

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

**VÜCUT KAS YÜZDESİNİN BİYOMEDİKAL
SİNYALLER İLE YAPAY ZEKA TABANLI
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Samet Oğuz AKSEKİ

Enstitü Anabilim Dalı	:	ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
Enstitü Bilim Dalı	:	ELEKTRONİK
Tez Danışmanı	:	Doç. Dr. Muhammed Kürşad UÇAR

Ocak 2022

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

**VÜCUT KAS YÜZDESİNİN BİYOMEDİKAL
SİNYALLER İLE YAPAY ZEKA TABANLI
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

Samet Oğuz AKSEKİ

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ
Enstitü Bilim Dalı : ELEKTRONİK**

Bu tez 14.01.2022 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

Jüri Başkanı

Üye

Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Samet Oğuz Akseki

14.01.2022

TEŞEKKÜR

Tez çalışmam boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Doç. Dr. Muhammed Kürşad Uçar'a ve desteklerini esirgemeyen değerli aileme en içten minnet ve teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vi
ÖZET	vii
SUMMARY	viii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
LİTERATÜR ÖZETİ	3
BÖLÜM 3.	
MATERYAL VE YÖNTEM	6
3.1. Akış Diyagramı.....	6
3.2. Verilerin Toplanması	7
3.3. Sinyal Önleme.....	8
3.4.Özellik Çıkarma	10
3.5. Özellik Seçme ve Sınıflandırma Algoritmaları.....	11
3.5.1.Spearman özellik seçme algoritması.....	12
3.6. Makine Öğrenmesi.....	15
3.6.1. Karar ağaçları.....	15
3.6.2. Destek vektör regresyonu.....	16
3.6.3.Karar ağaçları toplulukları.....	18

3.7. Performans Değerlendirme Kriterleri.....	19
BÖLÜM 4.	
ARAŞTIRMA BULGULARI	22
BÖLÜM 5.	
TARTIŞMA VE SONUÇ	36
KAYNAKLAR	41
ÖZGEÇMİŞ	47



SİMGELER VE KISALTMALAR LİSTESİ

ADP	: Hava Yer Değişirme Pletismografisi
BIA	: Biyoelektrik Empedans Analizi
BMP	: Body Mass Percentage
CT	: Bilgisayarlı Tomografi
D3 Kreatin	: Döteryumlanmış Kreatin
DXA	: Dual Enerji X-Ray Absorbsiyometri
EIM	: Elektrik Empedans Miyografisi
EKG	: Elektrokardiyografi
KA	: Karar Ağaçları
KAT	: Karar Ağaçları Toplulukları
MAD	: Mean Absolute Diffrence
MAPE	: Mean Absolute Percentage Error
MRI	: Manyetik Rezonans Görüntüleme
MSE	: Mean Squared Error
NAA	: Nötron Aktivasyon Analizi
R	: Korelasyon Katsayısı
R^2	: Açıklayıcılık Katsayısı
RMSE	: Root Mean Square Error
SE	: Standart Error
SVR	: Destek Vektör Regresyonu
VKY	: Vücut Kas Yüzdesi

ŞEKİLLER LİSTESİ

Şekil 3.1. Akış diyagramı	7
Şekil 3.2. Erkek ve kadınların boy uzunluğu / vücut ağırlığı / vücut kas yüzdesi (VKY) dağılımı.....	9
Şekil 3.3. Kadınlara ait filtrelenmiş EKG ve QRS sinyalleri.....	10
Şekil 3.4. Erkeklerle ait filtrelenmiş EKG ve QRS sinyalleri.....	11
Şekil 4.1. Erkekler için QRS frekans bandı performans değerleri.....	27
Şekil 4.2. Kadınlar için QRS frekans bandı performans değerleri	28
Şekil 4.3. Tüm bireyler için QRS frekans bandı performans değerleri	28
Şekil 4.4. Tüm bireyler için özellik seçimi işlemi sonrası performans değerleri....	30
Şekil 4.5. Erkekler için özellik seçimi işlemi sonrası performans değerleri.....	33
Şekil 4.6. Kadınlar için özellik seçimi işlemi sonrası performans değerleri.....	35

