından yararlanır.

Güçlendirme algoritmasında örnek sayısı  $n$  olan bir veri setinde yine örnek sayısı  $n$  olan bir veri seti kullanılır.  $n$  adet  $x_1, x_2 \dots x_n$  gözlemcileri için tüm veri noktalarının ortalaması  $(x_1 + x_2 + \dots + x_n)/n$ 'dir ve ortalamanın varyansı  $\sigma^2/n$ 'dir. Bu denklemler doğrultusunda eğer veri noktalarının sayısını artırılırsa ortalama varyans azalır. İstenen durumda veri setinde yanlılık ve varyansın azaltılmasıdır. Bu durumda güçlendirme algoritması bootstrapping ve aggregation olmak üzere iki adımla modeli oluşturur. Önyükleme algoritması alt veri setleri oluşturmayı amaçlamaktadır. Normalde hedef varyansın azaltılması buna bağlı olarak  $n$  adet gözlemci sayısının artırılmasıdır. Bu durumda şu an sadece tek bir eğitim modeli var. Çoklu karar ağacı setlerini oluşturmak gereklidir. Eğitim veri setinden bootstrapped örnekleri alınarak çoklu ağaç yapıları oluşturulur. Eğitim veri setinden rastgele veri noktaları seçilir, bir veri tekrardan kullanılabilir. Bu durumda  $n$  adet alt veri kümesi ve eğitim setinde  $n$  adet veri noktası bulunmaktadır. Bu durumda veri setinde her defasında bir önyükleme örneğinde özel bir veri noktasını seçme olasılığı  $1/n$ , seçmeme olasılığı ise  $1-1/n$ 'dir. Önyükleme örneğinde seçilmeyen her noktanın olasılığı  $(1 - \frac{1}{n})^n$ 'dir. Bu metot ayrıca 0,632 önyükleme olarak bilinmektedir. Bu değer her bir önyükleme örneğinde özel bir veri noktasının seçilme olasılığını gösterir. Önyükleme örnekleri oluşturuldu ve her bir önyükleme örneği için karar ağacı yapısı oluşturulmuştur. Regresyon ağacından alınan tahminlerin tümünün ortalamasından hedef değer hesaplanır ve çıkış değeri tahmin edilir.

Güçlendirme algoritmasında, EKG sinyal eğitim veri setinden birçok önyükleme örneği alınır. Her örnek için regresyon modeli gerçekleştirilmiş, oluşturulan bootstrap örnekleri birleştirilmiş ve model son halini almıştır. Güçlendirme tahmincisi, bu regresyon modelinin ortalaması alınarak belirlenir. Ortalama değer ve varyansın düşük olması istenir. Bu nedenle sistolik ve diyastolik kan basıncı tahminini gerçekleştirecek algoritma yapısının yüksek doğruluk oranı ile çalışması hedeflenmiştir. Buna göre, TKA her bir epoklanmış ve alt frekans bantlarına ayrılmış EKG sinyalleri üzerinde uygulanarak doğruluğu değerlendirilmiştir.



### 5.3. Karar ağacı: sistolik ve diyastolik kan basıncı tahmini

CART için geliştirilmiş birçok özgün yapı vardır [105, 106]. Bu yapılardan biri olan TKA, detaylı olarak anlatılmıştır. TKA'de incelenen karar ağacı yapısı, bu model için tek bir karar ağacı kullanılarak uygulanmaktadır.


Model, karar ağacının bölünmüş sayısı ile derinlik kontrolü yapılarak tasarlanmıştır. Ayrıca yazılım ortamındaki belirli bölme sayıları için karar ağacı performans değerlerine göre (en iyiden en kötüye) ince, orta ve kaba olarak ayrılır. Model tasarımı için veri setine uygunluğu ile makul bir tahmin doğruluk oranı sergileyen bir Karar Ağacı (KA) algoritması uygulanmıştır.

$$Entropi(T) = - \sum_{i=1}^c P(x_i) \log_b P(x_i) \quad (5.1)$$

$$Bilgi Kazancı = Entropi(T) - \sum_{v \in A} \frac{|T_v|}{T} * Entropi(T_v) \quad (5.2)$$

Kan basıncı sütun vektörünün ne kadar karmaşık olduğunu entropi ile test ederiz (5.1). Burada net bir etiket değeri yok. Regresyon problem mevcut. Bu durumda veri setindeki benzerlikler ve farklılıklar entropi ile tespit edilir. Bulunan entropi değeri ile bilgi kazancına artık ulaşılabilir. Bilgi kazancı sorulan sorunun önemi üzerine bir değer vermektedir. Yani sorulan soru ile bir bilgi edinimi sağlanıyorsa entropiyi düşürmesi bakımından değerlidir. Bilgi kazancı formülünde (5.2), T hedef değer, A test ettiğimiz değişken ya da sütun, v A'daki her bir değerdir.

Karar ağacı algoritması EKG ve KB verilerinin %5'i için Şekil 5.1'de gösterilen ağaç yapısına bakılır. Regresyon modelinde doğru cevap diye nitelendirebileceğimiz sabit bir değer olmadığı için kan basıncı değerleri arasında sorular sorularak ağaç oluşturulur. Herhangi x1 değişkeni 20,0328 kan basıncı değerinden büyük mü, küçük mü? Sorusu ile doğru sınıflar bir arada tutularak saf bir düğüm oluşturulana dek döngü devam eder. Bu KB değerinin belirlenmesindeki en önemli faktör ise KB verilerinde en büyük değişimin 20,0328'de meydana gelmesidir. Buradaki amaç karar ağacını oluştururken bölünecek en iyi değişkenleri bulmaktır. Karar ağacı yapısı denklem (5.2'de verilen bilgi kazancına göre dallara ayrılır. Burada ağacın çok fazla bölünmesi algoritmanın ancak bu şekilde daha iyi öğrenebildiği göstermektedir.



**Şekil 5.1.** Kan basıncı test verisi üzerinde karar ağacı yapısı örneği.

Ampirik kanıtlar, doğru, adım adım bir karar ağacının, tüm eğitim veri setinin test edildiği ve yapılandırıldığı bir modelden daha hızlı olduğunu belirtir. Ancak, yinelemeli olarak tasarlanmış bir ağacın nihai modeline, eğitim setinin tamamı kullanılmadan ulaşılamaz [107]. Bu çelişiklere ek olarak, model tasarımı açık, basit ve yüksek doğruluk oranına sahip olmalıdır. Bu çalışma, bölme sayısını minimumda tutarak istenilen hedeflere ulaşmıştır. Her bir epoklanan sinyal için sistolik ve diyastolik kan basıncı tahmin modelleri oluşturuldu. En yüksek performans oranı 11'inci özellik grubunda elde edilmiştir. Ancak KA performansının kullanılan diğer TKA ve GSR modellerinin performanslarına göre düşük olduğu gözlemlenmiştir. Bu durum kullanılan veri setinin algoritmaya tam olarak uymaması ile açıklanabilir.

#### **5.4. Gauss süreç regresyonu: sistolik ve diyastolik kan basıncı tahmini**

Gauss süreç regresyonu doğrusal algoritmalar için Bayes ve klasik istatistiksel yöntemlerini kullanan bir algoritmadır. Ancak doğrusal olmayan algoritmalarda bir fonksiyona ihtiyaç duyan algoritma bu analitiği yapamamaktadır. EKG'de giriş parametreleri lineer olmadığı ve birden fazla olduğu için bu algoritma ile sistolik ve diyastolik kan basıncı tahmini yapılmıştır.

Normalde düşünüldüğünde birinci, ikinci ya da üçüncü dereceden bir eğrinin çözümleri analiz edilebilmektedir (Eğri kapalı fonksiyonel bir formüle dönüştürülür). Ancak her veri kesin bir değer sunmamakla birlikte girdilere göre formüle edilir bir yaklaşımda da bulunulamaz. Bu durumda problemi analitik olarak çözmek yerine mevcut veriler ve gözlemlerden yararlanır.

Enterpolasyon ve regresyon teknikleri ile veri noktaları arasında kalan boşluklar doldurulur ve bir kez tamamladıktan sonra diğer çalışmada kullanılacak fonksiyon temsili olarak oluşturulur [108]. EKG grafiği üzerinde veri noktalarının GPR'nin KB verileri ile tahmin ettiği fonksiyonda kesişim noktaları bize modelin ne kadar iyi çalıştığını gösterir.

GPR'de önce bir ortalama fonksiyon ve kovaryans fonksiyonu kullanılarak belirtilebilen gauss süreci varsayılır. Daha spesifik olarak, veri kümesi etiketlerinin herhangi bir grubu sonsuz boyutlu çok değişkenli bir Gauss dağılımı gibidir. Bu durumda ortalama ve kovaryans iile fonksiyonun uzayı hakkında ön bilgide bulunulabilir.

$$m(x) = E(f(x)), \forall x \in X (\text{ortalama fonksiyon}) \quad (5.3)$$

$$(x, x') = Cov(f(x), f(x')), \forall x, x' \in X (\text{kovaryans fonksiyonu}) \quad (5.4)$$

Gauss temel fonksiyonu, ortalaması (5.3) ve kovaryans (5.4) işlevi ile tanımlanır [29]. Girdi değişkenlerinin GSR kovaryansı, çekirdek veya kovaryans fonksiyonu olarak adlandırılır. Ortalama işlevin ve çekirdek işlevinin birlikte kullanılması GSR'yi ifade eder. Ortalama ve kovaryans fonksiyonu model seçimi sırasında seçilir ve ayarlanır. Ortalama fonksiyon genelde sabit, 0 ya da eğitim veri kümesinin ortalamasıdır. Kovaryans çekirdek fonksiyonu ise fonksiyonun düzgünlüğünü kodlayan radyal çekirdeğe sahip sabit çekirdeğin bileşimidir. Bu çekirdeğin hiperparametreleride değerlendirildikten sonra EKG verilerine bağlı olarak KB tahmin fonksiyonu oluşturulabilecek ve çıkarımlar yapılabilir.

### 5.5. Doğrulama Teknikleri: Hold-out Doğrulama

Doğrulama, oluşturulan üç yöntemde dair makine öğrenme modellerini değerlendirmek ve test etmek için kullanılan bir yöntemdir. Spesifik tahmine dayalı modellemeler için uygun modelin seçilmesi ve karşılaştırılmasında kullanılır. Doğrulama yöntemi, eğitim ve test verileri için verileri rastgele bölen bir yöntemdir. Doğrulama yöntemi uygulamasının kolay olması ve düşük yanlılık göstermesi, en iyi modeli seçme bakımından güçlü bir araçtır.

Bir modeli doğrulamak için pek çok farklı teknik kullanılmaktadır. Bu tekniklerin tümü benzer algoritma üzerine oluşturulmuştur.

1. Veri seti eğitim ve test olmak üzere iki kısma ayrılır.
2. Eğitim veri seti eğitilir.
3. Test veri seti doğrulanır.
4. Tüm bu adımlar kullanılan çapraz doğrulama tekniklerine göre tekrarlanır.

Hold-out (bekletme), k-kat (k-fold), tekrarlanan k-kat, zaman serisi gibi pek çok çapraz doğrulama yöntemi kullanılmaktadır. Bu uygulamada ise en yaygın ve kullanımı basit olan hold-out tekniği kullanılmıştır (Hold-out teriminin tam karşılığı bulunamamıştır.). Model performanslarını değerlendirmek için veri seti %80 eğitim ve %20 test olmak üzere iki kısma bölünmüştür (Tablo 5.1). Her iki uygulama sürecine ilişkin eğitim ve test verileri Tablo 5.1'e göre bölünmüştür.

**Tablo 5.1.** Eğitim ve test veri seti dağılımı.

Veriseti	Eğitim (%80)	Test (%20)	Toplam
Diyastolik	9925	2481	12406
Sistolik	9925	2481	12406

## 5.6. Performans Değerlendirme Kriterleri

Her bir makine öğrenme modellerinin performanslarını değerlendirmek için yedi adet değerlendirme kriteri kullanılmıştır. Bunlar, ortalama mutlak yüzde hatası (MAPE-OMYH), ortalama mutlak hata (MAE-OMH), standart hata (SE-SH), ortalama karesel hata (MSE-OKH), kök ortalama karesel hatası (RMSE-KOKH), R ve  $R^2$  olmak üzere yedi adettir [100].

$$OMYH = \frac{1}{n} \sum_{i=1}^n \frac{|t_i - y_i|}{t_i} \times 100 \quad (5.5)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |t_i - y_i| \quad (5.6)$$

$$SH = \sqrt{\frac{\sum_{i=1}^n (t_i - y_i)^2}{n - 2}} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n - 2}} \quad (5.7)$$

$$OKH = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (5.8)$$

$$\text{KOKH} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (5.9)$$

$$R = 1 - 6 \sum_{i=1}^n \frac{d_i^2}{n(n^2 - 1)} \quad (5.10)$$

$t_i$ : gerçek değer,  $y_i$ : regresyon modelinden tahmin edilen değer,  $e_i = (t_i - y_i)$ : hata değeri ve  $n$  veri sayısıdır. Ortalama karesel hata, kareleri alınan hataların ortalamasını ölçer. Tahmin edilen değer ile gerçek değer arasındaki fark hesaplanır, sonuçların karesi alınır ve toplam veri sayısına bölünerek ortalaması hesaplanır. Hataların karesi alındığı negatif değere rastlanılmaz. Kök ortalama karesel hata, hataların karelerinin ortalaması hesaplanarak karekökü alınır. Ortalama mutlak hata hataların mutlak toplamını hesaplayarak ortalamasını bulur. Tahminlerin gerçek değerden ne kadar uzak olduğuna dair bir ölçü verir. Ancak bununla birlikte hatanın mutlak değeri alındığı için hatanın yönü hakkında bilgi edinilemez. Aynı zamanda OKH türevlenebilirken OMH türevlenemezdir. Ortalama mutlak yüzde hatası gerçek ve tahmin edilen değerler arasındaki hatayı gerçek değere bölerek hatayı yüzdelik olarak hesaplar. Standart hata, kareleri alınmış hataların toplamını ifade eder.  $R^2$  hedef değişkenin varyansının gözlemlenen değişkenin varyansını ne ölçüde açıkladığını belirtir. Eğer regresyon modeli hedef değişkenin varyansını yakalayabiliyorsa  $R^2$  değeri 1'e yakın olur ancak herhangi bir varyans değerini yakalayamazsa  $R^2$  değeri 0 olarak hesaplanır. Yani bir modelin  $R^2$  değeri %65 ise bu gözlemlenen varyasyonun yaklaşık %65'i modelin özellikleriyle açıklanabileceğini gösterir.  $R^2$  aralığı (0,1) olarak tanımlanır ancak regresyon doğrusunun hata karelerinin ortalamaya oranı 1 değerini geçebilir. Bu durumda aralık  $(-\infty, 1)$  olarak yeniden tanımlanabilir. Kullanılacak metrikler ve ifadeleri incelenmiş ve uygulama süreci için modeller oluşturulmuştur. Uygulama süreci iki safhada gerçekleştirilmiştir. İlk kısmı, kan basıncı minimum süre tahminine dair uygulama süreciyken, diğeri alt frekans bantlarında belirlenen süre için tasarlanan modele dair uygulama sürecidir. İlk uygulama için 660 model, ikinci uygulama için 594 model oluşturulmuştur. Toplam 1254 model için performans değerlerine bağlı olarak modeller değerlendirilmiştir.



## 6. SONUÇLAR

### 6.1. Diyastolik ve Sistolik Kan Basıncı Minimum Süre Tespiti Modeline Dayalı Sonuçlar

Çalışmanın temel amacı, EKG sinyalleri ile yapay zekâ algoritmalarına dayalı olarak SKB ve DKB tahminini minimum sürede gerçekleştiren ve uygun olan frekans aralığını tespit edebilen modeller oluşturmaktır. Bu amaç doğrultusunda uygulama adım adım Şekil 4.1'de verilen akış şemasına göre gerçekleştirilmiştir. İlk olarak, IEEE açık kaynaklı veri paylaşım platformundan EKG ve KB veri seti alınmıştır. Toplamda beş kişiden alınan EKG ve KB verileri kullanılmıştır. Daha sonra, sinyaller, epoklama işlemi için 2'den başlayarak, iki saniyelik aralıklarla 20'ye kadar epoklanmış olarak edilmiştir. Veri seti girdi (özellik) bilgisi içermediği için zaman alanında 25 adet öznitelik çıkarımı yapılmıştır. Boyut optimizasyonunu sağlamak için sonraki adımda özellik seçimi yapılmıştır. Seçilen 11 özellik seti farklı makine öğrenimi algoritmalarına dayalı performans değerlendirmesi yapılmıştır. Her yapılan işlem, hedeflenen her bir süre için gerçekleştirilmiştir. Son olarak, SKB ve DKB'nin tahminini en kısa sürede en iyi performans oranıyla gerçekleştiren algoritma sayısal olarak ifade edilmiştir.

Çalışmanın ilk bölümünde, her epoklanmış sinyal için SKB modelleri hazırlanmıştır (Tablo 6.1-Tablo 6.20). EKG sinyal giriş bilgisi olarak 225 adet özellik çıkarımı yapılmıştır. Özellik vektörünün boyutunu küçültmek ve gereksiz özelliklerin iş yükünden kurtulmak için özellik seçimi yapılmıştır. Her bir özelliğin korelasyonu Spearman yöntemiyle hesaplandı ve en yüksek korelasyon seviyesinden en düşük korelasyon seviyesine doğru özellikler sıralanmıştır. Özellik vektörleri bu sıralamaya göre %5 aralıklarla seçilmiştir. Başlangıçta 25 özelliğin %5'i (tam sayılara yuvarlanır) 1'e, %10'dan 3'e, %15 dördüncü özellik vektörüne, %50'ye kadar aynı aralıklarla alınarak devam edilir. Son olarak 25. sütunun özellik vektörü %100 alınarak elde edilmiştir. EKG sinyali ile 11 grup oluşturulmuş ve 660 modelin performans değerlendirme tablosu üretilmiştir. Bu tablolara göre en iyi model koyu renk ile belirlenir.

Tüm özellik vektörleri (11 öge) kullanılarak oluşturulan model olan TKA, OMYH=2,58 ve R=0,97 SKB değerleriyle en iyi performans gösteren algoritma olarak belirlenmiştir (Tablo 6.11).

Çalışma süreci, diğer epoklanmış sinyaller için aynı şekilde devam etmiştir. 4 saniyelik epok için her bir algoritmanın performansı değerlendirilerek SKB tahmin modelleri oluşturulmuştur. EKG sinyali ile toplam 11 grup oluşturulmuş ve 33 modellik performans değerlendirme tablosu üretilmiştir (Tablo 6.12). Tüm özellik vektörleri kullanılarak oluşturulan model için, TKA, OMYH=2,34 ve R=0,97 SKB değerleriyle en iyi performans gösteren algoritma olmuştur. 6 saniyelik epoklanmış EKG sinyali için 25 özellik vektörü vardır. Bu özellik vektörlerinin korelasyon düzeyi yüksek sütunları %5 aralıklarla alınmış ve 11 özellik için performans değerlendirmesi yapılmıştır. 11'inci özellik grubu için OMYH=2,27 ve R=0,97 SKB değerleri ile en iyi performans gösteren algoritma TKA olarak belirlenmiştir (Tablo 6.13). Her bir zaman dilimine ait epoklanmış sinyaller için aynı işlemler yapılmıştır. 11'inci özellik vektörü en iyi performans gösteren grup olmuştur. Buna göre, GSR algoritması ile 8 saniyelik epok için OMYH=2,20 ve R=0,97 SKB değerleri belirlenmiştir (Tablo 6.14). 10 saniyelik epoklanmış EKG sinyaline göre OMYH=2,08 ve R=0,97 SKB değerleri TKA algoritması kullanılarak hesaplanmıştır. Yavaş yavaş artan performans değerleri, 12 saniyelik epoklanmış EKG sinyali için OMYH=2,04 ve R=0,98 olarak hesaplanmıştır (Tablo 6.15). Artan epoklama süreleri göz önüne alındığında, algoritmanın en iyi performansı her adımda değişmiştir. Artışın gözlemlendiği epoklama süreleri için GSR algoritması R değerini artırırken OMYH değerinde azalmaya neden olmuştur. 14 saniyelik epok için SKB, OMYH=2,00 ve R=0,98 olarak elde edilmiştir (Tablo 6.17). 16 saniyelik epok için, SKB değerleri OMYH=1,92 ve R=0,98 olarak elde edilmiştir (Tablo 6.18). 18 saniyelik epok için, SKB değerleri OMYH=1,97 ve R=0,98 olarak elde edilmiştir (Tablo 6.19). 20 saniyelik epok için, SKB değerleri OMYH=1,96 ve R=0,98 olarak elde edilmiştir (Tablo 6.20).

16. saniyeden önce R değeri pek değişmezken, OMYH değeri azaldı. 16. saniyeden sonra OMYH değeri düşerken R değeri düşer. OMYH mümkün olduğu kadar düşük ve R mümkün olduğunca yüksek olmalıdır.

Tüm bunlara göre EKG sinyali ve GSR algoritması kullanılarak KB tespitinin 16 saniyede yapılabileceği değerlendirilmektedir. SKB ve DKB için sırasıyla OMYH değerleri 1,92 ve 2,44 olarak tespit edilmiştir.



SKB için tanımlanan tablo modelleri DKB için de geçerlidir. Tüm süreç için tablolar ayrı ayrı modellenmiştir (Tablo 6.1-Tablo 6.10). Tüm özellik gruplarını kullanan modeller, her bir epok için en iyi performans değeri edilmiştir. Buna göre, TKA algoritması kullanılarak 2 saniye için OMYH=3,31 ve R=0,97 DKB elde edilmiştir (Tablo 6.1). 4 saniye için OMYH=3,17 ve R=0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.2). 6 saniye için OMYH=3,14 ve 0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.3). OMYH=3,1 ve 8 saniye için R=0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.4). 10 saniye için OMYH=2,69 ve R=0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.5). 12 saniye için OMYH=2,88 ve R=0,97 DKB değerleri GSR algoritması kullanılarak elde edilmiştir (Tablo 6.6). 14 saniye için OMYH=3,28 ve R=0,98 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.7). 16 saniye için OMYH=2,44 ve R=0,98 DKB değerleri GSR algoritması kullanılarak elde edilmiştir (Tablo 6.8). 18 saniye için OMYH=2,49 ve R=0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.9). 20 saniye için OMYH=2,37 ve R=0,97 DKB değerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.10).