TABLolar LİSTESİ

Tablo 3.1. Demografik bilgiler	8
Tablo 3.2. QRS frekans bant aralığı	10
Tablo 3.3. Özelliklere ait eşitlikler.....	11
Tablo 3.4. Özellik sayıları.....	12
Tablo 3.5. Seçilen özellik dağılımı.....	14
Tablo 3.6. Erkekler, kadınlar ve tüm bireylerde seçilen özellikler.....	15
Tablo 3.7. Eğitim ve test veri seti dağılımı.....	22
Tablo 4.1. Tüm özellikler ile performans değerleri.....	24
Tablo 4.2. EKG ve QRS bant özelliklerine göre VKY hesaplama model performans değerleri –1	25
Tablo 4.3. EKG ve QRS bant özelliklerine göre VKY hesaplama model performans değerleri – 2.....	26
Tablo 4.4. Tüm bireylere (erkek ve kadın) ait vücut kas yüzdesi hesaplama modelleri performansları.....	29
Tablo 4.5. Erkeklerle ait vücut kas yüzdesi hesaplama modelleri performansları.....	31
Tablo 4.6. Kadınlara ait vücut kas yüzdesi hesaplama modelleri performansları.	33
Tablo 4.7. Vücut kas kütlesi tahmininde kullanılan yöntemlerin performans değerleri.....	36

ÖZET

Anahtar kelimeler: Elektrokardiyografi Sinyali, Makine Öğrenmesi, Yapay Zeka, Vücut Kompozisyonu, Vücut Kas Yüzdesi, Cinsiyet Bazlı Vücut Kas Yüzdesi

Sağlıklı bir hayat sürdürülmesi için gerekli olan kas kütlelerinin ölçülmesi ve takibi önemlidir. Özellikle kas kütlesi yaşlı bireylerin yaşam kalitesini doğrudan etkilediğinden dolayı bu bireylerde kas kütlesi takibinin yapılması daha da büyük öneme sahiptir. Kas kütlelerinin ölçümünde kullanılan mevcut yöntemler çeşitli dezavantajlara sahip olduklarından dolayı, kas kütlelerinin ölçümünde kullanılabilecek pratik, güvenilir ve yüksek teknolojiye cihazlara ihtiyaç bulunmaktadır. Bu çalışmada, yapay zeka algoritmaları ile biyomedikal sinyal kullanılarak düşük maliyetli ve güvenilir vücut kas yüzdesi hesaplanmasına yönelik bir model geliştirilmesi hedeflenmiştir.

Çalışmada 300 bireye ait Elektrokardiyografi (EKG) sinyalleri kullanılmıştır. Öncelikle EKG sinyali filtrelenmiş ve alt frekans bantları elde edilmiştir. Her bireye ait EKG sinyalinden, bu sinyalin farklı 7 frekansta bulunan QRS bileşenleri elde edilmiştir. Böylelikle her birey için 8 sinyale sahip olunmuştur. Elde edilen her sinyalden 25 adet olmak üzere toplam 200 adet zaman domeni özellikleri çıkarılmıştır. Ayrıca 5 adet demografik özellikte (yaş, kilo, boy, BMI, kas) modele eklenmiş ve toplamda 205 özelliğe ulaşılmıştır. Performans arttırımı için spearman özellik seçme algoritması kullanılmıştır. Makine öğrenmesi algoritması olarak Karar Ağaçları, Destek Vektör Regresyonu, Karar Ağaçları Topluluğu makine öğrenmesi algoritması kullanılmıştır.

Çalışmada, önerilen Vücut Kas Yüzdesi (VKY) tahmin modeli tüm bireyler için $MAPE=4,18$ (Karar Ağaçları Toplulukları), erkekler için $MAPE=3,91$ (Destek Vektör Regresyonu) ve kadınlar için $MAPE=4,54$ (Destek Vektör Regresyonu) performans değerlerine sahiptir.

Çalışma sonucuna göre EKG sinyali tabanlı VKY tahmin modellerinin kullanılabileceği düşünülmektedir.

ARTIFICIAL INTELLIGENCE-BASED ESTIMATION OF BODY MUSCLE PERCENTAGE WITH BIOMEDICAL SIGNALS

SUMMARY

Keywords: Electrocardiography Signal, Machine Learning, Artificial Intelligence, Body Composition, Body Muscle Percentage, Gender-Based Body Muscle Percentage

Measuring and monitoring the body muscle mass required to maintain a healthy life is essential. Especially, since muscle mass affects the life quality of elderly persons directly, monitoring the muscle mass in these persons has more importance. Since the current methods utilised to measure muscle mass have some disadvantages, it is required practical, reliable and high-tech devices can be used to measure muscle mass. This study aims to develop a low-cost and reliable BMP calculation model using artificial intelligence algorithms and biomedical signals.

In the study, 300 Electrocardiography (ECG) signals belonging to the individual were used. Firstly, the ECG signals were filtered, and sub-frequency bands were obtained. From the ECG signal of each individual, the QRS components of this signal at 7 different frequencies were obtained. Thus, 8 signals were acquired for each individual. A total of 200-time domain features were extracted, 25 of which were obtained from each signal. In addition, five demographic features (age, weight, height, BMI, muscle) were added to the model, and 205 features were reached. To enhance the performance, the spearman feature selection algorithm was used. As machine learning algorithms; Decision Trees, Support Vector Regression, Ensemble Decision Trees have been used.

The recommended BMP estimation model has the performance values for all individuals MAPE=4,18 (Ensemble Decision Tree), for males MAPE=3,91(Support Vector Regression) and for females MAPE=4,54 (Support Vector Regression) in this study.

Regarding the results of the study, It is thought that ECG-based BMP prediction models can be used.

BÖLÜM 1. GİRİŞ

Vücudumuzda bulunan yağ, kemik, kas ve sıvı bileşenlerinden oluşan vücut kompozisyonu, dahili (hastalıklar, metabolik, hormonal değişimler) ve harici (beslenme, stres) çeşitli faktörlerden etkilenmektedir. Bireylerin yaşa bağlı değişimlerinin tespiti, hasta-sağlıklı halleri arasında ki farklılıkların gözlenmesi ve bireylere uygulanan tedavi ile beslenme desteklerinin verimliliğinin tespitinde vücut kompozisyonunun değerlendirilmesi önem kazanmaktadır [1], [2]. Bireyin uzun süreli enerji depolanmasının sağlandığı, yağsız vücut kütlelerinin bir elemanı olan iskelet kası, sağlığımız üzerinde önemli etkiye sahiptir. Sağlıklı bir hayat sürdürebilmesi için yeterli miktarda ve kalitede iskelet kasına sahip olunması gerekmektedir [3], [4]. Kas gücü ve kütlesi, kasın ana parametrelerini oluşturmaktadır [5]. Yaşlanma, kilo kaybına sebep olan hastalıklar ve yanlış beslenme/diyetler gibi çeşitli etkenler sebebiyle kas kütlelerinde kayıplar yaşanabilir. Kas kütlelerinde yaşanacak bir kayıp bireyin kırılabilirliğini artırarak fiziksel ve psikolojik açıdan olumsuzluklara yol açmaktadır [6]–[15]. Başkalarına bağımlı olarak yaşama / fiziksel aktivitelerin sınırlandırılması ve dolayısıyla yaşam kalitesinde düşüş gibi fiziksel sonuçların yanında, düşünce ve davranışlara da yansıtılabilecek depresif bozuklukların / psikolojik problemlerin görülmesi söz konusu olmaktadır [3], [5], [12], [13]. Bireyin fiziki ve psikolojik sağlığına doğrudan etkisi olan kas kütlelerinin takibi bu sebeple öneme sahiptir [3], [10], [12].