DKB tahmini için oluşturulan modellerin performans tabloları dikkatle incelenmelidir. Artan her epok süresi için OMYH'deki hem düşüşler hem de artışlar birlikte gözlemlenmiştir ve en düşük OMYH değeri Tablo 6.10'da elde edilmiştir. Buna göre, R değeri dikkate alındığında, Tablo 6.7 ve Tablo 6.8 maksimum değer elde edilmiştir. OMYH'nin mümkün olduğu kadar düşük ve R'nin yüksek olması arzu edilir. Tüm bunlara göre EKG sinyali ve GSR algoritması kullanılarak DKB tespitinin istenilen minimum sürede 16 saniyede yapılabileceği değerlendirilmektedir. 20 saniye için 0,07 OMYH düşüşü çok önemli değildir. Ayrıca tablolarda OKH'nin aşırı yüksek değerlerine rastlanmaktadır. DKB minimum süre tespit GSR modellerine ait OKH değerleri Tablo 6.7 ve Tablo 6.8'de aşırı yüksek tespit edilmiştir. GSR'nin 14 ve 16 saniyede ilk 9 düzeye ait değerlerinin bu denli yüksek olması süre ve veriselerine uygun modelin geliştirilememesi ya da GSR algoritmasının bu veriseleri için iyi bir makine öğrenme tekniği olmaması ile ilişkilendirilebilir.

Tüm sürecin özetlendiği Tablo 6.21'e göre, minimum süre tayini için 16 saniye uygun kabul edilir. 11 özellik grubuna ait GSR algoritmasının EKG veri seti ile iyi uyum sağladığı, SKB ve DKB zaman tespiti için uygun olduğu değerlendirilmektedir.

**Tablo 6.1.** 2-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,43	6,18	8,32	69,21	8,32	0,62	0,39
			GSR	7,31	5,32	7,10	50,40	7,10	0,66	0,44
			TKA	7,69	5,62	7,52	56,61	7,52	0,64	0,41
2	3	10	KA	6,47	4,80	7,25	52,54	7,25	0,79	0,62
			GSR	6,99	5,10	6,88	47,33	6,88	0,73	0,53
			TKA	5,53	4,06	6,03	36,37	6,03	0,83	0,69
3	4	15	KA	6,16	4,56	7,00	48,97	7,00	0,81	0,66
			GSR	5,98	4,38	6,21	38,52	6,21	0,82	0,67
			TKA	5,22	3,85	5,77	33,30	5,77	0,85	0,73
4	5	20	KA	6,16	4,56	7,00	48,97	7,00	0,81	0,66
			GSR	5,96	4,36	6,19	38,34	6,19	0,82	0,67
			TKA	5,25	3,86	5,80	33,59	5,80	0,85	0,73
5	6	25	KA	6,17	4,56	7,02	49,30	7,02	0,81	0,66
			GSR	5,89	4,31	6,16	37,93	6,16	0,82	0,68
			TKA	5,25	3,86	5,78	33,40	5,78	0,85	0,73
6	8	30	KA	6,19	4,57	7,04	49,48	7,03	0,81	0,66
			GSR	5,99	4,39	6,21	38,56	6,21	0,81	0,66
			TKA	5,26	3,86	5,81	33,69	5,80	0,85	0,73
7	9	35	KA	5,65	4,17	6,55	42,94	6,55	0,85	0,72
			GSR	5,58	4,09	5,95	35,36	5,95	0,84	0,70
			TKA	5,01	3,68	5,57	31,07	5,57	0,87	0,76
8	10	40	KA	5,26	3,90	6,20	38,44	6,20	0,87	0,76
			GSR	5,07	3,73	5,49	30,13	5,49	0,88	0,77
			TKA	4,58	3,38	5,20	27,08	5,20	0,90	0,81
9	11	45	KA	5,26	3,89	6,20	38,39	6,20	0,87	0,76
			GSR	4,93	3,63	5,39	29,02	5,39	0,88	0,78
			TKA	4,60	3,39	5,20	27,03	5,20	0,90	0,81
10	13	50	KA	4,15	3,11	5,20	27,06	5,20	0,95	0,90
			GSR	3,65	2,68	4,31	18,57	4,31	0,96	0,92
			TKA	3,50	2,58	4,26	18,16	4,26	0,96	0,92
11	25	100	KA	4,06	3,03	5,23	27,33	5,23	0,95	0,91
			GSR	3,56	2,61	4,21	17,70	4,21	0,96	0,92
			TKA	<b>3,31</b>	<b>2,43</b>	<b>4,06</b>	<b>16,52</b>	<b>4,06</b>	<b>0,97</b>	<b>0,93</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.2.** 4-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,92	5,75	7,89	62,24	7,89	0,63	0,40
			GSR	7,10	5,11	6,87	47,21	6,87	0,65	0,43
			TKA	7,40	5,34	7,27	52,86	7,27	0,64	0,41
2	3	10	KA	4,87	3,53	5,57	31,06	5,57	0,92	0,85
			GSR	5,00	3,56	5,34	28,54	5,34	0,90	0,82
			TKA	4,11	2,93	4,71	22,13	4,70	0,94	0,88
3	4	15	KA	4,69	3,39	5,44	29,59	5,44	0,93	0,86
			GSR	4,21	3,01	4,77	22,72	4,77	0,93	0,86
			TKA	3,97	2,83	4,55	20,67	4,55	0,94	0,89
4	5	20	KA	4,69	3,39	5,44	29,59	5,44	0,93	0,86
			GSR	4,17	2,98	4,74	22,41	4,73	0,93	0,86
			TKA	3,97	2,83	4,56	20,81	4,56	0,94	0,88
5	6	25	KA	4,68	3,37	5,47	29,93	5,47	0,93	0,86
			GSR	4,21	3,01	4,77	22,71	4,77	0,93	0,86
			TKA	3,98	2,84	4,57	20,91	4,57	0,94	0,88
6	8	30	KA	4,72	3,40	5,49	30,11	5,49	0,93	0,86
			GSR	4,20	3,00	4,75	22,59	4,75	0,93	0,86
			TKA	4,01	2,86	4,60	21,13	4,60	0,94	0,88
7	9	35	KA	4,60	3,34	5,39	29,04	5,39	0,93	0,86
			GSR	4,02	2,86	4,61	21,21	4,61	0,94	0,88
			TKA	3,92	2,79	4,53	20,53	4,53	0,94	0,89
8	10	40	KA	4,44	3,20	5,24	27,42	5,24	0,93	0,87
			GSR	3,84	2,73	4,45	19,83	4,45	0,94	0,89
			TKA	3,74	2,66	4,39	19,28	4,39	0,95	0,90
9	11	45	KA	4,44	3,20	5,24	27,42	5,24	0,93	0,87
			GSR	3,86	2,75	4,46	19,92	4,46	0,94	0,89
			TKA	3,74	2,67	4,40	19,32	4,40	0,95	0,90
10	13	50	KA	3,97	2,84	4,76	22,60	4,75	0,96	0,91
			GSR	3,42	2,42	3,99	15,92	3,99	0,96	0,93
			TKA	3,39	2,40	4,04	16,32	4,04	0,96	0,93
11	25	100	KA	3,76	2,68	4,74	22,41	4,73	0,96	0,92
			GSR	3,28	2,31	3,89	15,15	3,89	0,97	0,94
			TKA	<b>3,17</b>	<b>2,24</b>	<b>3,85</b>	<b>14,82</b>	<b>3,85</b>	<b>0,97</b>	<b>0,94</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.3.** 6-saniyelik epok için DKB tahmin sonuçları

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,74	5,50	7,71	59,44	7,71	0,65	0,42
			GSR	6,80	4,79	6,64	44,00	6,63	0,71	0,50
			TKA	7,18	5,07	7,06	49,84	7,06	0,67	0,45
2	3	10	KA	6,40	4,52	6,87	47,23	6,87	0,79	0,62
			GSR	6,94	4,89	6,67	44,52	6,67	0,70	0,49
			TKA	5,77	4,01	5,89	34,73	5,89	0,83	0,68
3	4	15	KA	6,40	4,51	6,87	47,11	6,86	0,79	0,62
			GSR	6,92	4,87	6,67	44,41	6,66	0,70	0,49
			TKA	5,71	3,99	5,90	34,74	5,89	0,83	0,68
4	5	20	KA	6,40	4,51	6,87	47,11	6,86	0,79	0,62
			GSR	6,89	4,85	6,66	44,34	6,66	0,71	0,51
			TKA	5,73	3,99	5,91	34,85	5,90	0,82	0,68
5	6	25	KA	6,41	4,57	7,07	49,97	7,07	0,79	0,62
			GSR	6,24	4,37	6,28	39,43	6,28	0,78	0,61
			TKA	5,57	3,90	5,85	34,23	5,85	0,83	0,70
6	8	30	KA	6,38	4,57	7,02	49,27	7,02	0,79	0,62
			GSR	6,15	4,31	6,23	38,81	6,23	0,78	0,61
			TKA	5,54	3,88	5,82	33,85	5,82	0,84	0,70
7	9	35	KA	6,39	4,53	6,99	48,88	6,99	0,80	0,63
			GSR	6,16	4,31	6,22	38,65	6,22	0,78	0,61
			TKA	5,53	3,88	5,82	33,88	5,82	0,84	0,70
8	10	40	KA	6,40	4,55	7,00	48,94	7,00	0,79	0,62
			GSR	6,14	4,30	6,22	38,65	6,22	0,78	0,61
			TKA	5,56	3,89	5,85	34,24	5,85	0,83	0,69
9	11	45	KA	5,87	4,14	6,61	43,68	6,61	0,83	0,70
			GSR	5,94	4,14	6,02	36,22	6,02	0,81	0,65
			TKA	5,27	3,67	5,61	31,45	5,61	0,86	0,73
10	13	50	KA	3,96	2,75	4,70	22,04	4,69	0,95	0,91
			GSR	3,60	2,46	4,11	16,85	4,10	0,96	0,92
			TKA	3,46	2,38	4,04	16,35	4,04	0,96	0,92
11	25	100	KA	3,53	2,52	4,43	19,62	4,43	0,96	0,92
			GSR	3,32	2,27	3,87	15,00	3,87	0,97	0,94
			TKA	<b>3,14</b>	<b>2,15</b>	<b>3,79</b>	<b>14,34</b>	<b>3,79</b>	<b>0,97</b>	<b>0,94</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.4.** 8-saniyelik epok için DKB tahmin sonuçları

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,05	5,13	7,26	52,72	7,26	0,67	0,45
			GSR	6,41	4,59	6,25	39,05	6,25	0,73	0,53
			TKA	6,73	4,76	6,68	44,60	6,68	0,71	0,50
2	3	10	KA	5,55	3,89	6,03	36,30	6,03	0,85	0,73
			GSR	6,43	4,44	6,24	38,86	6,23	0,77	0,59
			TKA	5,60	3,85	5,70	32,41	5,69	0,84	0,71
3	4	15	KA	5,55	3,89	6,03	36,33	6,03	0,85	0,73
			GSR	6,43	4,44	6,25	39,00	6,25	0,77	0,59
			TKA	5,57	3,84	5,71	32,56	5,71	0,84	0,70
4	5	20	KA	5,55	3,89	6,03	36,33	6,03	0,85	0,73
			GSR	6,47	4,47	6,26	39,10	6,25	0,76	0,58
			TKA	5,68	3,92	5,80	33,57	5,79	0,83	0,69
5	6	25	KA	5,80	4,02	6,28	39,35	6,27	0,83	0,69
			GSR	6,45	4,45	6,26	39,15	6,26	0,77	0,59
			TKA	5,27	3,61	5,46	29,75	5,45	0,86	0,74
6	8	30	KA	5,95	4,09	6,39	40,82	6,39	0,83	0,68
			GSR	5,89	4,04	5,92	35,04	5,92	0,81	0,66
			TKA	5,10	3,47	5,33	28,33	5,32	0,87	0,76
7	9	35	KA	5,95	4,09	6,39	40,82	6,39	0,83	0,68
			GSR	5,83	4,00	5,87	34,40	5,87	0,82	0,67
			TKA	5,13	3,49	5,36	28,73	5,36	0,87	0,76
8	10	40	KA	5,96	4,10	6,46	41,71	6,46	0,83	0,68
			GSR	5,76	3,96	5,83	33,97	5,83	0,82	0,67
			TKA	5,10	3,45	5,36	28,68	5,36	0,87	0,76
9	11	45	KA	5,98	4,11	6,49	42,11	6,49	0,82	0,68
			GSR	5,78	3,97	5,84	34,03	5,83	0,82	0,68
			TKA	5,14	3,49	5,38	28,88	5,37	0,87	0,76
10	13	50	KA	5,50	3,87	6,15	37,73	6,14	0,85	0,72
			GSR	5,60	3,82	5,67	32,07	5,66	0,84	0,70
			TKA	4,93	3,36	5,23	27,32	5,23	0,88	0,78
11	25	100	KA	3,31	2,35	4,23	17,90	4,23	0,96	0,93
			GSR	3,23	2,11	3,59	12,86	3,59	0,97	0,94
			TKA	<b>3,11</b>	<b>2,04</b>	<b>3,63</b>	<b>13,19</b>	<b>3,63</b>	<b>0,97</b>	<b>0,95</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.5.** 10-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	6,56	4,86	6,93	48,00	6,93	0,71	0,50
			GSR	5,99	4,42	6,05	36,51	6,04	0,75	0,57
			TKA	6,14	4,52	6,35	40,26	6,35	0,74	0,54
2	3	10	KA	6,04	4,47	6,75	45,55	6,75	0,77	0,59
			GSR	5,85	4,32	5,98	35,71	5,98	0,76	0,58
			TKA	5,51	4,03	5,93	35,13	5,93	0,81	0,65
3	4	15	KA	6,04	4,47	6,75	45,55	6,75	0,77	0,59
			GSR	5,86	4,32	5,98	35,76	5,98	0,76	0,58
			TKA	5,48	4,02	5,92	35,04	5,92	0,81	0,65
4	5	20	KA	6,03	4,46	6,80	46,14	6,79	0,78	0,60
			GSR	5,66	4,15	5,94	35,19	5,93	0,79	0,62
			TKA	5,36	3,92	5,86	34,32	5,86	0,82	0,67
5	6	25	KA	5,34	3,96	6,08	36,90	6,07	0,83	0,69
			GSR	5,68	4,15	5,95	35,36	5,95	0,79	0,62
			TKA	4,89	3,58	5,42	29,31	5,41	0,86	0,74
6	8	30	KA	5,62	4,11	6,51	42,36	6,51	0,82	0,67
			GSR	5,20	3,81	5,63	31,65	5,63	0,83	0,69
			TKA	4,73	3,44	5,36	28,74	5,36	0,87	0,75
7	9	35	KA	5,59	4,08	6,48	41,89	6,47	0,82	0,68
			GSR	5,20	3,80	5,64	31,73	5,63	0,83	0,69
			TKA	4,75	3,46	5,40	29,13	5,40	0,86	0,75
8	10	40	KA	5,65	4,13	6,50	42,24	6,50	0,82	0,67
			GSR	5,21	3,81	5,61	31,48	5,61	0,83	0,68
			TKA	4,74	3,45	5,38	28,95	5,38	0,87	0,75
9	11	45	KA	5,60	4,09	6,48	41,90	6,47	0,82	0,68
			GSR	5,18	3,80	5,60	31,32	5,60	0,83	0,69
			TKA	4,75	3,45	5,39	29,03	5,39	0,87	0,75
10	13	50	KA	3,66	2,73	4,58	21,00	4,58	0,95	0,90
			GSR	3,27	2,40	3,84	14,71	3,84	0,96	0,92
			TKA	3,23	2,36	3,87	14,94	3,86	0,96	0,92
11	25	100	KA	3,05	2,30	4,16	17,32	4,16	0,96	0,93
			GSR	2,85	2,08	3,53	12,46	3,53	0,97	0,94
			TKA	<b>2,69</b>	<b>1,96</b>	<b>3,42</b>	<b>11,67</b>	<b>3,42</b>	<b>0,97</b>	<b>0,95</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.6.** 12-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	6,68	4,75	6,85	46,83	6,84	0,71	0,50
			GSR	5,97	4,20	5,89	34,62	5,88	0,78	0,60
			TKA	6,19	4,37	6,22	38,69	6,22	0,74	0,55
2	3	10	KA	5,83	4,12	6,21	38,47	6,20	0,81	0,66
			GSR	5,77	4,07	5,73	32,84	5,73	0,79	0,63
			TKA	5,38	3,69	5,54	30,68	5,54	0,84	0,71
3	4	15	KA	5,83	4,12	6,21	38,47	6,20	0,81	0,66
			GSR	5,77	4,07	5,74	32,88	5,73	0,79	0,63
			TKA	5,28	3,64	5,50	30,19	5,49	0,84	0,71
4	5	20	KA	5,79	4,09	6,24	38,90	6,24	0,83	0,68
			GSR	5,52	3,86	5,65	31,93	5,65	0,81	0,66
			TKA	5,33	3,63	5,52	30,40	5,51	0,85	0,71
5	6	25	KA	5,15	3,62	5,71	32,59	5,71	0,88	0,77
			GSR	4,72	3,28	5,07	25,63	5,06	0,88	0,77
			TKA	4,78	3,23	4,99	24,88	4,99	0,89	0,80
6	8	30	KA	4,84	3,39	5,43	29,42	5,42	0,89	0,79
			GSR	4,54	3,17	4,92	24,16	4,92	0,89	0,79
			TKA	4,35	2,91	4,65	21,57	4,64	0,92	0,84
7	9	35	KA	4,84	3,39	5,43	29,42	5,42	0,89	0,79
			GSR	4,48	3,14	4,86	23,58	4,86	0,89	0,79
			TKA	4,39	2,93	4,72	22,22	4,71	0,91	0,84
8	10	40	KA	4,85	3,39	5,44	29,55	5,44	0,89	0,79
			GSR	4,48	3,14	4,85	23,53	4,85	0,89	0,79
			TKA	4,40	2,94	4,72	22,21	4,71	0,91	0,83
9	11	45	KA	4,81	3,37	5,44	29,53	5,43	0,89	0,80
			GSR	4,48	3,13	4,85	23,50	4,85	0,89	0,79
			TKA	4,40	2,95	4,72	22,21	4,71	0,91	0,83
10	13	50	KA	3,91	2,71	4,49	20,12	4,49	0,95	0,90
			GSR	3,60	2,48	3,99	15,91	3,99	0,95	0,91
			TKA	3,57	2,34	3,95	15,56	3,95	0,96	0,92
11	25	100	KA	3,15	2,17	4,01	16,09	4,01	0,97	0,94
			GSR	<b>2,88</b>	<b>1,99</b>	<b>3,49</b>	<b>12,18</b>	<b>3,49</b>	<b>0,97</b>	<b>0,95</b>
			TKA	3,01	1,95	3,52	12,35	3,51	0,97	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.7.** 14-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	4,62	3,18	4,55	20,68	4,55	0,92	0,84
			GSR	3,98	2,68	3,97	15,75	3,97	0,94	0,88
			TKA	4,28	2,92	4,22	17,82	4,22	0,93	0,86
2	3	10	KA	4,18	2,83	4,29	18,36	4,29	0,94	0,89
			GSR	4,16	2,83	8,41	70,58	8,40	0,94	0,88
			TKA	4,24	2,64	4,44	19,69	4,44	0,94	0,88
3	4	15	KA	4,18	2,83	4,29	18,36	4,29	0,94	0,89
			GSR	4,24	2,90	9,98	99,45	9,97	0,94	0,88
			TKA	4,04	2,57	4,13	17,04	4,13	0,95	0,90
4	5	20	KA	4,25	2,92	4,40	19,29	4,39	0,94	0,89
			GSR	9,65	7,18	174,80	30511,96	174,68	0,95	0,89
			TKA	4,07	2,57	4,17	17,37	4,17	0,95	0,90
5	6	25	KA	4,10	2,77	4,41	19,42	4,41	0,95	0,91
			GSR	4,85	3,31	23,40	546,56	23,38	0,95	0,90
			TKA	3,83	2,41	4,04	16,32	4,04	0,96	0,91
6	8	30	KA	4,18	2,64	4,55	20,69	4,55	0,95	0,91
			GSR	4,45	3,28	28,94	836,05	28,91	0,94	0,89
			TKA	3,77	2,35	3,96	15,65	3,96	0,96	0,92
7	9	35	KA	4,18	2,64	4,55	20,69	4,55	0,95	0,91
			GSR	4,51	2,86	9,87	97,34	9,87	0,95	0,90
			TKA	3,87	2,39	4,06	16,44	4,05	0,96	0,92
8	10	40	KA	4,18	2,64	4,55	20,71	4,55	0,95	0,91
			GSR	5,30	3,38	5,29	27,93	5,28	0,87	0,75
			TKA	3,80	2,34	3,98	15,85	3,98	0,96	0,92
9	11	45	KA	4,16	2,62	4,53	20,53	4,53	0,95	0,91
			GSR	5,19	3,83	40,68	1652,57	40,65	0,95	0,90
			TKA	3,88	2,37	4,06	16,49	4,06	0,96	0,92
10	13	50	KA	3,75	2,51	4,18	17,43	4,17	0,95	0,91
			GSR	3,60	2,26	3,77	14,22	3,77	0,96	0,92
			TKA	3,65	2,22	3,84	14,72	3,84	0,96	0,93
11	25	100	KA	3,18	2,07	3,82	14,57	3,82	0,97	0,94
			GSR	3,37	1,97	3,66	13,40	3,66	0,97	0,95
			TKA	<b>3,28</b>	<b>1,87</b>	<b>3,64</b>	<b>13,25</b>	<b>3,64</b>	<b>0,98</b>	<b>0,95</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması



**Tablo 6.8.** 16-saniyelik epok için DKB tahmin sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	3,71	2,81	4,17	17,33	4,16	0,94	0,88
			GSR	3,33	2,50	3,72	13,84	3,72	0,94	0,89
			TKA	3,46	2,61	3,88	15,02	3,88	0,94	0,88
2	3	10	KA	3,62	2,76	4,04	16,32	4,04	0,95	0,89
			GSR	3,87	2,96	19,45	377,68	19,43	0,94	0,89
			TKA	3,34	2,48	3,86	14,86	3,85	0,95	0,90
3	4	15	KA	3,62	2,76	4,04	16,32	4,04	0,95	0,89
			GSR	5,93	4,62	76,65	5865,87	76,59	0,94	0,89
			TKA	3,34	2,50	3,79	14,34	3,79	0,95	0,90
4	5	20	KA	3,62	2,76	4,04	16,32	4,04	0,95	0,89
			GSR	7,76	6,09	127,74	16289,21	127,63	0,94	0,89
			TKA	3,35	2,50	3,87	14,93	3,86	0,95	0,90
5	6	25	KA	3,31	2,52	4,03	16,23	4,03	0,95	0,91
			GSR	6,20	4,84	84,13	7066,21	84,06	0,94	0,89
			TKA	3,19	2,36	3,76	14,09	3,75	0,96	0,91
6	8	30	KA	3,46	2,62	4,13	17,06	4,13	0,95	0,90
			GSR	21,04	16,78	499,07	248655,06	498,65	0,95	0,90
			TKA	3,04	2,26	3,59	12,87	3,59	0,96	0,92
7	9	35	KA	3,45	2,62	4,13	17,03	4,13	0,95	0,90
			GSR	20,87	16,64	493,67	243303,01	493,26	0,95	0,90
			TKA	3,08	2,29	3,69	13,56	3,68	0,96	0,92
8	10	40	KA	3,37	2,55	4,07	16,55	4,07	0,95	0,90
			GSR	5,70	4,41	67,87	4599,29	67,82	0,95	0,89
			TKA	3,06	2,28	3,66	13,41	3,66	0,96	0,92
9	11	45	KA	3,37	2,55	4,07	16,55	4,07	0,95	0,90
			GSR	4,36	3,24	4,94	24,34	4,93	0,88	0,78
			TKA	3,10	2,30	3,72	13,80	3,72	0,96	0,92
10	13	50	KA	3,06	2,32	3,74	13,95	3,73	0,96	0,92
			GSR	3,01	2,26	3,59	12,89	3,59	0,96	0,92
			TKA	2,85	2,11	3,51	12,30	3,51	0,97	0,93
11	25	100	KA	2,61	1,99	3,71	13,73	3,71	0,97	0,95
			GSR	<b>2,44</b>	<b>1,83</b>	<b>3,11</b>	<b>9,64</b>	<b>3,10</b>	<b>0,98</b>	<b>0,95</b>
			TKA	2,44	1,81	3,23	10,42	3,23	0,98	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.9.** 18-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,86	4,37	6,31	39,75	6,30	0,76	0,57
			GSR	5,21	3,87	5,41	29,17	5,40	0,82	0,67
			TKA	5,44	4,04	5,76	33,14	5,76	0,78	0,61
2	3	10	KA	4,65	3,49	5,31	28,19	5,31	0,87	0,76
			GSR	5,00	3,72	5,16	26,57	5,15	0,85	0,72
			TKA	4,29	3,15	4,85	23,52	4,85	0,89	0,80
3	4	15	KA	4,75	3,56	5,50	30,17	5,49	0,86	0,75
			GSR	4,27	3,18	4,68	21,90	4,68	0,89	0,79
			TKA	4,15	3,08	4,69	21,98	4,69	0,89	0,80
4	5	20	KA	4,75	3,56	5,50	30,17	5,49	0,86	0,75
			GSR	4,26	3,18	4,67	21,75	4,66	0,89	0,79
			TKA	4,19	3,11	4,77	22,67	4,76	0,89	0,79
5	6	25	KA	4,75	3,56	5,50	30,17	5,49	0,86	0,75
			GSR	4,25	3,17	4,65	21,60	4,65	0,89	0,79
			TKA	4,16	3,09	4,72	22,23	4,71	0,89	0,80
6	8	30	KA	4,41	3,32	5,27	27,74	5,27	0,89	0,79
			GSR	4,14	3,09	4,62	21,32	4,62	0,89	0,80
			TKA	3,78	2,80	4,35	18,93	4,35	0,91	0,84
7	9	35	KA	4,41	3,32	5,27	27,74	5,27	0,89	0,79
			GSR	4,13	3,08	4,60	21,15	4,60	0,90	0,80
			TKA	3,78	2,79	4,36	19,00	4,36	0,92	0,84
8	10	40	KA	4,41	3,32	5,27	27,74	5,27	0,89	0,79
			GSR	4,13	3,08	4,59	21,06	4,59	0,90	0,81
			TKA	3,78	2,80	4,35	18,87	4,34	0,91	0,84
9	11	45	KA	4,41	3,32	5,27	27,73	5,27	0,89	0,79
			GSR	4,14	3,09	4,60	21,09	4,59	0,90	0,81
			TKA	3,81	2,82	4,38	19,19	4,38	0,92	0,84
10	13	50	KA	3,21	2,43	3,99	15,89	3,99	0,96	0,91
			GSR	3,05	2,30	3,53	12,42	3,52	0,96	0,91
			TKA	2,98	2,20	3,54	12,48	3,53	0,96	0,93
11	25	100	KA	2,58	1,95	3,63	13,17	3,63	0,97	0,94
			GSR	2,53	1,89	3,39	11,48	3,39	0,97	0,94
			TKA	<b>2,49</b>	<b>1,83</b>	<b>3,24</b>	<b>10,45</b>	<b>3,23</b>	<b>0,97</b>	<b>0,95</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.10.** 20-saniyelik epok için DKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,58	4,16	6,09	36,96	6,08	0,77	0,59
			GSR	5,21	3,85	5,48	29,96	5,47	0,80	0,63
			TKA	5,25	3,91	5,65	31,89	5,65	0,78	0,61
2	3	10	KA	4,66	3,48	5,35	28,52	5,34	0,86	0,75
			GSR	4,39	3,26	4,90	23,97	4,90	0,87	0,76
			TKA	4,26	3,14	4,92	24,16	4,92	0,88	0,77
3	4	15	KA	4,65	3,47	5,34	28,48	5,34	0,86	0,75
			GSR	4,41	3,28	4,91	24,06	4,91	0,87	0,75
			TKA	4,20	3,11	4,89	23,84	4,88	0,88	0,77
4	5	20	KA	4,65	3,47	5,34	28,48	5,34	0,86	0,75
			GSR	4,29	3,18	4,89	23,83	4,88	0,88	0,77
			TKA	4,23	3,13	4,91	24,10	4,91	0,88	0,77
5	6	25	KA	4,19	3,14	4,86	23,54	4,85	0,89	0,79
			GSR	4,39	3,26	4,93	24,26	4,93	0,87	0,76
			TKA	3,87	2,84	4,58	20,89	4,57	0,91	0,82
6	8	30	KA	4,24	3,15	5,12	26,12	5,11	0,88	0,78
			GSR	4,05	3,02	4,64	21,47	4,63	0,89	0,79
			TKA	3,75	2,77	4,45	19,80	4,45	0,91	0,83
7	9	35	KA	4,24	3,15	5,12	26,12	5,11	0,88	0,78
			GSR	4,04	3,00	4,63	21,40	4,63	0,89	0,79
			TKA	3,83	2,83	4,53	20,49	4,53	0,91	0,82
8	10	40	KA	4,26	3,17	5,15	26,43	5,14	0,88	0,78
			GSR	4,04	3,00	4,62	21,33	4,62	0,89	0,79
			TKA	3,76	2,77	4,51	20,27	4,50	0,91	0,83
9	11	45	KA	4,25	3,15	5,14	26,33	5,13	0,88	0,78
			GSR	4,06	3,02	4,63	21,44	4,63	0,89	0,79
			TKA	3,78	2,79	4,49	20,14	4,49	0,91	0,83
10	13	50	KA	2,90	2,19	3,67	13,45	3,67	0,96	0,93
			GSR	2,86	2,13	3,41	11,59	3,40	0,96	0,93
			TKA	2,76	2,04	3,43	11,76	3,43	0,96	0,93
11	25	100	KA	2,72	2,02	3,77	14,17	3,76	0,97	0,94
			GSR	<b>2,49</b>	<b>1,85</b>	<b>3,14</b>	<b>9,82</b>	<b>3,13</b>	<b>0,97</b>	<b>0,95</b>
			TKA	2,37	1,75	3,17	10,04	3,17	0,97	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.11.** 2-saniyelik epok için SKB tahmin sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,15	9,10	11,79	138,93	11,79	0,62	0,39
			GSR	6,24	7,91	10,00	99,97	10,00	0,66	0,44
			TKA	6,54	8,30	10,62	112,75	10,62	0,64	0,41
2	3	10	KA	5,38	6,92	10,04	100,83	10,04	0,79	0,62
			GSR	6,31	7,99	9,99	99,84	9,99	0,66	0,44
			TKA	4,64	5,95	8,33	69,45	8,33	0,83	0,69
3	4	15	KA	5,11	6,58	9,74	94,86	9,74	0,81	0,66
			GSR	5,05	6,45	8,63	74,44	8,63	0,82	0,67
			TKA	4,37	5,62	7,94	63,10	7,94	0,85	0,73
4	5	20	KA	5,11	6,58	9,74	94,86	9,74	0,81	0,66
			GSR	4,99	6,38	8,57	73,49	8,57	0,82	0,67
			TKA	4,35	5,59	7,91	62,58	7,91	0,86	0,73
5	6	25	KA	5,19	6,68	9,85	97,07	9,85	0,81	0,65
			GSR	5,00	6,39	8,58	73,60	8,58	0,82	0,67
			TKA	4,39	5,63	7,96	63,41	7,96	0,85	0,73
6	8	30	KA	5,20	6,69	9,87	97,46	9,87	0,81	0,65
			GSR	4,93	6,30	8,52	72,49	8,51	0,82	0,68
			TKA	4,37	5,61	7,91	62,57	7,91	0,86	0,73
7	9	35	KA	4,66	6,01	9,01	81,15	9,01	0,85	0,72
			GSR	4,64	5,93	8,18	66,86	8,18	0,84	0,71
			TKA	4,12	5,29	7,52	56,47	7,51	0,88	0,77
8	10	40	KA	4,22	5,47	8,25	68,11	8,25	0,88	0,78
			GSR	4,10	5,28	7,32	53,54	7,32	0,88	0,78
			TKA	3,73	4,82	6,90	47,54	6,89	0,90	0,81
9	11	45	KA	4,22	5,48	8,26	68,14	8,25	0,88	0,78
			GSR	4,12	5,31	7,34	53,92	7,34	0,88	0,78
			TKA	3,77	4,87	6,96	48,40	6,96	0,90	0,81
10	13	50	KA	3,24	4,24	6,44	41,41	6,43	0,95	0,90
			GSR	2,86	3,73	5,39	29,06	5,39	0,96	0,92
			TKA	2,76	3,60	5,32	28,29	5,32	0,96	0,92
11	25	100	KA	3,19	4,16	6,49	42,12	6,49	0,95	0,91
			GSR	2,68	3,49	5,12	26,18	5,12	0,97	0,93
			TKA	<b>2,58</b>	<b>3,37</b>	<b>5,05</b>	<b>25,48</b>	<b>5,05</b>	<b>0,97</b>	<b>0,93</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.12.** 4-saniyelik epok için SKB tahmin sonuçları.

D	Bilgi		Performans Değerlendirme Kriterleri							
	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	6,54	8,45	11,24	126,33	11,24	0,63	0,40
			GSR	5,86	7,55	9,73	94,61	9,73	0,66	0,43
			TKA	6,09	7,85	10,30	106,13	10,30	0,64	0,41
2	3	10	KA	3,83	5,01	7,40	54,74	7,40	0,92	0,85
			GSR	4,09	5,28	7,30	53,20	7,29	0,91	0,82
			TKA	3,22	4,20	6,20	38,43	6,20	0,94	0,87
3	4	15	KA	3,60	4,73	7,14	50,94	7,14	0,93	0,86
			GSR	3,27	4,28	6,31	39,83	6,31	0,93	0,86
			TKA	3,04	3,99	5,94	35,24	5,94	0,94	0,89
4	5	20	KA	3,60	4,73	7,14	50,94	7,14	0,93	0,86
			GSR	3,28	4,29	6,30	39,73	6,30	0,93	0,86
			TKA	3,04	3,99	5,94	35,21	5,93	0,94	0,88
5	6	25	KA	3,63	4,77	7,22	52,07	7,22	0,93	0,86
			GSR	3,27	4,28	6,30	39,67	6,30	0,93	0,86
			TKA	3,07	4,02	5,97	35,61	5,97	0,94	0,88
6	8	30	KA	3,63	4,77	7,25	52,50	7,25	0,93	0,86
			GSR	3,26	4,27	6,29	39,56	6,29	0,93	0,86
			TKA	3,05	4,01	5,96	35,53	5,96	0,94	0,89
7	9	35	KA	3,56	4,68	7,09	50,19	7,08	0,93	0,86
			GSR	3,09	4,04	6,05	36,58	6,05	0,94	0,88
			TKA	3,00	3,94	5,89	34,64	5,89	0,94	0,89
8	10	40	KA	3,38	4,45	6,86	47,00	6,86	0,94	0,87
			GSR	2,93	3,84	5,80	33,67	5,80	0,94	0,89
			TKA	2,85	3,75	5,68	32,30	5,68	0,95	0,90
9	11	45	KA	3,38	4,45	6,86	47,00	6,86	0,94	0,87
			GSR	2,90	3,80	5,78	33,39	5,78	0,95	0,89
			TKA	2,83	3,72	5,63	31,65	5,63	0,95	0,90
10	13	50	KA	2,98	3,95	6,21	38,55	6,21	0,96	0,92
			GSR	2,53	3,33	5,03	25,25	5,02	0,96	0,93
			TKA	2,53	3,34	5,08	25,83	5,08	0,96	0,93
11	25	100	KA	2,82	3,72	5,92	35,01	5,92	0,96	0,92
			GSR	2,42	3,18	4,89	23,91	4,89	0,97	0,94
			TKA	<b>2,34</b>	<b>3,09</b>	<b>4,86</b>	<b>23,62</b>	<b>4,86</b>	<b>0,97</b>	<b>0,94</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.13.** 6-saniyelik epok için SKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	6,31	8,19	11,09	122,81	11,08	0,65	0,42
			GSR	5,58	7,22	9,52	90,49	9,51	0,70	0,49
			TKA	5,87	7,60	10,14	102,83	10,14	0,67	0,44
2	3	10	KA	5,11	6,68	9,80	95,97	9,80	0,79	0,62
			GSR	5,68	7,34	9,56	91,31	9,56	0,70	0,49
			TKA	4,63	6,01	8,39	70,43	8,39	0,82	0,68
3	4	15	KA	5,11	6,67	9,79	95,81	9,79	0,79	0,62
			GSR	5,67	7,33	9,56	91,24	9,55	0,70	0,50
			TKA	4,58	5,94	8,36	69,83	8,36	0,83	0,68
4	5	20	KA	5,11	6,67	9,79	95,81	9,79	0,79	0,62
			GSR	5,67	7,34	9,56	91,27	9,55	0,70	0,49
			TKA	4,59	5,97	8,38	70,12	8,37	0,82	0,68
5	6	25	KA	5,08	6,64	9,89	97,72	9,89	0,79	0,62
			GSR	5,07	6,56	8,97	80,47	8,97	0,78	0,61
			TKA	4,46	5,79	8,23	67,75	8,23	0,83	0,70
6	8	30	KA	5,08	6,64	9,89	97,79	9,89	0,79	0,62
			GSR	4,99	6,45	8,89	79,01	8,89	0,78	0,61
			TKA	4,45	5,79	8,22	67,58	8,22	0,83	0,70
7	9	35	KA	5,03	6,58	9,80	96,04	9,80	0,79	0,62
			GSR	4,97	6,44	8,88	78,79	8,88	0,78	0,61
			TKA	4,43	5,77	8,22	67,52	8,22	0,83	0,70
8	10	40	KA	5,05	6,61	9,80	95,97	9,80	0,79	0,63
			GSR	4,97	6,44	8,88	78,77	8,88	0,78	0,61
			TKA	4,45	5,80	8,28	68,56	8,28	0,83	0,69
9	11	45	KA	4,59	6,01	9,23	85,13	9,23	0,83	0,70
			GSR	4,80	6,20	8,57	73,41	8,57	0,81	0,65
			TKA	4,19	5,45	7,85	61,59	7,85	0,86	0,74
10	13	50	KA	2,98	3,95	6,27	39,31	6,27	0,95	0,91
			GSR	2,62	3,47	5,28	27,87	5,28	0,96	0,92
			TKA	2,57	3,41	5,26	27,61	5,25	0,96	0,92
11	25	100	KA	2,73	3,61	6,06	36,68	6,06	0,96	0,92
			GSR	2,36	3,13	4,94	24,41	4,94	0,97	0,94
			TKA	<b>2,27</b>	<b>3,00</b>	<b>4,83</b>	<b>23,31</b>	<b>4,83</b>	<b>0,97</b>	<b>0,94</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.14.** 8-saniyelik epok için SKB tahmin sonuçları.

D	Bilgi		Performans Değerlendirme Kriterleri							
	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,88	7,69	10,61	112,46	10,60	0,68	0,46
			GSR	5,31	6,92	9,08	82,35	9,07	0,73	0,54
			TKA	5,53	7,20	9,67	93,48	9,67	0,71	0,50
2	3	10	KA	4,49	5,91	8,75	76,48	8,75	0,84	0,71
			GSR	5,20	6,76	8,93	79,66	8,93	0,77	0,59
			TKA	4,49	5,85	8,09	65,43	8,09	0,84	0,70
3	4	15	KA	4,49	5,91	8,75	76,54	8,75	0,84	0,71
			GSR	5,20	6,77	8,94	79,82	8,93	0,76	0,58
			TKA	4,45	5,80	8,05	64,72	8,05	0,84	0,71
4	5	20	KA	4,49	5,91	8,75	76,54	8,75	0,84	0,71
			GSR	5,20	6,77	8,95	80,04	8,95	0,76	0,58
			TKA	4,52	5,89	8,19	67,03	8,19	0,83	0,69
5	6	25	KA	4,50	5,90	8,91	79,40	8,91	0,84	0,70
			GSR	5,20	6,77	8,95	80,02	8,95	0,76	0,58
			TKA	4,14	5,39	7,63	58,12	7,62	0,86	0,74
6	8	30	KA	4,66	6,09	9,23	85,13	9,23	0,82	0,67
			GSR	4,72	6,15	8,44	71,21	8,44	0,81	0,65
			TKA	3,98	5,20	7,49	56,01	7,48	0,87	0,76
7	9	35	KA	4,66	6,09	9,23	85,13	9,23	0,82	0,67
			GSR	4,67	6,08	8,36	69,77	8,35	0,81	0,66
			TKA	3,97	5,19	7,50	56,13	7,49	0,87	0,75
8	10	40	KA	4,70	6,15	9,26	85,72	9,26	0,82	0,67
			GSR	4,61	6,01	8,29	68,67	8,29	0,82	0,67
			TKA	3,97	5,19	7,48	55,87	7,47	0,87	0,76
9	11	45	KA	4,68	6,13	9,19	84,31	9,18	0,82	0,68
			GSR	4,60	6,00	8,28	68,47	8,27	0,82	0,67
			TKA	3,98	5,20	7,51	56,32	7,50	0,87	0,75
10	13	50	KA	4,48	5,87	8,97	80,37	8,96	0,85	0,72
			GSR	4,41	5,74	8,01	64,18	8,01	0,84	0,70
			TKA	3,83	5,01	7,24	52,37	7,24	0,88	0,78
11	25	100	KA	2,54	3,37	5,71	32,62	5,71	0,96	0,93
			GSR	<b>2,20</b>	<b>2,91</b>	<b>4,50</b>	<b>20,28</b>	<b>4,50</b>	<b>0,97</b>	<b>0,95</b>
			TKA	2,13	2,81	4,56	20,74	4,55	0,97	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.15.** 10-saniyelik epok için SKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,68	7,42	10,29	105,82	10,29	0,71	0,50
			GSR	5,17	6,74	8,85	78,30	8,85	0,75	0,57
			TKA	5,31	6,92	9,37	87,64	9,36	0,73	0,53
2	3	10	KA	5,10	6,68	9,91	98,04	9,90	0,77	0,59
			GSR	5,08	6,63	8,75	76,43	8,74	0,76	0,58
			TKA	4,73	6,16	8,59	73,71	8,59	0,81	0,65
3	4	15	KA	5,10	6,68	9,91	98,04	9,90	0,77	0,59
			GSR	5,07	6,62	8,74	76,39	8,74	0,76	0,58
			TKA	4,66	6,08	8,57	73,33	8,56	0,81	0,65
4	5	20	KA	5,09	6,66	9,91	98,20	9,91	0,77	0,60
			GSR	4,91	6,39	8,66	74,92	8,66	0,78	0,61
			TKA	4,57	5,97	8,50	72,24	8,50	0,81	0,66
5	6	25	KA	4,57	5,97	9,03	81,45	9,02	0,83	0,68
			GSR	4,91	6,39	8,66	74,92	8,66	0,78	0,61
			TKA	4,13	5,39	7,73	59,69	7,73	0,86	0,73
6	8	30	KA	4,59	5,99	9,13	83,22	9,12	0,83	0,68
			GSR	4,46	5,82	8,15	66,38	8,15	0,83	0,68
			TKA	4,01	5,22	7,70	59,19	7,69	0,86	0,74
7	9	35	KA	4,56	5,96	9,11	82,98	9,11	0,83	0,68
			GSR	4,46	5,81	8,15	66,28	8,14	0,83	0,68
			TKA	3,99	5,21	7,67	58,82	7,67	0,86	0,74
8	10	40	KA	4,60	6,02	9,14	83,52	9,14	0,82	0,68
			GSR	4,47	5,82	8,15	66,39	8,15	0,83	0,68
			TKA	4,01	5,23	7,70	59,23	7,70	0,86	0,74
9	11	45	KA	4,60	6,01	9,14	83,39	9,13	0,82	0,68
			GSR	4,44	5,79	8,14	66,20	8,14	0,83	0,68
			TKA	3,99	5,21	7,68	58,85	7,67	0,86	0,74
10	13	50	KA	2,97	3,93	6,07	36,86	6,07	0,95	0,90
			GSR	2,66	3,51	5,17	26,75	5,17	0,96	0,91
			TKA	2,58	3,41	5,14	26,39	5,14	0,96	0,92
11	25	100	KA	2,40	3,21	5,44	29,60	5,44	0,97	0,93
			GSR	2,17	2,88	4,50	20,27	4,50	0,97	0,95
			TKA	<b>2,08</b>	<b>2,75</b>	<b>4,37</b>	<b>19,11</b>	<b>4,37</b>	<b>0,97</b>	<b>0,95</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması



**Tablo 6.16.** 12-saniyelik epok için SKB tahmin sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,45	7,18	10,02	100,18	10,01	0,71	0,51
			GSR	4,95	6,46	8,61	73,99	8,60	0,77	0,60
			TKA	5,10	6,70	9,11	82,95	9,11	0,74	0,55
2	3	10	KA	4,67	6,18	9,16	83,80	9,15	0,81	0,65
			GSR	4,76	6,25	8,37	69,95	8,36	0,79	0,62
			TKA	4,28	5,60	7,95	63,19	7,95	0,84	0,71
3	4	15	KA	4,67	6,18	9,16	83,80	9,15	0,81	0,65
			GSR	4,76	6,25	8,38	70,11	8,37	0,79	0,62
			TKA	4,21	5,50	7,92	62,60	7,91	0,84	0,71
4	5	20	KA	4,64	6,12	9,01	81,00	9,00	0,81	0,66
			GSR	4,53	5,94	8,21	67,28	8,20	0,81	0,65
			TKA	4,13	5,42	7,83	61,28	7,83	0,84	0,71
5	6	25	KA	4,21	5,57	8,32	69,10	8,31	0,87	0,75
			GSR	3,80	5,01	7,20	51,76	7,19	0,87	0,77
			TKA	3,73	4,90	7,07	49,98	7,07	0,89	0,79
6	8	30	KA	3,79	5,01	7,83	61,25	7,83	0,89	0,79
			GSR	3,58	4,73	6,95	48,30	6,95	0,89	0,79
			TKA	3,35	4,40	6,58	43,26	6,58	0,91	0,83
7	9	35	KA	3,79	5,01	7,83	61,25	7,83	0,89	0,79
			GSR	3,56	4,70	6,89	47,38	6,88	0,89	0,79
			TKA	3,35	4,39	6,61	43,65	6,61	0,91	0,83
8	10	40	KA	3,80	5,02	7,84	61,44	7,84	0,89	0,78
			GSR	3,56	4,70	6,88	47,29	6,88	0,89	0,79
			TKA	3,34	4,39	6,58	43,26	6,58	0,91	0,83
9	11	45	KA	3,80	5,02	7,85	61,48	7,84	0,89	0,78
			GSR	3,56	4,71	6,87	47,07	6,86	0,89	0,79
			TKA	3,31	4,35	6,51	42,26	6,50	0,91	0,83
10	13	50	KA	2,94	3,91	6,09	37,06	6,09	0,95	0,90
			GSR	2,73	3,65	5,31	28,18	5,31	0,95	0,91
			TKA	2,58	3,42	5,16	26,57	5,15	0,96	0,92
11	25	100	KA	2,38	3,19	5,53	30,51	5,52	0,97	0,93
			GSR	<b>2,04</b>	<b>2,73</b>	<b>4,39</b>	<b>19,25</b>	<b>4,39</b>	<b>0,98</b>	<b>0,95</b>
			TKA	2,05	2,73	4,46	19,90	4,46	0,98	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.17.** 14-saniyelik epok için SKB tahmin sonuçları.

Bilgi				Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>	
1	1	5	KA	3,56	4,75	6,42	41,10	6,41	0,92	0,84	
			GSR	3,02	4,02	5,39	29,00	5,39	0,94	0,87	
			TKA	3,31	4,41	5,90	34,81	5,90	0,92	0,85	
2	3	10	KA	3,23	4,33	6,12	37,41	6,12	0,94	0,88	
			GSR	3,28	4,38	12,62	159,13	12,61	0,94	0,88	
			TKA	2,96	3,91	5,70	32,48	5,70	0,94	0,89	
3	4	15	KA	3,23	4,33	6,12	37,41	6,12	0,94	0,88	
			GSR	3,73	5,01	27,49	754,77	27,47	0,94	0,88	
			TKA	2,88	3,82	5,44	29,54	5,44	0,94	0,89	
4	5	20	KA	3,18	4,28	6,06	36,63	6,05	0,94	0,89	
			GSR	4,97	6,77	105,52	11118,50	105,44	0,95	0,90	
			TKA	2,85	3,78	5,43	29,41	5,42	0,95	0,90	
5	6	25	KA	3,01	4,02	5,91	34,90	5,91	0,95	0,90	
			GSR	3,58	4,83	30,51	929,23	30,48	0,95	0,90	
			TKA	2,72	3,58	5,35	28,60	5,35	0,96	0,91	
6	8	30	KA	2,93	3,91	5,99	35,81	5,98	0,95	0,91	
			GSR	5,40	7,36	117,78	13851,43	117,69	0,95	0,90	
			TKA	2,59	3,43	5,06	25,61	5,06	0,96	0,92	
7	9	35	KA	2,93	3,91	5,99	35,81	5,98	0,95	0,91	
			GSR	3,97	5,22	7,43	55,09	7,42	0,86	0,75	
			TKA	2,61	3,45	5,11	26,03	5,10	0,96	0,92	
8	10	40	KA	2,92	3,90	5,96	35,48	5,96	0,95	0,91	
			GSR	4,96	6,72	101,53	10293,64	101,46	0,95	0,90	
			TKA	2,61	3,46	5,13	26,25	5,12	0,96	0,92	
9	11	45	KA	2,91	3,89	5,96	35,45	5,95	0,95	0,91	
			GSR	3,97	5,22	7,48	55,84	7,47	0,86	0,75	
			TKA	2,62	3,47	5,22	27,23	5,22	0,96	0,92	
10	13	50	KA	2,76	3,65	5,70	32,49	5,70	0,95	0,91	
			GSR	2,49	3,33	4,81	23,14	4,81	0,96	0,93	
			TKA	2,47	3,27	4,85	23,50	4,85	0,96	0,93	
11	25	100	KA	2,24	3,00	5,14	26,41	5,14	0,97	0,94	
			GSR	<b>2,00</b>	<b>2,68</b>	<b>4,38</b>	<b>19,19</b>	<b>4,38</b>	<b>0,98</b>	<b>0,95</b>	
			TKA	2,05	2,72	4,39	19,22	4,38	0,98	0,95	

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.18.** 16-saniyelik epok için SKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	3,18	4,25	5,86	34,29	5,86	0,94	0,88
			GSR	2,87	3,82	5,17	26,64	5,16	0,94	0,89
			TKA	2,94	3,92	5,39	29,05	5,39	0,94	0,88
2	3	10	KA	3,07	4,11	5,76	33,10	5,75	0,94	0,89
			GSR	2,78	3,72	5,48	30,00	5,48	0,94	0,89
			TKA	2,78	3,70	5,24	27,42	5,24	0,95	0,90
3	4	15	KA	3,07	4,11	5,75	33,06	5,75	0,94	0,89
			GSR	5,33	7,27	124,66	15514,79	124,56	0,94	0,89
			TKA	2,77	3,69	5,18	26,80	5,18	0,95	0,90
4	5	20	KA	3,07	4,11	5,75	33,06	5,75	0,94	0,89
			GSR	6,77	9,27	192,70	37072,41	192,54	0,94	0,89
			TKA	2,79	3,71	5,27	27,68	5,26	0,95	0,90
5	6	25	KA	2,92	3,91	5,73	32,83	5,73	0,95	0,90
			GSR	8,36	11,48	268,79	72126,37	268,56	0,94	0,89
			TKA	2,67	3,54	5,13	26,29	5,13	0,96	0,91
6	8	30	KA	2,87	3,83	5,72	32,71	5,72	0,95	0,91
			GSR	6,49	8,86	179,87	32299,68	179,72	0,95	0,89
			TKA	2,53	3,36	4,98	24,77	4,98	0,96	0,92
7	9	35	KA	2,87	3,83	5,72	32,72	5,72	0,95	0,91
			GSR	63,68	88,44	2946,64	8668294,47	2944,20	0,95	0,90
			TKA	2,56	3,40	4,98	24,74	4,97	0,96	0,92
8	10	40	KA	2,91	3,88	5,75	33,03	5,75	0,95	0,90
			GSR	3,25	4,35	22,40	500,78	22,38	0,95	0,90
			TKA	2,54	3,38	4,91	24,10	4,91	0,96	0,92
9	11	45	KA	2,90	3,87	5,75	32,97	5,74	0,95	0,90
			GSR	5,67	7,73	138,96	19278,64	138,85	0,95	0,90
			TKA	2,53	3,36	4,95	24,47	4,95	0,96	0,92
10	13	50	KA	2,45	3,30	5,12	26,19	5,12	0,96	0,93
			GSR	2,50	3,33	4,91	24,05	4,90	0,96	0,92
			TKA	2,27	3,02	4,57	20,88	4,57	0,97	0,94
11	25	100	KA	2,00	2,69	4,66	21,70	4,66	0,98	0,95
			GSR	<b>1,92</b>	<b>2,56</b>	<b>4,09</b>	<b>16,66</b>	<b>4,08</b>	<b>0,98</b>	<b>0,96</b>
			TKA	1,95	2,60	4,22	17,80	4,22	0,98	0,96

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi  
KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.19.** 18-saniyelik epok için SKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,28	6,93	9,64	92,73	9,63	0,75	0,57
			GSR	4,74	6,21	8,20	67,10	8,19	0,81	0,66
			TKA	4,92	6,45	8,86	78,40	8,85	0,77	0,60
2	3	10	KA	4,01	5,30	7,89	62,06	7,88	0,88	0,77
			GSR	4,55	5,97	7,80	60,80	7,80	0,85	0,72
			TKA	3,83	5,00	7,24	52,29	7,23	0,89	0,80
3	4	15	KA	4,17	5,51	8,18	66,86	8,18	0,87	0,75
			GSR	3,83	5,05	7,04	49,43	7,03	0,89	0,79
			TKA	3,66	4,82	7,00	48,94	7,00	0,89	0,80
4	5	20	KA	4,17	5,51	8,18	66,86	8,18	0,87	0,75
			GSR	3,83	5,05	7,02	49,13	7,01	0,89	0,79
			TKA	3,73	4,90	7,08	50,05	7,07	0,89	0,79
5	6	25	KA	4,17	5,51	8,18	66,86	8,18	0,87	0,75
			GSR	3,83	5,06	7,02	49,13	7,01	0,89	0,79
			TKA	3,71	4,89	7,02	49,22	7,02	0,89	0,80
6	8	30	KA	3,72	4,93	7,59	57,58	7,59	0,89	0,79
			GSR	3,71	4,90	6,92	47,74	6,91	0,89	0,80
			TKA	3,30	4,33	6,38	40,59	6,37	0,92	0,84
7	9	35	KA	3,72	4,93	7,59	57,58	7,59	0,89	0,79
			GSR	3,70	4,87	6,91	47,66	6,90	0,90	0,80
			TKA	3,34	4,39	6,43	41,24	6,42	0,92	0,84
8	10	40	KA	3,70	4,91	7,58	57,35	7,57	0,89	0,80
			GSR	3,70	4,88	6,89	47,33	6,88	0,90	0,80
			TKA	3,34	4,39	6,40	40,90	6,39	0,92	0,84
9	11	45	KA	3,70	4,91	7,58	57,37	7,57	0,89	0,79
			GSR	3,70	4,89	6,89	47,40	6,88	0,90	0,81
			TKA	3,40	4,47	6,51	42,34	6,51	0,91	0,84
10	13	50	KA	2,76	3,69	5,67	32,10	5,67	0,96	0,92
			GSR	2,65	3,56	5,13	26,25	5,12	0,96	0,91
			TKA	2,57	3,41	5,03	25,24	5,02	0,96	0,92
11	25	100	KA	2,12	2,84	4,91	24,04	4,90	0,97	0,94
			GSR	<b>1,97</b>	<b>2,63</b>	<b>4,38</b>	<b>19,18</b>	<b>4,38</b>	<b>0,97</b>	<b>0,95</b>
			TKA	1,99	2,64	4,39	19,27	4,39	0,98	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.20.** 20-saniyelik epok için SKB tahmin sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	5,03	6,59	9,31	86,53	9,30	0,76	0,58
			GSR	4,71	6,14	8,31	68,84	8,30	0,80	0,64
			TKA	4,76	6,22	8,61	73,99	8,60	0,78	0,60
2	3	10	KA	4,20	5,54	8,22	67,46	8,21	0,86	0,73
			GSR	3,95	5,19	7,36	54,01	7,35	0,87	0,75
			TKA	3,72	4,87	7,22	52,08	7,22	0,88	0,78
3	4	15	KA	4,20	5,55	8,22	67,49	8,22	0,86	0,73
			GSR	3,97	5,21	7,37	54,21	7,36	0,87	0,75
			TKA	3,73	4,90	7,25	52,45	7,24	0,88	0,77
4	5	20	KA	4,20	5,55	8,22	67,49	8,22	0,86	0,73
			GSR	3,98	5,22	7,39	54,54	7,38	0,87	0,75
			TKA	3,74	4,90	7,29	53,09	7,29	0,88	0,78
5	6	25	KA	3,83	5,04	7,54	56,69	7,53	0,88	0,78
			GSR	3,82	5,02	7,25	52,40	7,24	0,88	0,77
			TKA	3,39	4,43	6,73	45,15	6,72	0,91	0,82
6	8	30	KA	3,73	4,90	7,66	58,48	7,65	0,88	0,78
			GSR	3,65	4,81	6,92	47,83	6,92	0,89	0,79
			TKA	3,28	4,29	6,55	42,87	6,55	0,91	0,83
7	9	35	KA	3,73	4,90	7,66	58,48	7,65	0,88	0,78
			GSR	3,66	4,82	6,91	47,72	6,91	0,89	0,79
			TKA	3,36	4,39	6,72	45,04	6,71	0,91	0,82
8	10	40	KA	3,72	4,90	7,67	58,74	7,66	0,88	0,78
			GSR	3,65	4,80	6,90	47,51	6,89	0,89	0,79
			TKA	3,29	4,31	6,52	42,39	6,51	0,91	0,83
9	11	45	KA	3,72	4,90	7,67	58,75	7,66	0,88	0,78
			GSR	3,65	4,80	6,90	47,54	6,90	0,89	0,79
			TKA	3,32	4,35	6,62	43,70	6,61	0,91	0,83
10	13	50	KA	2,39	3,23	5,11	26,08	5,11	0,96	0,93
			GSR	2,44	3,26	4,80	23,00	4,80	0,96	0,92
			TKA	2,28	3,02	4,70	22,05	4,70	0,97	0,93
11	25	100	KA	2,17	2,89	5,15	26,43	5,14	0,97	0,94
			GSR	<b>1,96</b>	<b>2,62</b>	<b>4,13</b>	<b>16,98</b>	<b>4,12</b>	<b>0,98</b>	<b>0,96</b>
			TKA	1,96	2,60	4,29	18,41	4,29	0,98	0,95

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GSR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı Algoritması

**Tablo 6.21.** En iyi sonuç veren sürelere dair SKB ve DKB tahmin sonuçları.

ES	Bilgi		Model	Performans Değerlendirme Kriterleri						
	KB	ÖS		OMYH (%)	OMS	SH	OKH	KOKH	R	R <sup>2</sup>
2	SKB	11	TKA	2,58	3,37	5,05	25,48	5,05	0,97	0,93
	DKB	11	TKA	3,31	2,43	4,06	16,52	4,06	0,97	0,93
4	SKB	11	TKA	2,34	3,09	4,86	23,62	4,86	0,97	0,94
	DKB	11	TKA	3,17	2,24	3,85	14,82	3,85	0,97	0,94
6	SKB	11	TKA	2,27	3,00	4,83	23,31	4,83	0,97	0,94
	DKB	11	TKA	3,14	2,15	3,79	14,34	3,79	0,97	0,94
8	SKB	11	GSR	2,20	2,91	4,50	20,28	4,50	0,97	0,95
	DKB	11	TKA	3,11	2,04	3,63	13,19	3,63	0,97	0,95
10	SKB	11	TKA	2,08	2,75	4,37	19,11	4,37	0,97	0,95
	DKB	11	TKA	2,69	1,96	3,42	11,67	3,42	0,97	0,95
12	SKB	11	GSR	2,04	2,73	4,39	19,25	4,39	0,98	0,95
	DKB	11	GSR	2,88	1,99	3,49	12,18	3,49	0,97	0,95
14	SKB	11	GSR	2,00	2,68	4,38	19,19	4,38	0,98	0,95
	DKB	11	TKA	3,28	1,87	3,64	13,25	3,64	0,98	0,95
16	SKB	11	GSR	<b>1,92</b>	<b>2,56</b>	<b>4,09</b>	<b>16,66</b>	<b>4,08</b>	<b>0,98</b>	<b>0,96</b>
	DKB	11	GSR	<b>2,44</b>	<b>1,83</b>	<b>3,11</b>	<b>9,64</b>	<b>3,10</b>	<b>0,98</b>	<b>0,95</b>
18	SKB	11	GSR	1,97	2,63	4,38	19,18	4,38	0,97	0,95
	DKB	11	TKA	2,49	1,83	3,24	10,45	3,23	0,97	0,95
20	SKB	11	GSR	1,96	2,62	4,13	16,98	4,12	0,98	0,96
	DKB	11	TKA	2,37	1,75	3,17	10,04	3,17	0,97	0,95

ES: Epok Süresi, ÖS: Özellik Sayısı, KB: Kan Basıncı, SKB: Sistolik Kan Basıncı, DKB: Diyastolik Kan Basıncı

TKA: Topluluk Karar Ağacı Algoritması, GSR: Gauss Süreç Regresyonu

## **6.2. Elektrokardiyografi Alt Frekans Bantları Ayrımına Dayalı Diyastolik ve Sistolik Kan Basıncı Tahmin Sonuçları**

Çalışmanın ilk kısmında (Bölüm 6.1) minimum süre tespiti yapılarak modelin uygulama sürecine dair sonuçlar ayrıntılarıyla değerlendirilmiştir. Bu sürece göre, 16 saniyede en başarılı kan basıncı tahmini gerçekleştirilirken, diğer epoklarında küçük başarı oranı farkları ile kullanılabileceği öngörülmüştür. Alt frekans bant analizi sürecine ilişkin 10 saniyelik süre kullanımının sebebi ise her saniyeye ait küçük bir fark gösteren başarı oranlarının yükseltmek istenmesidir. Ayrıca, 10 saniye ile daha hızlı sonuçlar elde edilir ve kan basıncı değerlerinin hesaplanmasında ortalama tepe değerleri alınarak hata oranının azaltılması sağlanır.

EKG'nin alt frekans bant analizinde öncelikli olarak istenen durum, hangi frekans aralıklarından alınan bilginin faydalı edinimler sunacağını ortaya çıkarmaktır. Bu durum dahilinde EKG kayıtları Tablo 4.1.'de belirtilen bant aralıklarına bölünmüştür. Burada göze çarpan bir nokta da 64 Hz frekansa sahip EKG kaydı için 56 Hz frekans bantında, frekans bant ayrımını yapabilmektir. Açıkça belirtmek gerekirse, 64 Hz frekans bantındaki bir kayıt, sadece 32 Hz frekans bantı içerisinde bilgi aktarabilir. Bu durumda kayıtlara üst örnekleme uygulanmıştır. Üst örnekleme yapılarak yeni veri seti frekansı 128 Hz olarak belirlenmiştir. Veri setinde üst örneklemin uygulanmadığı kısım ham sinyaller olarak ifade edilmiştir. 128 Hz frekans bantındaki üst örneklenmiş sinyaller belirlenen bant aralıklarına bölünerek (Tablo 4.1) yedi adet alt frekans bantına ait sinyal veri seti oluşturulmuştur. Hem ham sinyaller hem de alt örnekleme uygulanmış ve üst örneklenmiş sinyaller için özellik çıkarım işlemi yapılmıştır. Bu işlem sürecinde, 9 çeşit sinyal türünün her birinden 225 adet özellik çıkarımı yapılmıştır. Sonrasında, özellik vektörlerinin boyutunu küçültmek ve gereksiz özelliklerin iş yükünden kurtulmak için özellik seçimi yapılmıştır. Her bir özelliğin korelasyonu spearman yöntemiyle hesaplanmıştır ve en yüksek korelasyon seviyesinden en düşük korelasyon seviyesine doğru sıralanmıştır. Özelliğin %5'i (tam sayılara yuvarlanır) 1'e, %10'dan 3'e, %15 dördüncü özellik vektörüne, %50'ye kadar aynı aralıklarla alınır ve son olarak 25 sütunun özellik vektörünün %100 alınarak sıralama için veriler hazırlanır.

EKG sinyali ile her iki uygulama süreci için 11 grup oluşturulmuş ve minimum süre tespit modelleri için 660, alt frekans bant analizi için 594 olmak üzere toplam 1254

adet modele ait performans değerlendirme tabloları oluşturulmuştur. Bu tablolara göre en iyi model koyu renk ile belirtilmiştir.

Tüm öznitelik vektörleri kullanılarak oluşturulan model olan TKA, OMYH=1,36 ve R=0,97 SKB değerleriyle en iyi performans gösteren algoritma olarak belirlenmiştir.