Çalışmada yapay zeka algoritmaları ve biyomedikal sinyali kullanılarak maliyeti düşük, güvenilir, Vücut Kas Yüzdesi (VKY) hesaplanmasına yönelik bir model geliştirilmesi hedeflenmiştir. Literatürde kullanılan vücut kas yüzdesi hesaplama yöntemlerinden farklı olarak bu çalışmada Elektrokardiyografi (EKG) sinyali kullanılmıştır. Vücut kompozisyonunu oluşturan bileşenlerin kalbin çalışmasıyla bağlantılı olduğu bilindiğinden dolayı ve literatürde bulunan mevcut çalışmalar da göz

önüne alındığında EKG sinyaliyle vücut kas yüzdesinin hesaplanabileceği değerlendirilmiştir [16]–[19].

Çalışmanın amacı EKG sinyali ve biyomedikal sinyal işleme teknikleriyle VKY hesaplanabilmesi için makine öğrenmesi tabanlı tahmin modeli geliştirmektir (Şekil 3.1.). Çalışmada 300 bireyden alınan EKG sinyalleri filtrelenerek sinyallerde ki gürültü temizlenmiş ve her bir bireyin EKG sinyali 7 adet QRS bandına göre frekans bantlarına ayrılmıştır (Bölüm 3.3.). Toplamda elde edilen 8 sinyalin (EKG + 7 adet QRS) her birine Tablo 3.3’te bulunan 25 adet eşitlik uygulanmış ve toplamda 200 adet istatistiksel özellik elde edilmiştir (Bölüm 3.4.). Demografik bilgiler ile toplam 205 özellik elde edilmiştir (Tablo 3.1.). Özellik seçme algoritması yardımıyla 205 özellik belirli seviyelerde seçilmiştir (Bölüm 3.5.). Her seviyede yapay zeka tabanlı modeller oluşturulmuştur (Bölüm 3.6.). Geliştirilen her modelin performansı literatürde sıklıkla kullanılan yedi parametre ile kontrol edilmiştir (Bölüm 3.7.).

Çalışmada oluşturulan modeller Bölüm 4’te açıklanmıştır. İlk olarak özellik seçimi yapılmadan, tüm veri seti ve özelliklerin yer aldığı, erkek, kadın ve tüm bireyler için makine öğrenmesi algoritmaları ile üçer model oluşturulmuştur (Tablo 4.1.). İkinci kısımda ise çalışmada kullanılan QRS frekans bantlarından çıkarılan özelliklerin hangisinin daha verimli olduğunu tespit edebilmek amacıyla her bir QRS bant özellikleri üç sınıflandırıcı ile sınıflandırılmıştır (Tablo 4.2., Tablo 4.3.). Üçüncü kısımda ise tüm özellikler (205), özellik seçme algoritmaları ile seçilmiş ve 10 seviyede farklı modeller çıkartılmıştır. Bu işlem hem cinsiyet bazlı hem de tüm bireyler için gerçekleştirilmiştir (Tablo 4.4., Tablo 4.5., Tablo 4.6.). Literatürde yapılan diğer çalışmalara ait performans değerleri de Tablo 4.7.’de paylaşılmıştır.

Önerilen çalışma, literatürde ki diğer çalışmalarla Bölüm 5’te karşılaştırılmıştır. Diğer çalışmaların performansları ile sahip oldukları dezavantajlara yönelik bilgi verilmiştir.

BÖLÜM 2. LİTERATÜR ÖZETİ

Kas kütlesinin doğru ve güvenilir bir şekilde ölçülmesi, riskli bireylerin tespiti ve uygun tedavinin tercih edilmesi açısından önemlidir. Günümüzde vücut kas kütlesinin tespiti için kullanılan yöntemlere örnek olarak Antropometrik Ölçümler, Bilgisayarlı Tomografi (CT), Biyoelektrik Empedans Analizi (BIA), Biyokimyasal Belirteçler (Total veya Kısmi Vücut Potasyumu, Serum ve İdrar Kreatinin, Döteryumlanmış Kreatin (D3 Kreatin) Dilüsyonu), Dual Enerji X-Ray Absorbsiyometri (DXA), Elektrik Empedans Miyografisi (EIM), Hava Yer Değiştirme Pletismografisi (ADP), Manyetik Rezonans Görüntüleme (MRI) ve Nötron Aktivasyon Analizi (NAA) verilebilir. Literatürde kullanılan bu yöntemlerin avantajları kadar dezavantajları da mevcuttur [20]–[23].

Vücut kas yüzdesinin hesaplanmasında güvenilir yöntemlerden biri olan MRI yüksek maliyeti, kapalı alan korkusu olan kişilerde uygulanamaması, hacminin büyük olmasından dolayı geniş alana ihtiyaç duyması, veri toplama süresinin uzun olması, prosedürel sürecinin fazlalığı sebebiyle standardizasyonun sağlanamaması ve nitelikli sağlık teknisyenine ihtiyaç bulunması gibi bazı dezavantajlara sahiptir. Cihaz içinde hareketsiz kalınmasını ve nefes tutulmasını gerektiren süreçleri bulunması sebebiyle özellikle çocuklarda bu yöntemin kullanımı açısından zorluklar bulunmaktadır [3], [4], [20], [21]. Vücut kas kütlesinin ölçümünde bilgisayarlı tomografi yöntemi de kullanılabilir. BT vücut kas kütlesinin ölçümünde güvenilir sonuçlar vermesine rağmen maliyeti yüksek, tecrübeli personel ihtiyacının olduğu, taşınamayan ve geniş alan gereksinimi bulunan bir yöntemdir. Ayrıca BT uygulamasında yüksek radyasyon maruziyeti de söz konusudur [3], [4], [10], [20], [21], [23]. Periferik Kantitatif BT taşınabilirlik ve daha düşük radyasyon maruziyetine sahip olması dolayısıyla normal bilgisayarlı tomografinin alternatifi olarak kullanılabilir olmasına rağmen, bu yöntemde yalnız vücudun alt ve üst ekstremiteleri incelenebildiğinden dolayı net bir