Çalışma süreci, diğer frekans bantındaki sinyaller için aynı şekilde devam etmiştir. 0-128 Hz aralığındaki frekans bantı için her bir algoritmanın performansı değerlendirilerek SKB ve DKB tahmin modelleri oluşturulmuştur. Her bir frekans bant aralığı için EKG sinyali ile toplam 11 grup oluşturulmuş, 9 adet sinyal için toplam 99 adet ve 3 ayrı makine öğrenmesi için 297 adet modele ilişkin performans değerlendirme tabloları üretilmiştir (Tablo 6.22-Tablo 6.39). Tüm özellik vektörleri kullanılarak oluşturulan model için, TKA algoritması ile oluşturulmuş ham EKG sinyal modeli, OMYH=1,36 ve R=0,99 SKB değerleriyle en iyi performans gösteren model olmuştur. Aynı zamanda DKB tahmin modelleri için TKA algoritması, 5-58,5 Hz (QRS3) aralığındaki EKG sinyallerine ait model için hesaplanan OMYH=1,79 ve R=0,99 değerleri ile yüksek performans sergilemiştir (Tablo 6.35). 5-11 Hz aralığındaki EKG sinyali için (QRS2), 25 özellik vektörü vardır. Bu özellik vektörlerinin korelasyon düzeyi yüksek sütunları %5 aralıklarla alınmış ve 11 özellik için performans değerlendirmesi yapılmıştır. 11'inci özellik grubu için OMYH=1.5 ve R=0.99 SKB değerleri ile en iyi performans gösteren algoritma KA olarak belirlenmiştir (Tablo 6.25-Tablo 6.34). Her bir frekans aralığındaki sinyaller için aynı işlemler yapılmıştır. Saniyede 11'inci özellik vektörü en iyi performans gösteren grup olmuştur. Buna göre, TKA algoritması ile QRS3 için OMYH=1,38 ve R=0,99 SKB değerleri belirlenmiştir (Tablo 6.26). 3-40 Hz frekans bantındaki EKG sinyaline göre OMYH=1,37 ve R=0,99 SKB değerleri TKA algoritması kullanılarak hesaplanmıştır. Yavaş yavaş azalan hata oranları ile performans değerleri, 8-58,5 Hz aralığındaki EKG sinyali için OMYH=1,37 ve R=0,99 olarak hesaplanmıştır (Tablo 6.30). Frekans bant aralıklarının değiştiği her bir model git gide iyileşme göstermektedir. 8-20 Hz arasındaki frekans bantı modeli için OMYH=1,37 ve R=0,99 SKB değeri TKA algoritması için hesaplanmıştır (Tablo 6.28). 9-30 ve 2-40 Hz frekans bantı (QRS6 ve QRS7) için TKA algoritması ile hesaplanan modelin SKB performans değerleri aynı olup OMYH=1,37 ve R=0,99 değerlerindedir (Tablo 6.29-Tablo 6.30).

QRS4 bant aralığından sonra OMYH değerinde çok fazla bir değişim gözlemlenmez ancak her bir bantın basamak değerinde değişim mevcuttur.



Bu deęişimin önem arzettięi durumlarda bu ifadeler dikkate alınmalıdır. Tüm bunlara göre, EKG sinyali ve TKA algoritması kullanılarak KB tespitinin gerçekleştirilebileceęi deęerlendirilmektedir.

SKB için tanımlanan tablo modelleri DKB içinde geçerlidir. Tüm süreç için tablolar ayrı ayrı modellenmiştir (Tablo 6.31-Tablo 6.39). Tüm özellik gruplarını kullanan modeller, her bir frekans bant aralığı için en iyi performans gösteren model olarak deęerlendirilmektedir. Buna göre, ham EKG sinyali için  $OMYH=1,8$  ve  $R=0,99$  DKB elde edilmiştir (Tablo 6.31). Üst örneklenmiş EKG sinyali için,  $OMYH=1,78$  ve  $R=0,99$  DKB deęerleri TKA algoritması kullanılarak elde edilmiştir (Tablo 6.32). QRS1 bantı ile TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,79$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.33). QRS2 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,81$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.34). QRS3 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,84$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.35). QRS4 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,41$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.36). QRS5 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,37$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.37). QRS6 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,37$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.38). QRS7 bant aralığında TKA algoritması kullanılarak oluşturulan model için  $OMYH=1,36$  ve  $R=0,99$  DKB deęerleri elde edilmiştir (Tablo 6.39). DKB tahmini için oluşturulan modellerin performans tabloları dikkatle incelenmelidir. Her bir frekans bant aralığı için oluşturulan modellere ait tablolar dikkatle incelenmelidir. Her bir frekans bantı için  $OMYH$  deęerinde düşüş ve yükselişler beraberinde gözlemlenmiştir. Ancak bununla birlikte en düşük  $OMYH$  deęeri Tablo 6.37 ve Tablo 6.39'de TKA algoritması ile oluşturulan QRS5 ve QRS7 bantlarına ait model olmuştur. KB tahmin modelleri oluşturulurken istenen durum  $R$  deęerinin 1'e ve  $OMYH$  deęerinin ise 0'a oldukça yakın veya eşit olması istenmektedir. Tüm bunlara göre QRS5 ve QRS7 bantları için TKA algoritması ile en uygun DKB tahmin modeli oluşturulmuştur.

Bölüm 6.1 ve 6.2'ye göre hedeflenen kan basıncı tahmin modelleri oluşturulmuştur ve minimum sürede belirli frekans bant aralığında tespitler gerçekleştirilmiştir.

Kan basıncının 2-4-6...20 saniye aralıkları için tespit edilebilecek en uygun modelin 8 saniyelik EKG sinyali olabileceği değerlendirilmekte ancak hataların minimize edilebileceği gözardı edilmemelidir. Bu sebeple 10 saniyelik modele uygun bir iyileştirme sunulması hedefi ile belirli frekans bant aralıklarına ilişkin değerlendirme düşünülmüştür. Buna göre, SKB ve DKB tahmin modelleri oluşturulmuştur. Oluşturulan her bir frekans bant aralığı için modeller farklı performans göstermiştir. TKA algoritması kullanılarak her iki tahmin modeli için de en uygun modelin oluşturulabileceği görülmüştür.

Buna göre 10 saniyelik sürede, TKA yapay zekâ algoritması kullanılarak oluşturulan SKB ve DKB tahmin modelleri ile yüksek doğruluk oranında KB tahmini yapılabilecektir.

**Tablo 6.22.** Ham EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,26	14,34	205,44	14,33	NaN	NaN
			TKA	6,63	8,74	12,20	148,72	12,20	0,60	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,90	11,51	132,40	11,51	0,62	0,38
			TKA	5,66	7,44	10,76	115,69	10,76	0,69	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,42	11,51	0,62	0,38
			TKA	5,62	7,40	10,74	115,25	10,74	0,70	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,44	11,51	0,62	0,38
			TKA	5,69	7,49	10,83	117,17	10,82	0,69	0,47
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,70	7,51	10,85	117,63	10,85	0,69	0,48
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,77	2,44	4,18	17,44	4,18	0,98	0,96
			TKA	1,69	2,33	3,94	15,52	3,94	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,66	2,30	4,19	17,50	4,18	0,98	0,96
			TKA	1,61	2,23	3,87	14,98	3,87	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,28	18,28	4,28	0,98	0,96
			TKA	1,55	2,15	3,74	13,96	3,74	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,94	2,65	4,58	21,00	4,58	0,97	0,94
			TKA	1,60	2,22	3,89	15,08	3,88	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,08	2,81	4,62	21,37	4,62	0,97	0,94
			TKA	1,53	2,12	3,75	14,03	3,75	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,61	13,00	3,61	0,98	0,97
			TKA	<b>1,36</b>	<b>1,89</b>	<b>3,51</b>	<b>12,32</b>	<b>3,51</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.23.** Üst örneklenmiş EKG sinyalleri için SKB sonuçları.

D	Bilgi		Performans Değerlendirme Kriterleri							
	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,46	11,28	14,34	205,53	14,34	NaN	NaN
			TKA	6,59	8,69	12,13	147,08	12,13	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,69	7,48	10,79	116,25	10,78	0,69	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,67	7,46	10,81	116,86	10,81	0,69	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,45	11,51	0,62	0,38
			TKA	5,65	7,44	10,81	116,86	10,81	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,46	11,51	0,62	0,38
			TKA	5,73	7,55	10,89	118,51	10,89	0,69	0,47
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,79	2,46	4,20	17,59	4,19	0,98	0,95
			TKA	1,68	2,32	3,92	15,37	3,92	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,69	2,34	4,14	17,12	4,14	0,98	0,96
			TKA	1,61	2,22	3,86	14,85	3,85	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,75	2,42	4,26	18,15	4,26	0,98	0,95
			TKA	1,56	2,17	3,80	14,42	3,80	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,95	2,67	4,59	21,04	4,59	0,97	0,94
			TKA	1,58	2,19	3,83	14,64	3,83	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,05	2,77	4,62	21,32	4,62	0,97	0,94
			TKA	1,55	2,14	3,77	14,18	3,77	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,47	2,03	3,58	12,79	3,58	0,98	0,97
			TKA	<b>1,39</b>	<b>1,93</b>	<b>3,54</b>	<b>12,55</b>	<b>3,54</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.24.** QRS1 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,25	14,34	205,50	14,34	NaN	NaN
			TKA	6,62	8,74	12,16	147,83	12,16	0,60	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,73	8,91	11,51	132,43	11,51	0,62	0,38
			TKA	5,66	7,45	10,77	115,99	10,77	0,70	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,83	9,05	11,62	134,95	11,62	0,61	0,38
			TKA	5,64	7,42	10,81	116,71	10,80	0,70	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,44	11,51	0,62	0,38
			TKA	5,67	7,46	10,82	116,89	10,81	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,45	11,51	0,62	0,38
			TKA	5,70	7,50	10,84	117,43	10,84	0,69	0,48
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,79	2,46	4,21	17,68	4,21	0,98	0,95
			TKA	1,67	2,31	3,89	15,12	3,89	0,98	0,97
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,69	2,33	4,17	17,38	4,17	0,98	0,96
			TKA	1,64	2,26	3,88	15,06	3,88	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,75	2,41	4,27	18,19	4,27	0,98	0,95
			TKA	1,54	2,14	3,78	14,27	3,78	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,98	2,70	4,58	20,97	4,58	0,97	0,94
			TKA	1,62	2,24	3,87	14,94	3,86	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,04	2,76	4,62	21,34	4,62	0,97	0,94
			TKA	1,53	2,12	3,71	13,78	3,71	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,61	13,02	3,61	0,98	0,97
			TKA	<b>1,40</b>	<b>1,94</b>	<b>3,55</b>	<b>12,61</b>	<b>3,55</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.25.** QRS2 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,46	11,27	14,34	205,46	14,33	NaN	NaN
			TKA	6,59	8,69	12,13	146,90	12,12	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,90	11,51	132,43	11,51	0,62	0,38
			TKA	5,67	7,45	10,75	115,51	10,75	0,70	0,49
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,67	7,46	10,85	117,73	10,85	0,69	0,47
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,46	11,51	0,62	0,38
			TKA	5,69	7,49	10,83	117,11	10,82	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,45	11,51	0,62	0,38
			TKA	5,70	7,51	10,82	116,92	10,81	0,69	0,47
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,78	2,45	4,18	17,48	4,18	0,98	0,95
			TKA	1,68	2,32	3,91	15,24	3,90	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,66	2,30	4,19	17,52	4,19	0,98	0,96
			TKA	1,60	2,21	3,85	14,81	3,85	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,27	18,22	4,27	0,98	0,96
			TKA	1,57	2,18	3,79	14,33	3,79	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,96	2,68	4,57	20,89	4,57	0,97	0,94
			TKA	1,61	2,22	3,87	14,94	3,86	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,05	2,77	4,62	21,29	4,61	0,97	0,94
			TKA	1,52	2,12	3,68	13,51	3,67	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,02	3,63	13,14	3,63	0,98	0,97
			TKA	<b>1,37</b>	<b>1,90</b>	<b>3,53</b>	<b>12,44</b>	<b>3,53</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.26.** QRS3 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,25	14,34	205,47	14,33	NaN	NaN
			TKA	6,64	8,77	12,17	147,98	12,16	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,67	7,45	10,73	115,09	10,73	0,70	0,49
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,42	11,51	0,62	0,38
			TKA	5,65	7,43	10,77	116,00	10,77	0,69	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,43	11,51	0,62	0,38
			TKA	5,64	7,42	10,79	116,24	10,78	0,70	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,44	11,51	0,62	0,38
			TKA	5,69	7,49	10,85	117,57	10,84	0,69	0,47
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,79	2,46	4,19	17,58	4,19	0,98	0,95
			TKA	1,67	2,31	3,91	15,30	3,91	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,67	2,31	4,18	17,49	4,18	0,98	0,96
			TKA	1,68	2,32	3,95	15,61	3,95	0,98	0,96
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,26	18,10	4,25	0,98	0,96
			TKA	1,58	2,19	3,80	14,45	3,80	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	2,00	2,73	4,60	21,16	4,60	0,97	0,94
			TKA	1,61	2,22	3,88	15,02	3,88	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,04	2,76	4,62	21,29	4,61	0,97	0,94
			TKA	1,50	2,08	3,68	13,50	3,67	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,60	12,94	3,60	0,98	0,97
			TKA	<b>1,38</b>	<b>1,91</b>	<b>3,55</b>	<b>12,60</b>	<b>3,55</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.27.** QRS4 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,25	14,34	205,47	14,33	NaN	NaN
			TKA	6,62	8,74	12,18	148,31	12,18	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,91	11,51	132,43	11,51	0,62	0,38
			TKA	5,70	7,50	10,79	116,25	10,78	0,69	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,63	7,41	10,78	116,04	10,77	0,70	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,46	11,51	0,62	0,38
			TKA	5,69	7,49	10,83	117,27	10,83	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,43	11,51	0,62	0,38
			TKA	5,70	7,50	10,85	117,53	10,84	0,69	0,48
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,80	2,48	4,22	17,81	4,22	0,98	0,95
			TKA	1,70	2,34	3,98	15,81	3,98	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,67	2,31	4,18	17,49	4,18	0,98	0,96
			TKA	1,68	2,31	3,98	15,79	3,97	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,27	18,20	4,27	0,98	0,96
			TKA	1,57	2,18	3,80	14,46	3,80	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,97	2,68	4,57	20,89	4,57	0,97	0,94
			TKA	1,58	2,19	3,85	14,80	3,85	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,05	2,78	4,63	21,40	4,63	0,97	0,94
			TKA	1,52	2,11	3,75	14,02	3,74	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,47	2,03	3,58	12,80	3,58	0,98	0,97
			TKA	<b>1,40</b>	<b>1,94</b>	<b>3,62</b>	<b>13,11</b>	<b>3,62</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı



**Tablo 6.28.** QRS5 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,48	11,25	14,34	205,57	14,34	NaN	NaN
			TKA	6,59	8,70	12,15	147,41	12,14	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,71	8,89	11,51	132,36	11,50	0,62	0,38
			TKA	5,67	7,46	10,79	116,31	10,78	0,69	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,43	11,51	0,62	0,38
			TKA	5,66	7,44	10,78	116,18	10,78	0,69	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,43	11,51	0,62	0,38
			TKA	5,69	7,49	10,82	116,88	10,81	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,71	8,88	11,50	132,21	11,50	0,62	0,38
			TKA	5,71	7,51	10,83	117,22	10,83	0,69	0,47
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,79	2,46	4,19	17,55	4,19	0,98	0,95
			TKA	1,66	2,30	3,87	14,95	3,87	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,67	2,31	4,16	17,31	4,16	0,98	0,96
			TKA	1,65	2,28	3,93	15,44	3,93	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,75	2,41	4,27	18,26	4,27	0,98	0,96
			TKA	1,58	2,18	3,83	14,64	3,83	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,98	2,70	4,59	21,01	4,58	0,97	0,94
			TKA	1,62	2,23	3,90	15,20	3,90	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,01	2,73	4,64	21,50	4,64	0,97	0,94
			TKA	1,53	2,13	3,72	13,84	3,72	0,98	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,62	13,09	3,62	0,98	0,97
			TKA	<b>1,37</b>	<b>1,90</b>	<b>3,48</b>	<b>12,12</b>	<b>3,48</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.29.** QRS6 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,26	14,34	205,44	14,33	NaN	NaN
			TKA	6,60	8,71	12,14	147,30	12,14	0,61	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,71	8,89	11,51	132,33	11,50	0,62	0,38
			TKA	5,67	7,46	10,75	115,49	10,75	0,70	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,42	11,51	0,62	0,38
			TKA	5,69	7,50	10,86	117,75	10,85	0,69	0,47
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,89	11,51	132,40	11,51	0,62	0,38
			TKA	5,67	7,46	10,81	116,87	10,81	0,69	0,48
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,73	7,54	10,86	117,93	10,86	0,69	0,47
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,80	2,47	4,21	17,69	4,21	0,98	0,95
			TKA	1,70	2,35	3,96	15,68	3,96	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,68	2,32	4,17	17,36	4,17	0,98	0,96
			TKA	1,58	2,18	3,81	14,47	3,80	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,27	18,20	4,27	0,98	0,96
			TKA	1,56	2,17	3,80	14,39	3,79	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,99	2,71	4,59	21,08	4,59	0,97	0,94
			TKA	1,60	2,22	3,88	15,02	3,87	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,04	2,76	4,62	21,31	4,62	0,97	0,94
			TKA	1,52	2,12	3,73	13,94	3,73	0,98	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,60	12,93	3,60	0,98	0,97
			TKA	<b>1,37</b>	<b>1,89</b>	<b>3,51</b>	<b>12,32</b>	<b>3,51</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.30.** QRS7 frekans aralığındaki EKG sinyalleri için SKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	7,19	9,55	13,36	178,39	13,36	0,53	0,28
			GPR	8,47	11,26	14,34	205,44	14,33	NaN	NaN
			TKA	6,63	8,74	12,20	148,72	12,20	0,60	0,37
2	3	10	KA	6,30	8,33	12,42	154,14	12,42	0,60	0,36
			GPR	6,72	8,90	11,51	132,40	11,51	0,62	0,38
			TKA	5,66	7,44	10,76	115,69	10,76	0,69	0,48
3	4	15	KA	6,30	8,33	12,50	156,16	12,50	0,60	0,36
			GPR	6,72	8,90	11,51	132,42	11,51	0,62	0,38
			TKA	5,62	7,40	10,74	115,25	10,74	0,70	0,48
4	5	20	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,44	11,51	0,62	0,38
			TKA	5,69	7,49	10,83	117,17	10,82	0,69	0,47
5	6	25	KA	6,34	8,39	12,57	157,76	12,56	0,59	0,35
			GPR	6,72	8,90	11,51	132,41	11,51	0,62	0,38
			TKA	5,70	7,51	10,85	117,63	10,85	0,69	0,48
6	8	30	KA	1,88	2,63	4,62	21,36	4,62	0,98	0,96
			GPR	1,77	2,44	4,18	17,44	4,18	0,98	0,96
			TKA	1,69	2,33	3,94	15,52	3,94	0,98	0,96
7	9	35	KA	1,71	2,40	4,50	20,28	4,50	0,98	0,96
			GPR	1,66	2,30	4,19	17,50	4,18	0,98	0,96
			TKA	1,61	2,23	3,87	14,98	3,87	0,98	0,97
8	10	40	KA	1,71	2,40	4,40	19,34	4,40	0,98	0,97
			GPR	1,74	2,40	4,28	18,28	4,28	0,98	0,96
			TKA	1,55	2,15	3,74	13,96	3,74	0,98	0,97
9	11	45	KA	1,70	2,39	4,33	18,73	4,33	0,98	0,96
			GPR	1,94	2,65	4,58	21,00	4,58	0,97	0,94
			TKA	1,60	2,22	3,89	15,08	3,88	0,98	0,97
10	13	50	KA	1,57	2,21	4,13	17,06	4,13	0,98	0,97
			GPR	2,08	2,81	4,62	21,37	4,62	0,97	0,94
			TKA	1,53	2,12	3,75	14,03	3,75	0,99	0,97
11	25	100	KA	1,51	2,13	4,35	18,95	4,35	0,99	0,97
			GPR	1,46	2,01	3,61	13,00	3,61	0,98	0,97
			TKA	<b>1,36</b>	<b>1,89</b>	<b>3,51</b>	<b>12,32</b>	<b>3,51</b>	<b>0,99</b>	<b>0,98</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.31.** Ham EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,88	9,30	86,45	9,30	NaN	NaN
			TKA	7,36	5,56	8,21	67,31	8,20	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,33	5,57	7,75	59,97	7,74	0,62	0,38
			TKA	6,34	4,77	7,31	53,43	7,31	0,68	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,29	4,74	7,31	53,39	7,31	0,68	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,56	7,75	59,99	7,75	0,62	0,38
			TKA	6,30	4,74	7,33	53,62	7,32	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,29	4,73	7,31	53,41	7,31	0,68	0,47
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,34	1,85	3,56	12,65	3,56	0,97	0,95
			TKA	2,21	1,74	3,39	11,47	3,39	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,18	1,73	3,54	12,49	3,53	0,98	0,95
			TKA	2,11	1,67	3,32	11,00	3,32	0,98	0,96
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,29	1,81	3,56	12,67	3,56	0,97	0,95
			TKA	2,03	1,61	3,27	10,69	3,27	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,58	2,03	3,76	14,10	3,75	0,97	0,93
			TKA	2,12	1,68	3,32	11,00	3,32	0,98	0,96
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,56	2,00	3,73	13,87	3,72	0,97	0,93
			TKA	2,04	1,62	3,28	10,76	3,28	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,93	1,54	3,08	9,51	3,08	0,98	0,96
			TKA	<b>1,80</b>	<b>1,43</b>	<b>3,03</b>	<b>9,17</b>	<b>3,03</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.32.** Üst örneklenmiş EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,86	9,30	86,43	9,30	NaN	NaN
			TKA	7,33	5,54	8,18	66,81	8,17	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,28	4,72	7,28	52,93	7,28	0,68	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,30	4,74	7,33	53,74	7,33	0,68	0,46
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	60,00	7,75	0,62	0,38
			TKA	6,35	4,78	7,35	53,92	7,34	0,68	0,46
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,36	4,78	7,34	53,77	7,33	0,68	0,47
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,36	1,86	3,56	12,67	3,56	0,97	0,95
			TKA	2,18	1,73	3,35	11,20	3,35	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,19	1,74	3,50	12,23	3,50	0,98	0,95
			TKA	2,10	1,66	3,30	10,88	3,30	0,98	0,97
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,24	1,78	3,59	12,88	3,59	0,98	0,95
			TKA	2,05	1,63	3,26	10,63	3,26	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,57	2,02	3,75	14,02	3,74	0,97	0,93
			TKA	2,13	1,69	3,36	11,31	3,36	0,98	0,96
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,59	2,02	3,71	13,73	3,70	0,97	0,93
			TKA	2,04	1,62	3,26	10,59	3,25	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,92	1,53	3,04	9,22	3,04	0,98	0,96
			TKA	<b>1,78</b>	<b>1,42</b>	<b>3,04</b>	<b>9,24</b>	<b>3,04</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.33.** QRS1 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,86	9,30	86,43	9,30	NaN	NaN
			TKA	7,34	5,55	8,22	67,49	8,22	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,31	4,74	7,30	53,25	7,30	0,69	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,44	5,66	7,80	60,82	7,80	0,61	0,38
			TKA	6,32	4,75	7,32	53,53	7,32	0,68	0,46
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,31	4,75	7,33	53,67	7,33	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,37	4,80	7,35	54,00	7,35	0,68	0,46
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,36	1,86	3,58	12,78	3,58	0,97	0,95
			TKA	2,19	1,73	3,33	11,09	3,33	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,20	1,75	3,48	12,07	3,47	0,98	0,95
			TKA	2,06	1,64	3,25	10,57	3,25	0,98	0,97
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,25	1,79	3,56	12,66	3,56	0,98	0,95
			TKA	2,00	1,60	3,19	10,19	3,19	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,51	1,98	3,73	13,91	3,73	0,97	0,94
			TKA	2,04	1,63	3,30	10,87	3,30	0,98	0,97
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,60	2,03	3,71	13,74	3,71	0,97	0,93
			TKA	2,03	1,61	3,24	10,50	3,24	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,91	1,52	3,05	9,27	3,05	0,98	0,96
			TKA	<b>1,79</b>	<b>1,43</b>	<b>3,05</b>	<b>9,32</b>	<b>3,05</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.34.** QRS2 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,86	9,30	86,42	9,30	NaN	NaN
			TKA	7,32	5,54	8,20	67,24	8,20	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,32	5,56	7,75	59,97	7,74	0,62	0,38
			TKA	6,28	4,72	7,29	53,09	7,29	0,69	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,28	4,72	7,29	53,11	7,29	0,68	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,36	4,79	7,35	53,99	7,35	0,68	0,46
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,38	4,80	7,37	54,23	7,36	0,68	0,46
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,32	1,83	3,57	12,71	3,57	0,98	0,95
			TKA	2,19	1,74	3,34	11,18	3,34	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,19	1,74	3,50	12,25	3,50	0,98	0,95
			TKA	2,08	1,66	3,27	10,66	3,27	0,98	0,96
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,28	1,81	3,55	12,56	3,54	0,97	0,95
			TKA	1,97	1,58	3,18	10,09	3,18	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,51	1,98	3,73	13,90	3,73	0,97	0,94
			TKA	2,10	1,66	3,33	11,05	3,32	0,98	0,96
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,62	2,04	3,71	13,73	3,71	0,97	0,93
			TKA	2,03	1,61	3,25	10,55	3,25	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,95	1,55	3,14	9,87	3,14	0,98	0,96
			TKA	<b>1,81</b>	<b>1,44</b>	<b>3,07</b>	<b>9,40</b>	<b>3,07</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.35.** QRS3 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,97	6,90	9,31	86,58	9,30	NaN	NaN
			TKA	7,37	5,57	8,23	67,64	8,22	0,60	0,35
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,44	5,66	7,81	60,87	7,80	0,61	0,38
			TKA	6,31	4,74	7,27	52,87	7,27	0,69	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,97	7,74	0,62	0,38
			TKA	6,33	4,76	7,33	53,72	7,33	0,68	0,46
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,31	4,74	7,33	53,66	7,33	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,32	4,75	7,32	53,59	7,32	0,68	0,46
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,33	1,84	3,57	12,72	3,57	0,98	0,95
			TKA	2,21	1,74	3,38	11,44	3,38	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,19	1,74	3,50	12,21	3,49	0,98	0,95
			TKA	2,07	1,64	3,25	10,55	3,25	0,98	0,96
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,27	1,80	3,64	13,23	3,64	0,97	0,95
			TKA	2,01	1,61	3,21	10,31	3,21	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,56	2,01	3,74	13,97	3,74	0,97	0,93
			TKA	2,08	1,65	3,29	10,84	3,29	0,98	0,97
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,56	2,00	3,72	13,84	3,72	0,97	0,93
			TKA	2,01	1,59	3,24	10,47	3,24	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,91	1,52	3,04	9,22	3,04	0,98	0,96
			TKA	<b>1,84</b>	<b>1,46</b>	<b>3,15</b>	<b>9,90</b>	<b>3,15</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı



**Tablo 6.36.** QRS4 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi				Performans Değerlendirme Kriterleri						
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,97	6,84	9,31	86,52	9,30	NaN	NaN
			TKA	7,34	5,55	8,20	67,16	8,20	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,33	5,57	7,75	59,97	7,74	0,62	0,38
			TKA	6,30	4,74	7,29	53,15	7,29	0,69	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,30	4,74	7,31	53,42	7,31	0,68	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,30	4,74	7,31	53,47	7,31	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,37	4,79	7,36	54,15	7,36	0,68	0,46
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,36	1,86	3,57	12,74	3,57	0,97	0,95
			TKA	2,16	1,71	3,31	10,94	3,31	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,20	1,75	3,47	12,06	3,47	0,98	0,95
			TKA	2,13	1,68	3,33	11,06	3,33	0,98	0,96
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,30	1,82	3,56	12,65	3,56	0,97	0,95
			TKA	2,02	1,61	3,24	10,48	3,24	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,55	2,01	3,74	13,98	3,74	0,97	0,93
			TKA	2,10	1,66	3,29	10,84	3,29	0,98	0,97
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,60	2,03	3,70	13,70	3,70	0,97	0,93
			TKA	1,97	1,57	3,17	10,02	3,17	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,91	1,52	3,04	9,24	3,04	0,98	0,96
			TKA	<b>1,81</b>	<b>1,44</b>	<b>3,08</b>	<b>9,45</b>	<b>3,07</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.37.** QRS5 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,89	9,30	86,51	9,30	NaN	NaN
			TKA	7,31	5,53	8,18	66,90	8,18	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,32	5,56	7,75	59,97	7,74	0,61	0,38
			TKA	6,30	4,74	7,30	53,20	7,29	0,69	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,56	7,75	59,97	7,74	0,62	0,38
			TKA	6,28	4,72	7,29	53,09	7,29	0,69	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,33	4,76	7,33	53,72	7,33	0,68	0,46
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,35	5,58	7,75	60,03	7,75	0,62	0,38
			TKA	6,34	4,77	7,32	53,50	7,31	0,68	0,47
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,33	1,83	3,57	12,72	3,57	0,98	0,95
			TKA	2,19	1,73	3,35	11,18	3,34	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,17	1,72	3,53	12,43	3,53	0,98	0,95
			TKA	2,07	1,63	3,29	10,82	3,29	0,98	0,97
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,25	1,79	3,61	13,05	3,61	0,98	0,95
			TKA	2,00	1,59	3,22	10,36	3,22	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,52	1,99	3,73	13,92	3,73	0,97	0,94
			TKA	2,10	1,66	3,34	11,13	3,34	0,98	0,97
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,55	2,00	3,73	13,89	3,73	0,97	0,93
			TKA	1,96	1,56	3,21	10,29	3,21	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,91	1,52	3,05	9,30	3,05	0,98	0,96
			TKA	<b>1,84</b>	<b>1,46</b>	<b>3,14</b>	<b>9,84</b>	<b>3,14</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.38.** QRS6 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	R <sup>2</sup>
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,87	9,30	86,44	9,30	NaN	NaN
			TKA	7,34	5,55	8,22	67,44	8,21	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,44	5,66	7,80	60,83	7,80	0,61	0,38
			TKA	6,35	4,78	7,32	53,57	7,32	0,68	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,35	5,58	7,75	60,05	7,75	0,62	0,38
			TKA	6,31	4,75	7,31	53,40	7,31	0,68	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,34	5,57	7,75	60,00	7,75	0,62	0,38
			TKA	6,32	4,76	7,34	53,84	7,34	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,33	4,77	7,31	53,46	7,31	0,68	0,47
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,32	1,83	3,56	12,64	3,55	0,98	0,95
			TKA	2,21	1,75	3,38	11,42	3,38	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,20	1,75	3,47	12,01	3,47	0,98	0,95
			TKA	2,03	1,62	3,26	10,64	3,26	0,98	0,97
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,29	1,81	3,56	12,65	3,56	0,97	0,95
			TKA	2,01	1,60	3,22	10,34	3,22	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,49	1,96	3,74	13,97	3,74	0,97	0,94
			TKA	2,11	1,67	3,36	11,25	3,35	0,98	0,96
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,67	2,09	3,71	13,76	3,71	0,96	0,93
			TKA	1,98	1,58	3,19	10,19	3,19	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,91	1,52	3,05	9,31	3,05	0,98	0,96
			TKA	<b>1,84</b>	<b>1,46</b>	<b>3,08</b>	<b>9,48</b>	<b>3,08</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.39.** QRS7 frekans aralığındaki EKG sinyalleri için DKB sonuçları.

Bilgi			Performans Değerlendirme Kriterleri							
D	ÖS	ÖY	Model	OMYH (%)	OMH	SH	OKH	KOKH	R	$R^2$
1	1	5	KA	8,08	6,16	9,04	81,72	9,04	0,50	0,25
			GPR	8,96	6,88	9,30	86,45	9,30	NaN	NaN
			TKA	7,36	5,56	8,21	67,31	8,20	0,60	0,36
2	3	10	KA	7,20	5,44	8,47	71,72	8,47	0,58	0,33
			GPR	7,33	5,57	7,75	59,97	7,74	0,62	0,38
			TKA	6,34	4,77	7,31	53,43	7,31	0,68	0,47
3	4	15	KA	7,18	5,44	8,46	71,43	8,45	0,58	0,34
			GPR	7,33	5,57	7,75	59,98	7,74	0,62	0,38
			TKA	6,29	4,74	7,31	53,39	7,31	0,68	0,47
4	5	20	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,56	7,75	59,99	7,75	0,62	0,38
			TKA	6,30	4,74	7,33	53,62	7,32	0,68	0,47
5	6	25	KA	7,17	5,43	8,46	71,58	8,46	0,58	0,34
			GPR	7,33	5,57	7,75	59,99	7,75	0,62	0,38
			TKA	6,29	4,73	7,31	53,41	7,31	0,68	0,47
6	8	30	KA	2,34	1,89	3,83	14,66	3,83	0,98	0,96
			GPR	2,34	1,85	3,56	12,65	3,56	0,97	0,95
			TKA	2,21	1,74	3,39	11,47	3,39	0,98	0,96
7	9	35	KA	2,16	1,76	3,63	13,17	3,63	0,98	0,97
			GPR	2,18	1,73	3,54	12,49	3,53	0,98	0,95
			TKA	2,11	1,67	3,32	11,00	3,32	0,98	0,96
8	10	40	KA	2,17	1,76	3,66	13,36	3,66	0,98	0,97
			GPR	2,29	1,81	3,56	12,67	3,56	0,97	0,95
			TKA	2,03	1,61	3,27	10,69	3,27	0,98	0,97
9	11	45	KA	2,18	1,77	3,70	13,66	3,70	0,98	0,96
			GPR	2,58	2,03	3,76	14,10	3,75	0,97	0,93
			TKA	2,12	1,68	3,32	11,00	3,32	0,98	0,96
10	13	50	KA	2,14	1,73	3,64	13,24	3,64	0,98	0,97
			GPR	2,56	2,00	3,73	13,87	3,72	0,97	0,93
			TKA	2,04	1,62	3,28	10,76	3,28	0,98	0,97
11	25	100	KA	1,98	1,62	3,69	13,59	3,69	0,99	0,97
			GPR	1,93	1,54	3,08	9,51	3,08	0,98	0,96
			TKA	<b>1,80</b>	<b>1,43</b>	<b>3,03</b>	<b>9,17</b>	<b>3,03</b>	<b>0,99</b>	<b>0,97</b>

D: Düzey, ÖS: Özellik Sayısı, ÖY: Özellik Yüzdesi

KA: Karar Ağacı, GPR: Gauss Süreç Regresyonu, TKA: Topluluk Karar Ağacı

**Tablo 6.40.** 10 s süre için en iyi sonuç veren frekans bantlarına dair SKB ve DKB tahmin sonuçları.

Frekans Bant Aralığı	Bilgi			Performans Değerlendirme Kriterleri						
	KB	ÖS	Model	OMYH (%)	OMS	SH	OKH	KOKH	R	R <sup>2</sup>
Ham	SKB	11	TKA	1,36	1,89	3,51	12,32	3,51	0,99	0,98
	DKB	11	TKA	1,80	1,43	3,03	9,17	3,03	0,99	0,97
Üst	SKB	11	TKA	1,39	1,93	3,54	12,55	3,54	0,99	0,98
	DKB	11	TKA	1,78	1,42	3,04	9,24	3,04	0,99	0,97
Örneklenmiş	SKB	11	TKA	1,40	1,94	3,55	12,61	3,55	0,99	0,98
	DKB	11	TKA	1,79	1,43	3,05	9,32	3,05	0,99	0,97
QRS1	SKB	11	TKA	1,37	1,90	3,53	12,44	3,53	0,99	0,98
	DKB	11	TKA	1,81	1,44	3,07	9,40	3,07	0,99	0,97
QRS2	SKB	11	TKA	1,38	1,91	3,55	12,60	3,55	0,99	0,98
	DKB	11	TKA	1,81	1,46	3,15	9,90	3,15	0,99	0,97
QRS3	SKB	11	TKA	1,40	1,94	3,62	13,11	3,62	0,99	0,98
	DKB	11	TKA	1,81	1,44	3,08	9,45	3,07	0,99	0,97
QRS4	SKB	11	TKA	1,37	1,90	3,48	12,12	3,48	0,99	0,98
	DKB	11	TKA	1,84	1,46	3,14	9,84	3,14	0,99	0,97
QRS5	SKB	11	TKA	1,37	1,89	3,51	12,32	3,51	0,99	0,98
	DKB	11	TKA	1,84	1,46	3,08	9,48	3,08	0,99	0,97
QRS6	SKB	11	TKA	<b>1,36</b>	<b>1,89</b>	<b>3,51</b>	<b>12,32</b>	<b>3,51</b>	<b>0,99</b>	<b>0,98</b>
	DKB	11	TKA	<b>1,80</b>	<b>1,43</b>	<b>3,03</b>	<b>9,17</b>	<b>3,03</b>	<b>0,99</b>	<b>0,97</b>
QRS7	SKB	11	TKA							
	DKB	11	TKA							

ÖS: Özellik Sayısı, KB: Kan Basıncı, SKB: Sistolik Kan Basıncı, DKB: Diyastolik Kan Basıncı

TKA: Topluluk Karar Ağacı Algoritması, GSR: Gauss Süreç Regresyonu



## 7. TARTIŞMA VE KARAR

### 7.1. Tartışma

Hipertansiyon sessiz katil olarak bilindiğinden, hipertansiyonu olan hastalar sürekli takip edilmelidir [1, 3]. Hipertansiyonu kontrol altında tutmak için hastaların ilaç tedavilerine sıkı bir şekilde uymaları beklenir [3]. Hipertansiyonun evde sürekli izlenmesi için teknik bilgiye ihtiyaç duymadan kullanılabilir yeni teknolojilere ihtiyaç vardır [2, 3]. Bu çalışma, hipertansiyon hastalarında EKG sinyaline dayalı minimum KB zaman yanıtını hesaplamayı ve alt frekans bantlarındaki yanıtlarını değerlendirmeyi amaçlamaktadır. Çalışmada ilk olarak beş kişinin EKG sinyal verileri toplanmıştır. Sinyaller daha sonra 2-4-6-8-10-12-14-16-18-20 saniyelik epoklara bölünmüştür. Zaman alanındaki her bir sinyalden 25 istatistiksel özellik çıkarılmıştır. Modelin gereksiz iş yükünü azaltmak ve boyut optimizasyonu sağlamak için özellik seçim algoritması kullanılır. TKA, GSR ve KA algoritmaları ile KB tahmini için seçilen özellikler kullanılmıştır. Her bir epok için KB tahmin performans değerleri belirli özellikler dahilinde hesaplanmış ve tablolara kaydedilmiştir (Tablo 6.1-Tablo 6.20). Bu tablolara göre KB tahmini minimum zamanda değerlendirilebilir. Çalışmada önerilen model zaman aşımı açısından literatürdeki çalışmalardan önemli ölçüde farklılık göstermektedir. Her epok için KB hesaplaması yapılmıştır. Hesaplanan KB değerleri, her adımda benzersiz bir yapı sergilemiştir ve performans artışı göstermiştir. İlk olarak EKG sinyali için istatistiksel girdiler belirlendikten sonra modelin performansının bazı özellikler karşısında düşük olduğu belirlenmiştir. Öte yandan, veri boyutu optimize edilerek gereksiz özellikler kaldırılmıştır. Bu sayede yüksek korelasyon seviyelerine sahip veri setlerinde performans artışı gözlemlenmiştir. Kademeli olarak geliştirilmeye çalışılan bu sistemde periyodik gözlemler grafiksel olarak yapılmış ve yüksek doğruluk oranı ile minimum zaman tespiti sağlanmıştır. Önerilen model şu ana kadar literatürde elde edilen yüksek doğruluğa sahip algoritmalar arasındadır (Tablo 7.2, R=0,98).

Çalışmanın en dikkat çekici özelliği, EKG sinyalini epoklama yaparak her epok için KB değerlerini tespit etmesidir.

EKG, PPG ve KB özellikleriyle ilgili arařtırmalar, literatüründe kapsamlı bir şekilde yürütölmektedir [30, 32, 40]. Bu sinyaller arasında, alıřmanın arařtırma konusu olan EKG sinyalinde bir kalp atıřında sergilenen QRS ve diđer bileřenler genellikle özellik giriři olarak tercih edilmektedir [32, 33, 38]. EKG sinyalindeki deęiřiklikler nedeniyle, özellik ıkarma iř yüküne ve hesaplama karmařıklıđına neden olabilir. Öte yandan, istatistiksel parametreler kullanılmıř ve epoklara ait EKG sinyalleri üzerinde KB tahmini performans deęerlendirmesi yapılmıřtır. Minimum sürede hesaplanabilecek en iyi performans deęeri  $R=0,98$ 'dir (Tablo 6.21- 16 Saniye). KB'nin iki saniye boyunca yüksek doęrulukla tespit edilebildiđi ve bu süre ierisinde uygulamaların yapılabileceđi anlařılmaktadır. alıřmada, KB tahmini iin 10 saniyelik epoklanmış sinyal modeli kullanılmıřtır. Bunun nedeni, hata oranını azaltılabilmesi ve bir epoktaki minimum ve maksimum noktaların gözlemlenebilmesidir. EKG ve KB benzer sinyallerdir. KB sinyalinin yerel minimum noktalarının ve yerel maksimum noktalarının ortalamaları, sırasıyla DKB ve SKB deęerlerine karřılık gelir. Bu noktaların okluđu hata oranını azaltır ve yürütme süresini artırır. Bu durumda tasarım gerekleřtirilmiřtir. Literatür arařtırmalarında henüz belirli bir sürede KB belirlemeye yönelik bir arařtırma yapılmamıřtır. alıřma özgün bir arařtırma konusu olmasına rađmen yeni arařtırma sorularına cevap verebilecek alt yapıya sahiptir. Buna göre, kaç saniyelik EKG kaydı ile son derece doęru bir KB tahmin modeli geliřtirilebilir? Hangi frekans bant aralıđında EKG kaydından yüksek doęrulukta kan basıncı tespiti gerekleřtirilir? alıřma bulguları, en az iki saniyelik epoklu bir EKG sinyali ile KB tahmininin yapılabileceđini göstermektedir. Bununla birlikte, en yüksek performans 16 saniyelik epokta elde edilmiřtir ancak performans deęiřikliđi kayda deđer deęildir. Bu nedenle farklı sinyal iřleme süreçleri ile iki saniyelik epoklardan yüksek performans elde edilebileceđi düşünölmektedir. Bu sonuçlara binaen uygun olarak düşünölen 10 saniyelik epoklama süresince alt frekans bant aralıkları incelenerek model performansı deęerlendirilmiřtir. alıřmanın ikinci safhasında, alt frekans bantlarında EKG sinyalinin KB ile iliřkisi incelenmektedir. Bu süreçte belirli frekans bantlarında sinyalinden alınan girdilerin KB ile iliřkisi incelenmiřtir. Bu tür alıřmalar literatürde de mevcuttur (Tablo 7.1). Ancak bu alıřmaların her biri farklı uygulama süreçlerini kapsamaktadır. Bu alıřma temelde regresyon modellerini kullanarak frekans bant analizi gerekleřtirmiřtir.



Ancak diğ er ç alıřmalar sınıflandırma yöntemi ile frekans bant ayırımı düşüncesinde uygulamalarını gerçekleřtirmiřtir. Bu düşüncedeki ç alıřmaların büyük çoğunluđu EKG’de bulunan QRS kompleksi tespiti üzerine olmuřtur. Ancak bu ç alıřma frekans bantını edinilen bilginin niteliğini ö ne ç ıkarmak ve iliřkili bant aralığ ının EKG ile KB tespitinin mümkün kılınmasını sađlama önceliđiyle gerçekleřtirilmiřtir. Literatürde EKG kayıtları belirli frekans bantlarına ayrılarak, EKG sinyalinin nokta nokta (beat to beat) incelemesi yapılmıřtır ve QRS komplekslerinin tespitinin farklı ya da ilave yöntemler dahilinde uygulamaları geliřtirilmiřtir (Tablo 7.1). Thakor et al. 5-15 Hz EKG kaydının maksimum QRS enerjisini taşıdığını ileri sürmüř ve QRS kompleksi tespitini üzerine ç alıřmasını yürütmüřtür[109]. Pan ve Tompkins kaskat yapıda tasarladıkları alç ak geçiren ve yüksek geçiren filtreleri kullanmıřlardır. Yaklařık 5-11 Hz aralığ ında 3 dB bant geçiren filtre elde etmek için frekans bant ayırımını kullanmıřlardır. Cuiwei et al., ikinci dereceden bir spline dalga kullanmıřtır. QRS kompleksinin enerjisinin çoğunun  $2^3$  ve  $2^4$  ölçeklerinde olduđu hükmüne varmıřlardır. Bu da frekans aralıđı 8-58,5 Hz aralıđına karş ılık gelmektedir. Sahambi et al., yine aynı düşüncede olup yalnızca Gauss dalgacığ ının birinci dereceden türevinin kullanımı ile aynı yargıya varmıřtır. Ancak bu kiřiler QRS kompleksinin enerjisinin 3-40 Hz aralığ ında olduđ unu düşünmüřlerdir. Benitez et al., Hilbert dönüşüm özelliđini kullanarak QRS tespit algoritması oluřturmuřtur. Moraes et al., iki geliřmiř algoritmayı birleřtirdi ve 9-30 Hz aralığ ında bant geçiren filtre kullanmıřtır. Mahmoodabadi et al ise frekans aralıđı 2-40 Hz olan  $2^3$  ve  $2^5$  ölçeklerini kullanarak QRS tespitini gerçekleřtirmiřtir. Tüm bu ç alıřmalara göre iliřkili bilginin nerede mevcut olduđu her yazarın ç alıřmalarında farklılık göstermiřtir. Ayrıca EKG alt frekans bantı sinyal bilgisinin bařka bir deđer ile iliřkisinin incelenmesi üzerine bir ç alıřmaya rastlanılmadıđ ı görölmektedir. Ancak edinilen bilgiler ış ığ ında EKG bilgisinde enerji yoğunluđ unun bulunduđu bantda farklı edinimlerin elde edileceđ i görölmüřtür.