şekilde kasların ayrımı yapılamamaktadır [24]. Pek çok hastalığın ön tespitinde kullanılan ultrasonografi yöntemi, radyasyon içermeyen ve ses dalgaları yardımıyla vücut yoğunluğunun belirlendiği bir yöntemdir. Yansıyan ses dalgaları dönüştürülerek elektriksel sinyaller elde edilmektedir. Ultrason yöntemi için nitelikli personel ihtiyacının bulunması ve subkutan (deri altı kalınlığı) ile hidrasyon (vücuttaki su ve elektrolit düzeyinin belirli seviyede tutulması) gibi etkenlere karşı hassasiyet göstermesi söz konusudur [3], [20], [21], [23]. Uygulama yapılacak bölgenin sıkıştırılması, dönüştürücüye uygulanan basınç seviyesi gibi hususlar sebebiyle bu yöntemin sonucu uygulayıcı personele göre değişkenlik gösterebilir. Bu sebeple güvenilirliği düşük bir yöntemdir [3], [10], [20], [23]. DXA yöntemi esasen kemik mineral yoğunluğunun tespit edilmesinde kullanılmasının yanında vücut yağsız kütleinin tespiti için de kullanılabilen bir yöntemdir. Maliyetinin yüksek olması, taşınabilir olmayışı ve cihaz üreticileri arasında donanım-yazılımsal farklılıkların söz konusu olması ve nitelikli personel ihtiyacının bulunması gibi bazı dezavantajları mevcuttur [4], [20], [23]. DXA yönteminde ağırlık, genişlik ve uzunluk gibi bazı kısıtlamalar söz konusu olduğu için bu yöntem tüm bireylerde uygulanamamaktadır [25]. Ayrıca düşüğe olsa bu yöntemde radyasyon maruziyeti bulunmaktadır. Bundan dolayı hamile bireyler için kullanılamayan bir yöntemdir [3], [21], [23], [26]. BIA yönteminde vücut bir iletken olarak kabul edilir ve vücuda düşük / hissedilmeyen bir seviyede akım verilerek vücut kompozisyonu hesaplanmaktadır. Gövde ve ekstremiteler uzunluğu, elektrotların yerleşim yeri, bireyin beslenme, genel sağlık durumu ile en son yaptığı fiziksel aktivite, vücut hidrasyonu, doku sıcaklığı gibi bu yöntemin doğruluğunun etkilendiği parametreler bulunmaktadır [3], [4], [10], [23]. Bu yöntemde denklemlere dayalı hesaplamalar yapıldığı için farklı cihazlarda farklı sonuçlar gözlemlenebilir, bu da sistemin güvenilirliğini azaltmaktadır [26]–[28]. Kullanılan denklemler popülasyona özgü olduğundan ve ölçüm yöntemi standartlaştırılmadığı için bu yöntemde bazı kısıtlar mevcuttur [3], [23], [26], [28]. Yöntem hamile ve kalp pili bulunan bireylerde de kullanılamamaktadır. Literatürde yer alan çalışmalar BIA yönteminin DXA yöntemiyle kıyaslandığında tutarsızlığa sahip olduğunu, ultrason yöntemi ile kıyaslandığında ise güvenilirliğinin daha düşük olabileceği görülmektedir [29], [30]. BIA yöntemi fonksiyonel olmasına rağmen varsayımlara dayalı çalışması sebebiyle VKY hesaplamasında kullanılabilecek referans bir yöntem

kabul edilmemektedir [31]. ADP yönteminde kapalı bir platforma giren bireyin, havanın yer değiştirme özelliğinden faydalanılarak vücut hacmi ölçülmektedir. Vücuttaki kas dağılımını spesifik olarak belirleyememesi, kapalı alan korkusu olan bireylerde kullanılamaması gibi dezavantajları mevcuttur [3], [4]. NAA yöntemi vücut bileşiminin kimyasal olarak analizine dayanan bir yöntemdir. Bu yöntemle vücut iskelet kası kapsamlı, güvenilir olarak belirlenebilir. Radyasyona maruziyet, uygulamada ki teknik zorluk, nitelikli personel ihtiyacı ve yüksek maliyet gibi dezavantajları mevcuttur. EIM yöntemi kas kompozisyonunun belirlenmesinde kullanılabilen non-invaziv, etkili ve ağrısız bir yöntemdir. Yöntemin kullanımı yaygın olmamakla birlikte nitelikli personel ihtiyacı bulunmaktadır, bundan dolayı klinik uygulamalar için uygun görülmemektedir [21]. EIM yöntemi uygulanacak bireyin konumlandırılması, yöntemin güvenilirliği ve çeşitli faktörlerle ilgili bilgilerde yetersizlik bulunmaktadır [32]. Antropometrik ölçümler, vücut kompozisyonu ve kas kütlelerinin tahmininde kullanılan yöntemlerden biridir. Maliyeti ucuz, non-invaziv ve çoğunlukla yaygın olarak uygulanabilir bir yöntem olmasına rağmen yaşlı bireyler için standardizasyonu, çocuk ve gençlere kıyasla daha azdır. Biyokimyasal belirteçler de kas kütlelerinin ölçümünde kullanılabilen yöntemlerden biri olarak değerlendirilmektedir. Fakat bu yöntemin uygulanmasında da önemli kısıtlar söz konusudur. Total veya Kısmi Vücut Potasyumu yönteminde ki hesaplamalar yaşlı ve çeşitli hastalıklara sahip bireyler için geçerli kabul edilemeyen bazı varsayımlar içerdiğinden dolayı bu bireyler için önerilmemektedir [21]. Kastaki kreatin fosfatın parçalanması sonucu, kreatinin ve onun serum seviyesi ortaya çıkmaktadır. Dolaşımda bulunan kreatinin, stabil böbrek fonksiyonları (et tüketimi) altında kas kütlesi miktarı ile orantılı olduğu varsayılmaktadır. İdrar kreatinin yöntemi, 24 saatlik idrar toplama gereksinimi olduğundan ve yaşlı bireyler için referans değerinin bulunmamasından dolayı zorluklar içermektedir. D3 Kreatin Dilüsyonu yönteminde nitelikli personel ve gelişmiş /komplike ekipman ihtiyacı bulunmaktadır. Ayrıca bu yöntemde idrar örneğinin işlenmesi ve D3 kreatinin belirlenmesi zorluklar içermektedir [21] ve D3 kreatin yönteminin kas kütlesiyle ilgili olmadığını belirten bazı çalışmalar da bulunmaktadır [33], [34]. Kas kütlesi tayini için kullanılabilen yöntemlerin çeşitli dezavantajlara sahip olması sebebiyle yeni yöntemlere ihtiyaç bulunmaktadır.