Buna göre, ç alıřma kapsamının farklı dođrultularda farklı bakıřlar ile genişletilebileceđ i deđerlendirilir. Hayati bulguların bir ifadesi olan EKG iřaretinden yapılabilecek ç ıkarımların sınırsız olduđu ve pek çok soruya cevap verebilecek yenilikçi yapay zekâ yöntemlerinin mevcut olduđu deđerlendirilir.

**Tablo 7.1.** Frekans bant aralıkları ile ilişkili literatür çalışmaları

Literatürdeki ilişkili çalışmalar	Frekans bant aralıkları
Thakor et al.1983 [109]	5-15 Hz
Pan and Tompkins, 1985[110]	5-11 Hz
Cuiwei et al., 1995 [111]	8-58,5 Hz
Sahambi et al., 1997[112]	3-40 Hz
Benitez et al., 2000[113]	8-20 Hz
Moraes et al., 2002[114]	9-30 Hz
Mahmoodabadi et al., 2005[115]	2-40 Hz

Veri kümeleri, tanımlayıcı istatistiksel parametreler yardımıyla önemli ölçüde özetlenmiştir. Bu çalışmada 25 özellik setli EKG sinyali daha net bir veri setine dönüştürülmüştür (Tablo 4.3). Literatürdeki çalışmalar genellikle belirli özelliklere dayanmaktadır [30, 32, 33]. Ayrıca zamansal, kaotik ve morfolojik özellikler derin öğrenme temelli çalışmalarda en çok tercih edilenlerdir [20, 33]. Ancak farklı özellik çıkarma algoritmalarına dayalı çalışmalar performans açısından yetersiz görünmektedir [27, 38]. Bu açıdan çalışmada kullanılan öznelik çıkarma algoritmasının literatüre göre daha iyi bir yapıya sahip olduğu düşünülebilir.

Klasik makine öğrenmesi yöntemleri ile özellik seçme işlemi önerilir. Ancak bu süreç birçok KB tahmin çalışmasında uygulanmamıştır [26, 30, 32]. Özellik seçim algoritması, kullanılan modelin boyutunu optimize ederek ve gereksiz özellikleri ortadan kaldırarak iyi bir model oluşumu sağlamış ve modellerin performansı bakımından literatürden daha iyi değer sunmuştur.

Önerilen modeldeki TKA, GSR ve KA algoritmaları, model performansının belirlenmesinde önemli bir unsur olmuştur. Bu modellerin her bir epoklanmış sinyal üzerindeki performans değerleri, o algoritmanın epoklanmış veri seti ile ne kadar uyumlu olduğunu gösterir. Bu durum, Tablo 6.21'deki epoklanmış sinyaller arasında algoritma varyasyonu olduğunu gösterir. Önerilen modeller performans açısından literatürdeki çalışmalardan bir adım öndedir (Tablo 7.2).

**Tablo 7.2.** Çalışma alanına ilişkin genel literatür taraması

No	Yıl	Sinyal	Model Yöntemleri		Diyastolik/Sistolik Kan Basıncı Performansları														
			Özellikler	Yöntem	OMYH	OMH	SH	OKH	KOKH	R	R <sup>2</sup>	OMYH	OMS	SH	OKH	KOKH	R	R <sup>2</sup>	
1	2020	Osilometrik Dalga Formu	Grafiksel Özellikler	WkNN		11,032		200,531	14,161	0,423	0,179		3,520		41,998	6,480	0,948	0,899	
2	2020	Oskültasyon ve osilometrik dalga formu	Zaman Domeni	GMM-HMM		2,900							-0,9						
3	2020	PPG- EKG	Kaotik, zaman ve frekans domeni	RNN				1,730	1,240	0,854	0,730				1,210	0,780	0,849	0,720	
4	2020	Oscillometric waveforms	Kaotik, zaman ve frekans domeni	GPR	0,2878	4,2705		28,843	5,371	0,891	0,794	0,114	3,636		23,845	4,883	0,962	0,925	
5	2021	Periferik özellikler	Hibrit	MLR					3,000	0,970	0,941						3,000	0,970	0,941
6	2020	PPG- ECG	Zaman domeni	RF		5,48			6,000	0,840	0,706		9,000				13,830	0,850	0,723
7	2020	Ses	Sesli Harfler	CNN-R					0,350								0,236		
8	2019	PPT- PIR	SSR- CHC	MARS	3,630								7,830						
9	2020	PPG	PPG Segment Serisi	CNN-LSTM		3,97				0,950	0,903	0,670						0,950	0,903
10	2021	PPG	Çoklu Tip Özelliği	MTFF-ANN		3,36								5,590					

CHC: Kalp akım döngüsü  
CNN-R: Geleneksel Sinir Ağları  
GMM-HMM: Gauss Karışım Modelleri ve Gizli Markov  
LSTM: Uzun Kısa Süreli Bellek  
MARS: Çoklu Uyarlamalı Regresyon Çizgisi  
MLR: Çoklu doğrusal regresyon

MTFF-ANN: Çoklu Özellik Füzyon Yapay Sinir Ağı (2 CNN+1 LSTM)  
PIR: Fotopletismogram Yoğunluk Oranı  
PPG: Fotopletismografi  
PPT: Darbe Geçiş Süresi  
RNN: Tekrarlayan Sinir Ağları  
SSR: Durum Alanı Yeniden İnşası  
WkNN: Ağırlıklı k-Yakın Komşu

## 7.2. Güçlü Yönler ve Sınırlamalar

Sürekli manşonsuz KB tahmini, özellik çıkarımı ve kalibrasyon gerektirmeyen değerlendirme süreçleri açısından yapay zekâ algoritmalarının kullanılması, doğru teşhis ve tedavi için hala tartışma konusudur. Bu çalışma, çeşitli makine öğrenme tekniklerini kullanarak performanslarını karşılaştırır. EKG sinyallerine epoklama işlemi uygulanarak her bir epoklanmış sinyalden istatistiksel özellik çıkarımı uygulanmıştır. Yapay zekâ tekniklerinin değerlendirildiği veri seti, her bir epok için yüksek performans göstermiştir. Model için farklı özellik setleri çıkarılmış olmasına rağmen, EKG sinyalinin morfolojik özellikleri araştırılmamıştır. Ek olarak, deneklerin demografik bilgilerinin artırılması, KB tahmin performansını iyileştirebilir. Veri setinin toplanmasında teknik aksaklıklar olsa bile yazılım ortamında sinyale uygulanan işlemler bu veri kaybını engellemekte ve performansa etkisi minimuma indirilmektedir.

## 7.3. Karar

KB'nin izlenmesi, hipertansiyonun takip ve tedavisi için hayati önem taşımaktadır. Evde KB izleme için yeni güvenilir standartlarla uyumlu algoritmalar ve cihazlar gereklidir. Bu teknolojilerin zahmetsiz ölçüm sunması bekleniyor. Bu çalışmada, EKG ile KB'yi izlemek için yapay zekâ tabanlı algoritmalar geliştirilmiştir. Çalışmanın ana sorusu "EKG ile KB tespiti için gereken minimum süre nedir?" ve "Minimum sürede hangi frekans bantlarında EKG ile KB tespiti yüksek doğrulukta gerçekleştirilir?" dir. Bu amaçla 2-20 saniye arasında farklı sürelerle sahip sinyaller için modeller geliştirilmiş ve algoritmalar test edilmiştir. Tespit edilen süre zarfında farklı frekans bantlarında EKG sinyal bilgisi alınarak KB tahmin modelleri oluşturulmuş ve performansları test edilmiştir.

KB tahmininin 2 saniye dahil herhangi bir zaman için yüksek doğrulukla yapılabileceği belirlenmiştir. 14 ve 16 saniyelik epoklar için  $R=0,98$  iken 2 saniyelik epok için  $R=0,97$  olarak belirlenmiştir.

Diğer epoklarda  $R$ , 0,97-0,98 aralığında değişmektedir. Bu durum, KB'nin EKG için yüksek doğrulukla tespit edilebileceğini gösterir.

İlk uygulama sonucu karar verilen 10 saniyelik süre için EKG sinyali farklı frekans bantlarında ayrımı yapılmıştır.

Her bir banttandır edinilen EKG bilgisi ile KB tahmin modellerinin performansı değerlendirilmiştir. Buna göre, SKB tahmini 2-40 Hz aralığı için OMYH = 1,37 ve R = 0,99 değerinde en iyi sonuca varıldığı, DKB tahmini içinde OMYH = 1,41 ve R = 0,99 değerinde 3-40 Hz aralığında en iyi performansın olduğu gözlemlenmiştir.

Tüm bunlara göre, 10 saniyelik EKG sinyalinin 2-40 Hz frekans bandında yüksek performans oranıyla sistolik ve diyastolik kan basıncı değerlerinin hesaplanabileceği değerlendirilmektedir.

Bu çalışmanın bulgularında yer alan yenilikler aşağıdaki gibidir. (1) EKG ile KB yüksek doğrulukta tahmin edilebilir. (2) EKG sinyal süresinin kısaltılması başarı oranını etkilemez. (3) KB, 2 saniyelik bir epok ile tahmin edilebilir. (4) Özellik çıkarma ve seçme süreçleri, model performansını iyileştirmiştir. (5) Frekans bant aralıklarında edinilen EKG bilgisinin yaklaşık 2-40 Hz aralığında daha değerli olduğu ve KB tahmini ile ilişkisinin yüksek olduğu görülmüştür. (6) Yapay zekâ tabanlı modeller, sistem güvenilirliğini artırdı. Önerilen modelin yüksek performansı ve güvenilirliği nedeniyle EKG sinyallerini ölçebilen tüm sistemlerde KB izleme için yardımcı bir yazılım olarak kullanılabilirliği düşünülmektedir.

#### **7.4. Gelecek Çalışmalar**

Bu cesaret verici sonuçlarla gelecek çalışmalar planlanmaktadır. Çalışmanın kapsamı, çok çeşitli insan gruplarını ve daha spesifik yapay zekâ tekniklerini içeren bir veri seti kullanılarak genişletilebilir. Sinyallerin örnekleme frekansının artırılması bilgi kaybını önleyecektir. Bu nedenle yeni çalışmalar için sinyal frekans aralığının en az 2,5 katı örnekleme frekansı önerilmektedir. Ayrıca EKG sinyalinin morfolojik özellikleri göz önünde bulundurularak ve veri seti üzerindeki frekans alanı özellik grupları çıkarılarak EKG ve KB arasındaki ilişkiye başka bir açıdan bakılarak çalışmalara devam edilebilir. EKG frekans bant aralığı daraltılarak daha dar bir aralık için KB tespitinin gerçekleştirilebilirliği incelenebilir.



## KAYNAKLAR

- [1] K. E. di Palo and N. J. Barone, (2020, Jan). Hypertension and Heart Failure: Prevention, Targets, and Treatment. *Heart Fail Clin*,16(1), 99–106. doi: 10.1016/J.HFC.2019.09.001
- [2] J. Slivnick and B. C. Lampert, “Hypertension and Heart Failure,” *Heart Fail Clin*, vol. 15, no. 4, pp. 531–541, Oct. 2019, doi: 10.1016/J.HFC.2019.06.007.
- [3] World Health Organization (2013). A global brief on hypertension | A global brief on Hypertension. [www.who.int](http://www.who.int)
- [4] C. Rosendorff et al. (2015, May). Treatment of Hypertension in Patients With Coronary Artery Disease: A Scientific Statement from the American Heart Association, American College of Cardiology, and American Society of Hypertension. *J Am Coll Cardiol*, 65(18), 1998–2038. doi: 10.1016/J.JACC.2015.02.038
- [5] J. Lu et al. (2017, Dec). Prevalence, awareness, treatment, and control of hypertension in China: data from 1.7 million adults in a population-based screening study (China PEACE Million Persons Project). *The Lancet*, 390(10112), 2549–2558. doi: 10.1016/S0140-6736(17)32478-9
- [6] P. M. O’Shea, T. P. Griffin, and M. Fitzgibbon. (2017, Feb). Hypertension: The role of biochemistry in the diagnosis and management. *Clinica Chimica Acta*, 465, 131–143. doi: 10.1016/J.CCA.2016.12.014.
- [7] G. S. Stergiou et al. (2018, Jul). Home blood pressure monitoring in the 21st century. *J Clin Hypertens (Greenwich)*, 20(7), 1116–1121. doi: 10.1111/JCH.13284
- [8] H. al Ghorani, F. Götzinger, M. Böhm, and F. Mahfoud. (2022). Jan. Arterial hypertension – Clinical trials update 2021. *Nutrition, Metabolism and Cardiovascular Diseases*, 32(1), 21–31. doi: 10.1016/J.NUMECD.2021.09.007
- [9] D. Akça and S. Elif Yıldız. (2019). The Effect of Training on Medication Adherence of Patients with Hypertension. *Kafkas Journal of Medical Sciences*, 9(2), 117–124. doi: 10.5505/kjms.2019.48343
- [10] G. Mancia and E. A. Rosei. (2020). Updates in Hypertension and Cardiovascular Protection. <http://www.springer.com/series/15049>
- [11] M. C. Myers et al. (2022, 01, Mar.), Effect of positioning on blood pressure measurement in pregnancy, *Pregnancy Hypertension, Elsevier B.V.*, 27, 110–114. doi: 10.1016/j.preghy.2021.12.013

- [12] B. Williams et al. (2018). ESC/ESH Guidelines for the management of arterial hypertension: The Task Force for the management of arterial hypertension of the European Society of Cardiology and the European Society of Hypertension: The Task Force for the management of arterial hypertension of the European Society of Cardiology and the European Society of Hypertension, *J Hypertens*, 36(10), 1956–2041. doi: 10.1097/HJH.0000000000001940.
- [13] K. A. Nerenberg et al. (2018, May). Hypertension Canada’s 2018 Guidelines for Diagnosis, Risk Assessment, Prevention, and Treatment of Hypertension in Adults and Children, *Can J Cardiol*, 34(5), 506–525. doi: 10.1016/J.CJCA.2018.02.022.
- [14] E. O’Brien et al. (1990). The British Hypertension Society protocol for the evaluation of automated and semi-automated blood pressure measuring devices with special reference to ambulatory systems. *J Hypertens*, 8(7), 607–619. doi: 10.1097/00004872-199007000-00004
- [15] E. O’Brien et al. (2010, Feb). European Society of Hypertension International Protocol revision 2010 for the validation of blood pressure measuring devices in adults. *Blood Press Monit*, 15(1), 23–38. doi: 10.1097/MBP.0B013E3283360E98.
- [16] P. K. Whelton et al., (2018). 2017 ACC/AHA/AAPA/ABC/ACPM/AGS/APhA/ASH/ASPC/NMA/PCNA Guideline for the Prevention, Detection, Evaluation, and Management of High Blood Pressure in Adults: Executive Summary: A Report of the American College of Cardiology/American Heart Association Task Force on Clinical Practice Guidelines. *Hypertension*, 71(6), 1269–1324. doi: 10.1161/HYP.0000000000000066
- [17] D. S. Picone et al. (2017) Accuracy of Cuff-Measured Blood Pressure Systematic Reviews and Meta-Analyses.
- [18] G. S. Stergiou, A. Kollias, and A. D. Protogerou, Evidence on Blood Pressure Measurement Methodology and Clinical Implementation Research Agenda for the 21st Century\*.
- [19] X. Xing and M. Sun. (2016, Aug). Optical blood pressure estimation with photoplethysmography and FFT-based neural networks. *Biomed Opt Express*, 7(8), 3007. doi: 10.1364/BOE.7.003007.
- [20] M. Rong and K. Li. (2021, Jul). A multi-type features fusion neural network for blood pressure prediction based on photoplethysmography. *Biomed Signal Process Control*, 68. doi: 10.1016/j.bspc.2021.102772.
- [21] R. Tabatabaei, A. Aasi, and S. M. Jafari. (2020). Experimental Investigation of the Diagnosis of Angular Contact Ball Bearings Using Acoustic Emission Method and Empirical Mode Decomposition. *Advances in Tribology*, 2020. doi: 10.1155/2020/8231752.
- [22] V. Bajaj and R. B. Pachori. (2020). Classification of seizure and nonseizure EEG signals using empirical mode decomposition. *IEEE Transactions on Information Technology in Biomedicine*, 16(6), 1135–1142. doi: 10.1109/TITB.2011.2181403



- [23] Y. Zhang and Z. Wang. (2018, Jun). A hybrid model for blood pressure prediction from a PPG signal based on MIV and GA-BP neural network. ICNC-FSKD 2017- 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery, 1989–1993. doi: 10.1109/FSKD.2017.8393073
- [24] Y. Zhang and Z. Wang. (2018, Jun). A hybrid model for blood pressure prediction from a PPG signal based on MIV and GA-BP neural network. ICNC-FSKD 2017- 13th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery, 1989–1993. doi: 10.1109/FSKD.2017.8393073
- [25] Y. Chen and M. Q. Feng. (2003). A technique to improve the empirical mode decomposition in the Hilbert-Huang transform. *Earthquake Engineering and Engineering Vibration* 2003 2:1, 2(1) ,75–85. doi: 10.1007/BF02857540.
- [26] J. Esmaelpour, M. H. Moradi, and A. Kadkhodamohammadi. (2020, May). A multistage deep neural network model for blood pressure estimation using photoplethysmogram signals. *Comput Biol Med*, 120. doi: 10.1016/j.combiomed.2020.103719
- [27] A. S. Alghamdi, K. Polat, A. Alghoson, A. A. Alshdadi, and A. A. Abd El-Latif. (2020, July). A novel blood pressure estimation method based on the classification of oscillometric waveforms using machine-learning methods. *Applied Acoustics*, 164. doi: 10.1016/j.apacoust.2020.107279
- [28] A. Aasi, R. Tabatabaei, E. Aasi, and S. M. Jafari. (2021, May). “Experimental investigation on time-domain features in the diagnosis of rolling element bearings by acoustic emission”. 1–11, doi: 10.1177/10775463211016130.
- [29] A. S. Alghamdi, K. Polat, A. Alghoson, A. A. Alshdadi, and A. A. Abd El-Latif. (2020, Jul). Gaussian process regression (GPR) based non-invasive continuous blood pressure prediction method from cuff oscillometric signals. *Applied Acoustics*, 164. doi: 10.1016/j.apacoust.2020.107256.
- [30] B. G. Celler, P. N. Le, A. Argha, and E. Ambikairajah. (2020, Jun). GMM-HMM-Based Blood Pressure Estimation Using Time-Domain Features. *IEEE Trans Instrum Meas*, 69(6), 3631–3641, doi: 10.1109/TIM.2019.2937074.
- [31] H. Ankişhan. (2020, Apr). Blood pressure prediction from speech recordings. *Biomed Signal Process Control*, 58. doi: 10.1016/j.bspc.2019.101842
- [32] I. Sharifi, S. Goudarzi, and M. B. Khodabakhshi, “A novel dynamical approach in continuous cuffless blood pressure estimation based on ECG and PPG signals,” *Artif Intell Med*, vol. 97, pp. 143–151, Jun. 2019, doi: 10.1016/j.artmed.2018.12.005.
- [33] I. Sharifi, S. Goudarzi, and M. B. Khodabakhshi. (2019, Jun). A novel dynamical approach in continuous cuffless blood pressure estimation based on ECG and PPG signals. *Artif Intell Med*, 97, 143–151. doi: 10.1016/j.artmed.2018.12.005
- [34] M. K. Uçar, Z. Uçar, K. Uçar, M. Akman, and M. R. Bozkurt. (2021, Jul). Determination of body fat percentage by electrocardiography signal with gender based artificial intelligence. *Biomed Signal Process Control*, 68, 102650. doi: 10.1016/j.bspc.2021.102650

- [35] M. Akman, M. K. Uçar, Z. Uçar, K. Uçar, B. Baraklı, and M. R. Bozkurt. (2021, Jan). Determination of Body Fat Percentage by Gender Based with Photoplethysmography Signal Using Machine Learning Algorithm. *IRBM*, doi: 10.1016/j.irbm.2020.12.003.
- [36] F. Bozkurt, M. K. Uçar, C. Bilgin, and A. Zengin. (2021, Mar). Sleep–wake stage detection with single channel ECG and hybrid machine learning model in patients with obstructive sleep apnea. *Phys Eng Sci Med*, 44(1), 63–77. doi: 10.1007/S13246-020-00953-5/TABLES/14.
- [37] G. Leonard et al. (2022, Jul). Machine Learning Improves Prediction Over Logistic Regression on Resected Colon Cancer Patients. *Journal of Surgical Research*, 275, 181–193. doi: 10.1016/J.JSS.2022.01.012
- [38] G. Thambiraj, U. Gandhi, U. Mangalanathan, V. J. M. Jose, and M. Anand. (2020, Jul). Investigation on the effect of Womersley number, ECG and PPG features for cuff less blood pressure estimation using machine learning. *Biomed Signal Process Control*, 60. doi: 10.1016/j.bspc.2020.101942
- [39] K. H. Yu, A. L. Beam, and I. S. Kohane, “Artificial intelligence in healthcare,” *Nature Biomedical Engineering* 2018 2:10, vol. 2, no. 10, pp. 719–731, Oct. 2018, doi: 10.1038/s41551-018-0305-z.
- [40] K. H. Yu, A. L. Beam, and I. S. Kohane. (2018, Oct). Artificial intelligence in healthcare. *Nature Biomedical Engineering* 2018 2:10, 2(10), 719–731. doi: 10.1038/s41551-018-0305-z
- [41] F. Alenezi, Ş. Öztürk, A. Armghan, and K. Polat. (2022, Oct). An effective hashing method using W-Shaped contrastive loss for imbalanced datasets. *Expert Syst Appl*, 204, 117612. doi: 10.1016/J.ESWA.2022.117612
- [42] M. Lin, X. Li, R. Chen, H. Fujita, and J. Lin. (2022, Feb). Picture fuzzy interactional partitioned Heronian mean aggregation operators: an application to MADM process. *Artif Intell Rev*, 55(2), 1171–1208. doi: 10.1007/S10462-021-09953-7/TABLES/7
- [43] M. Lin, Z. Chen, R. Chen, and H. Fujita. (2021, May). Evaluation of startup companies using multicriteria decision making based on hesitant fuzzy linguistic information envelopment analysis models. *International Journal of Intelligent Systems*, 36(5), 2292–2322. doi: 10.1002/INT.22379
- [44] M. Lin, Q. Zhan, and Z. Xu. (2020, Aug). Decision making with probabilistic hesitant fuzzy information based on multiplicative consistency. *International Journal of Intelligent Systems*, 35(8), 1233–1261. doi: 10.1002/INT.22240
- [45] C. Huang, S. Chen, Y. Zhang, W. Zhou, J. J. P. C. Rodrigues, and V. H. C. de Albuquerque. (2021, Nov). A robust approach for privacy data protection: IoT security assurance using generative adversarial imitation learning. *IEEE Internet Things J*, 1(1). doi: 10.1109/JIOT.2021.3128531.
- [46] S. Pirbhulal, W. Wu, K. Muhammad, I. Mehmood, G. Li, and V. H. C. de Albuquerque. (2020, Mar). Mobility Enabled Security for Optimizing IoT based Intelligent Applications. *IEEE Netw*, 34(2), 72–77. doi: 10.1109/MNET.001.1800547

- [47] S. A. Parah et al. (2021, Nov). Efficient Security and Authentication for Edge-Based Internet of Medical Things. *IEEE Internet Things J*, 8(21), 15652–15662, doi: 10.1109/JIOT.2020.3038009
- [48] S. Wang et al. (2022, Aug). Hand gesture recognition framework using a lie group based spatio-temporal recurrent network with multiple hand-worn motion sensors. *Inf Sci (N Y)*, 606, 722–741. doi: 10.1016/J.INS.2022.05.085
- [49] W. Wu, H. Zhang, V. H. C. de Albuquerque, and L. Xu. (2021, Mar). Hyper-Noise Interference Privacy Protection Framework for Intelligent Medical Data-Centric Networks. *IEEE Netw*, 35(1), 333–339. doi: 10.1109/MNET.011.2000356
- [50] F. Ahamed and F. Farid. (2019, Jan). Applying internet of things and machine-learning for personalized healthcare: Issues and challenges. *Proceedings - International Conference on Machine Learning and Data Engineering, iCMLDE 2018*, 22–29, doi: 10.1109/ICMLDE.2018.00014
- [51] Z. xia Lu et al. (2021, Dec). Application of AI and IoT in Clinical Medicine: Summary and Challenges. *Current Medical Science 2021* 41:6, 41(6), 1134–1150, doi: 10.1007/S11596-021-2486-Z
- [52] J. Canning et al. (2016, Oct). Noninvasive and continuous blood pressure measurement via superficial temporal artery tonometry. *Annu Int Conf IEEE Eng Med Biol Soc*, 2016, 3382–3385. doi: 10.1109/EMBC.2016.7591453
- [53] V. Mouradian, A. Poghosyan, and L. Hovhannisyan. (2015, Jul). Noninvasive continuous mobile blood pressure monitoring using novel PPG optical sensor. *2015 IEEE Topical Conference on Biomedical Wireless Technologies, Networks, and Sensing Systems, BioWireleSS 2015*, 60–62. doi: 10.1109/BIOWIRELESS.2015.7152111
- [54] A. K. Sahani, V. Ravi, and M. Sivaprakasam. (2015, Feb). Automatic estimation of carotid arterial pressure in ARTSENS. *11th IEEE India Conference: Emerging Trends and Innovation in Technology, INDICON 2014*, doi: 10.1109/INDICON.2014.7030624.
- [55] S. Tanaka, M. Nogawa, T. Yamakoshi, and K. I. Yamakoshi. (2007, Oct). Accuracy assessment of a noninvasive device for monitoring beat-by-beat blood pressure in the radial artery using the volume-compensation method. *IEEE Trans Biomed Eng*, 54(10), 1892–1895. doi: 10.1109/TBME.2007.894833
- [56] Y. Li, Y. Gao, N. Deng, Y. Li, Y. Gao, and N. Deng. (2013, Oct). Mechanism of Cuff-Less Blood Pressure Measurement Using MMSB,” *Engineering*, 5(10), 123–125. doi: 10.4236/ENG.2013.510B025.
- [57] R. A. Payne, C. N. Symeonides, D. J. Webb, and S. R. J. Maxwell. (2006, Jan). “Pulse transit time measured from the ECG: An unreliable marker of beat-to-beat blood pressure”. *J Appl Physiol*, 100(1), 136–141, doi:10.1152/JAPPLPHYSIOL.00657.2005/ASSET/IMAGES/LARGE/ZDG0010662680004.JPEG

- [58] M. Y. M. Wong, C. C. Y. Poon, and Y. T. Zhang. (2009). An evaluation of the cuffless blood pressure estimation based on pulse transit time technique: a half year study on normotensive subjects. *Cardiovasc Eng*, 9(1), 32–38. doi: 10.1007/S10558-009-9070-7
- [59] S. Goli and Jayanthi. (2014). “Cuff less Continuous Non-Invasive Blood Pressure Measurement Using Pulse Transit Time Measurement”.
- [60] M. Simjanoska, M. Gjoreski, M. Gams, and A. M. Bogdanova, “Non-Invasive Blood Pressure Estimation from ECG Using Machine Learning Techniques,” *Sensors* 2018, Vol. 18, Page 1160, vol. 18, no. 4, p. 1160, Apr. 2018, doi: 10.3390/S18041160
- [61] U. Senturk, I. Yucedag, and K. Polat, “Repetitive neural network (RNN) based blood pressure estimation using PPG and ECG signals,” *ISMSIT 2018- 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, Dec. 2018, doi: 10.1109/ISMSIT.2018.8567071.
- [62] R. Nye, Z. Zhang, and Q. Fang, “Continuous non-invasive blood pressure monitoring using photoplethysmography: A review,” *4th International Symposium on Bioelectronics and Bioinformatics, ISBB 2015*, pp. 176–179, Dec. 2015, doi: 10.1109/ISBB.2015.7344952.
- [63] B. M. McCarthy, B. O’Flynn, and A. Mathewson, “An Investigation of Pulse Transit Time as a Non-Invasive Blood Pressure Measurement Method,” *J Phys Conf Ser*, vol. 307, no. 1, p. 012060, Aug. 2011, doi: 10.1088/1742-6596/307/1/012060.
- [64] Y. Choi, Q. Zhang, and S. Ko, “Noninvasive cuffless blood pressure estimation using pulse transit time and Hilbert–Huang transform,” *Computers & Electrical Engineering*, vol. 39, no. 1, pp. 103–111, Jan. 2013, doi: 10.1016/J.COMPELECENG.2012.09.005.
- [65] A. Rasool, F. M. Kashif, M. Rafiq, and A. Nasir. (2019, Jan). Continuous and noninvasive blood pressure estimation by two-sensor measurement of pulse transit time. *2018 14th International Conference on Emerging Technologies, ICET 2018*. doi: 10.1109/ICET.2018.8603612
- [66] M. Y. M. Wong, C. C. Y. Poon, and Y. T. Zhang. (2009). An evaluation of the cuffless blood pressure estimation based on pulse transit time technique: a half year study on normotensive subjects. *Cardiovasc Eng*, 9(1), 32–38. doi: 10.1007/S10558-009-9070-7
- [67] X. Chen, S. Yu, Y. Zhang, F. Chu, and B. Sun, “Machine Learning Method for Continuous Noninvasive Blood Pressure Detection Based on Random Forest,” *IEEE Access*, vol. 9, pp. 34112–34118, 2021, doi: 10.1109/ACCESS.2021.3062033.
- [68] F. Miao et al. (2020, Aug) “Continuous blood pressure measurement from one-channel electrocardiogram signal using deep-learning techniques”. *Artif Intell Med*, 108, 101919, doi: 10.1016/J.ARTMED.2020.101919
- [69] *Anatomy & Physiology*. OpenStax CNX. <http://cnx.org/contents/14fb4ad7-39a1-4eee-ab6e-ef2482e3e22@8.25>. “Heart Anatomy | Anatomy and Physiology II.” <https://courses.lumenlearning.com/suny-ap2/chapter/heart-anatomy/>

- [70] E. J. Topol and Cleveland Clinic, Eds. (2022, Nov, 26). Cleveland Clinical Heart Book. 4(5), 2000, <https://archive.org/details/clevelandclinich0000unse>
- [71] A Wiggers Diagrams. (2016, Jul). “File: Wiggers Diagram 2.svg-WikimediaCommons”.[https://commons.wikimedia.org/wiki/File:Wiggers\\_Diagram\\_2.svg](https://commons.wikimedia.org/wiki/File:Wiggers_Diagram_2.svg)
- [72] H. Fukuta and W. C. Little. (2008, Jan). “The Cardiac Cycle and the Physiological Basis of Left Ventricular Contraction, Ejection, Relaxation, and Filling”. *Heart Fail Clin.* 4(1), 1-11, doi: 10.1016/j.hfc.2007.10.004
- [73] BruceBlaus. (2015, Nov). “File: Systolevs Diastole.png- Wikimedia Commons” [https://commons.wikimedia.org/wiki/File:Systolevs\\_Diastole.png](https://commons.wikimedia.org/wiki/File:Systolevs_Diastole.png)
- [74] D. E. Becker. (2006). “Fundamentals of Electrocardiography Interpretation” *Anesth Prog*, 53, 53–64.
- [75] Diagram of electrocardiogram paper. (2007, May). “File: ECG Paper v2.svg-Wikimedia Commons” [https://commons.wikimedia.org/wiki/File:ECG\\_Paper\\_v2.svg](https://commons.wikimedia.org/wiki/File:ECG_Paper_v2.svg)
- [76] R. J. Noble, J. S. Hillis, and D. A. Rothbaum. (1990, Jan.) *Electrocardiography. Practical Cardiology: Principles and Approaches*, 17–59. doi: 10.1016/B978-0-323-80915-3.00005-3.
- [77] Electrical conduction system of the human heart. (2015, Mar). “File: Cardiac Conduction System.jpg- Wikimedia Commons”. [https://commons.wikimedia.org/wiki/File:Cardiac\\_Conduction\\_System.jpg](https://commons.wikimedia.org/wiki/File:Cardiac_Conduction_System.jpg)
- [78] M.Gabriel Khan. (2008). “Basic Concepts”. *Rapid ECG Interpretation*, 1–24, doi: 10.1007/978-1-59745-408-7\_1
- [79] J. Ribeiro Pinto, J. S. Cardoso, and A. Lourenco. (2018, Jun). “Evolution, current challenges, and future possibilities in ECG Biometrics”. *IEEE Access*, 6, 34746–34776, doi: 10.1109/ACCESS.2018.2849870.
- [80] A. H. Kashou, H. Basit, and L. Chhabra. (2022, Nov, 08). *Electrical Right and Left Axis Deviation. StatPearls*, <https://www.ncbi.nlm.nih.gov/books/NBK470532/>
- [81] P. Lyakhov, M. Kiladze, and U. Lyakhova. (2021, Aug). “System for Neural Network Determination of Atrial Fibrillation on ECG Signals with Wavelet-Based Preprocessing,” *Applied Sciences*, 11(16), 7213, doi: 10.3390/app11167213
- [82] B. J. Kenny and K. N. Brown. (2022, Aug). “ECG T Wave”. *StatPearls*, Available: <https://www.ncbi.nlm.nih.gov/books/NBK538264/>
- [83] A. Diker, E. Avci, E. Tanyildizi, and M. Gedikpinar. (2020, Mar). “A novel ECG signal classification method using DEA-ELM,” *Med Hypotheses*, 136, 109515, doi: 10.1016/J.MEHY.2019.109515
- [84] A. v Chobanian et al. (2023 Jan) “The Seventh Report of the Joint National Committee on Prevention, Detection, Evaluation, and Treatment of High Blood Pressure The JNC 7 Report”, Accessed: Available: [www.jama.com](http://www.jama.com)
- [85] B. S. Alpert, D. Quinn, and D. Gallick. (2014, Dec). Oscillometric blood pressure: a review for clinicians. *Journal of the American Society of Hypertension*, 8(12), 930–938. doi: 10.1016/J.JASH.2014.08.014

- [86] P. F. F Cartwright FFARC S and by Jeremy Booth. (1977). “A short history of blood pressure measurement” *Proc R Soc Med*, 70(11), 793, doi: 10.1177/003591577707001112
- [87] J. L. Izzo and A. A. Taylor. (1999). The sympathetic nervous system and baroreflexes in hypertension and hypotension. *Current Hypertension Reports* 1999 1:3, 1(3),254–263. doi: 10.1007/S11906-999-0030-9.
- [88] M. R. Weir and V. J. Dzau. (1999, Dec). “The renin-angiotensin-aldosterone system: A specific target for hypertension management”. *Am J Hypertens*, 12(12), 205S-213S, doi: 10.1016/S0895-7061(99) 00103-X/2/AJH.205S.F8.JPEG
- [89] Chow, Jonathan H. Galvagno, Samuel M. Tanaka, Kenichi A. et al. (2018). “When All Else Fails: Novel Use of Angiotensin II for Vasodilatory Shock: A Case Report” *A & A Practice*. 11(7), 175–180, DOI: 10.1213/XAA.0000000000000775
- [90] Y. L. Shevchenko and J. E. Tsitlik. (1996, Jul). “90th Anniversary of the Development by Nikolai S. Korotkoff of the Auscultatory Method of Measuring Blood Pressure,” *Circulation*, 94(2), 116–118, doi: 10.1161/01.CIR.94.2.116
- [91] C. E. Grim and C. M. Grim, “Auscultatory BP: still the gold standard,” *Journal of the American Society of Hypertension*, vol. 10, no. 3, pp. 191–193, Mar. 2016, doi: 10.1016/J.JASH.2016.01.004
- [92] G. Ogedegbe and T. Pickering, “Principles and techniques of blood pressure measurement,” *Cardiol Clin*, vol. 28, no. 4, pp. 571–586, 2010, doi: 10.1016/j.ccl.2010.07.006
- [93] G. D. Baura. (2012) “Blood Pressure Monitors” in *Medical Device Technologies*, 147–164, doi: 10.1016/B978-0-12-374976-5.00007-4
- [94] M. Dilek, Z. Adibelli, T. Aydogdu, A. R. Koksall, B. Cakar, and T. Akpolat. (2009). “Self- measurement of blood pressure at home: Is it reliable?”. 17(1), 34–41, doi: 10.1080/08037050701758018
- [95] D. G. Erdem et al. (2009). “Accuracy of Sphygmomanometers at Pharmacies” *Kidney Blood Press Res*, 32(4),231–234, doi: 10.1159/000228936).
- [96] C. Landry, E. T. Hedge, R. L. Hughson, S. D. Peterson, and A. Arami. (2021). *Wearable Physiological and Blood Pressure Measurements During Activities of Daily Living*. IEEE Dataport. doi: <https://dx.doi.org/10.21227/wysp-gt69>
- [97] C. Landry, E. T. Hedge, R. L. Hughson, S. Peterson, and A. Arami. (2021). *Accurate Blood Pressure Estimation during Activities of Daily Living: A Wearable Cuffless Solution*. IEEE J Biomed Health Inform. doi: 10.1109/JBHI.2021.3054597
- [98] Stephen Marsland. (2009). “MACHINE LEARNING: An Algorithmic Perspective”. Chapman & Hall/CRC, <https://doi.org/10.1201/9781420067194>
- [99] Stephen Marsland. (2014). “MACHINE LEARNING: An Algorithmic Perspective, Second Edition”. Chapman & Hall/CRC *Machine Learning & Pattern Recognition*.

- [100] M. K. Uçar, M. Nour, H. Sindi, and K. Polat. (2020). The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets. *Math Probl Eng*, 2020, 1–17. doi: 10.1155/2020/2836236.
- [101] L. Breiman, J. H. Friedman, R. A. Olshen, and C. J. Stone. (2017, Jan). Classification and regression trees. *Classification and Regression Trees*, 1–358. doi:10.1201/9781315139470/CLASSIFICATION-REGRESSION-TREES-LEO-BREIMAN-JEROME-FRIEDMAN-RICHARD-OLSHEN-CHARLES-STONE.
- [102] C. Crisci, B. Ghattas, and G. Perera. (2012, Aug). A review of supervised machine learning algorithms and their applications to ecological data. *Ecol Modell*, 240, 113–122. doi: 10.1016/J.ECOLMODEL.2012.03.001.
- [103] T. Hastie, R. Tibshirani, and J. Friedman. *Springer Series in Statistics the Elements of Statistical Learning Data Mining, Inference, and Prediction*.
- [104] L. Breiman. (1996, Dec). Heuristics of instability and stabilization in model selection. *24(6)*, 2350–2383. doi: 10.1214/AOS/1032181158
- [105] W.-D. L. W.-Y. L. and C.C. Y. Probal Chaudhuri, (1995). “GENERALIZED REGRESSION TREES on JSTOR”. <https://www.jstor.org/stable/24305062>
- [106] P. E. Utgoff. (1989). *Incremental Induction of Decision Trees*. 4, 161–186.
- [107] J. R. Quinlan, “Induction of decision trees,” *Machine Learning* 1986 1:1, vol. 1, no. 1, pp. 81–106, Mar. 1986, doi: 10.1007/BF00116251.
- [108] V. L. Deringer, A. P. Bartók, N. Bernstein, D. M. Wilkins, M. Ceriotti, and G. Csányi. (2021, Aug). “Gaussian Process Regression for Materials and Molecules” *121(16)*, 10073–10141, doi: 10.1021/ACS.CHEMREV.1C00022/ASSET/IMAGES/MEDIUM/CR1C00022\_M069.GIF.
- [109] N. v Thakor, J. G. Webster, and W. J. Tompkins. (1983). Optimal QRS detector. *Biol. Eng. & Comput*, 21, 350.
- [110] J. Pan and W. J. Tompkins. (1985). A Real-Time QRS Detection Algorithm. *IEEE Trans Biomed Eng*, vol. BME-32, 3, 230–236doi: 10.1109/TBME.1985.325532
- [111] C. Li, C. Zheng, and C. Tai. (1995). Detection of ECG characteristic points using wavelet transforms. *IEEE Trans Biomed Eng*, 42(1), 21–28, [https://www.academia.edu/36444193/Detection\\_of\\_ECG\\_Characteristic\\_Points\\_Using\\_Wavelet\\_Transforms](https://www.academia.edu/36444193/Detection_of_ECG_Characteristic_Points_Using_Wavelet_Transforms)
- [112] J. S. Sahambi, S. N. Tandon, and R. K. P. Bhatt. (1997, Jan). Using wavelet transforms for ECG characterization. *IEEE Engineering in Medicine and Biology Magazine*, 16(1), 77–83. doi: 10.1109/51.566158
- [113] D. S. Benitez, P. A. Gaydecki, A. Zaidi, and A. P. Fitzpatrick. (2020). New QRS detection algorithm based on the Hilbert transform. *Comput Cardiol*, 379–382. doi: 10.1109/CIC.2000.898536.
- [114] J. Moraes, M. Freitas, F. Vilani, and E. Costa. (2002). A QRS Complex Detection Algorithm using Electrocardiogram Leads.
- [115] S. Z. Mahmoodabadi, A. Ahmadian, and M. D. Abolhasani. ECG FEATURE EXTRACTION USING DAUBECHIES WAVELETS.





## ÖZGEÇMİŞ

Ad-Soyad : Derya KANDAZ

### ÖĞRENİM DURUMU:

- **Lisans** : 07/07/2020, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği
- **Yükseklisans:** Devam etmekte, Sakarya Üniversitesi, Mühendislik Fakültesi, Elektronik Anabilim Dalı

### MESLEKİ DENEYİM VE ÖDÜLLER:

- 2022 yılında Sakarya Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümünde Araştırma Görevlisi olarak başlamış ve halen devam etmektedir.
- 2020-2022 yılları arasında Beyazıt Asansör Firmasında Elektrik Elektronik Mühendisi olarak çalıştı.

### TEZDEN TÜRETİLEN ESERLER:

- Majid Nour, Derya Kandaz, Muhammed Kursad Ucar, Kemal Polat and Adi Alhudhaif. (2022). Machine Learning and Electrocardiography Signal-Based Minimum Calculation Time Detection for Blood Pressure Detection. Computational and Mathematical Methods in Medicine, doi: 10.1155/2022/5714454.

### DİĞER ESERLER:

- Buse Nur KAHRAMAN, Zeynep BAĞDATLI, Nilay TAÇYILDIZ, Sude ÇİĞNİTAŞ, DERYA KANDAZ, MUHAMMED KÜRŞAD UÇAR. (2022). Hybrid Artificial Intelligence-Based Algorithm Design For Cardiovascular Disease Detection. Advances in Artificial Intelligence Research, 2, 2, 59. doi: 10.54569/aair.1141465

- Hilal apkan, BūŖra DÖNMEZ, Muhammed Zahid KAYA, Gazi Muhammed KALKAN, Sūmeyye GÜREL, Eren AKDAĞLI, Yusuf Cafer TOK, Sevde Nur ŖENOL, Derya KANDAZ, Muhammed KūrŖad UAR. (2022). Diagnosis of Breast Cancer with Hybrid Artificial Intelligence Method. European Journal of Science and Technology, 42, 14-19. doi: 10.31590/ejosat.1189743
- Abdullah ALTUNTAŖ, AyŖenur OZEN, Destina KURT, Buse AKINCI, Zeynep BAGDATLI, Derya KANDAZ, Muhammed KūrŖad UAR. (2022) Brain Tumor Detection Based on Hybrid Artificial Intelligence Algorithm. Medical Technologies Congress (TIPTEKNO) | 978-1-6654-5432-2/22/\$31.00 ©2022 IEEE
- Gazi Muhammed KALKAN, BūŖra DONMEZ, Yusuf Cafer TOK, Sūmeyye GUREL, Eren AKDAGLI, Sevde Nur ŖENOL, Hilal APKAN, Muhammed Zahid Kaya, Derya KANDAZ, Muhammed KūrŖad UAR. (2022). Diagnosis of Lung Cancer with Hybrid Artificial Intelligence Method”, 2022 Medical Technologies Congress (TIPTEKNO) | 978-1-6654-5432-2/22/\$31.00 ©2022 IEEE | DOI: 10.1109/TIPTEKNO56568.2022.9960150