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Akış Diyagramı

Çalışmanın uygulama adımları Şekil 3.1.'de gösterilmiştir. Öncelikle bireylerden EKG sinyalleri toplanmış olup, sonrasında EKG sinyalleri farklı QRS bant aralıklarında filtrelenmiştir. Her aralıktan 25 adet zaman domeninde özellik çıkartılmıştır. Demografik bilgiler ve sinyal özellikleri birleştirilerek cinsiyet bazlı tekrar gruplandırılmıştır. Birleştirilen özellikler özellik seçme algoritması yardımıyla azaltılmış olup makine öğrenmesi algoritmaları yardımıyla VKY değerleri tahmin edilmiştir.



Şekil 3.1. Akış Diyagramı

3.2. Verilerin Toplanması

Çalışma kapsamında kullanılan veriler, Sakarya Üniversitesi sağlıklı beslenme ve danışmanlık birimine beslenme ve danışmanlık hizmeti için Eylül 2019 - Şubat 2020 tarihleri arasında başvuru yapan bireylerin kayıtlarından oluşmaktadır. Çalışma için etik kurul ve veri kullanım izinleri alınmıştır. Etik kurul izni Sakarya Üniversitesi, Tıp Fakültesi'nden 03/05/2019 tarihinde 71522473/050.01.04/112 sayılı izin belgesi ile alınmıştır. Verilerin kullanım izni Sakarya Üniversitesi Rektörlüğünden 27/08/2019 tarih ve sayılı 35955870/604.02 belge ile alınmıştır.


Çalışma kapsamında 300 gönüllü bireyden alınan veriler kullanılmıştır. Bireylere ait demografik bilgiler Tablo 3.1.'de verilmiştir. Makine öğrenmesi sürecinde demografik bilgiler özellik olarak kullanılmıştır (Şekil 3.1.).

Tablo 3.1. Demografik bilgiler

Bilgiler	Erkek			Kadın			Toplam		
	n=160			n=140			n=300		
	Ort	±	Std	Ort	±	Std	Ort	±	Std
Yaş	23.67	±	6.55	23.06	±	5.86	23.38	±	6.24
Kilo	78.71	±	14.27	61.42	±	10.77	70.64	±	15.39
Boy	175.45	±	6.33	162.44	±	6.04	169.38	±	8.97
BMI	25.57	±	4.41	23.30	±	4.11	24.51	±	4.41
Kas %	78.10	±	6.51	69.76	±	7.24	73.37	±	8.52

Ort Ortalama, Std Standart Sapma, BMI Body Mass Indeks

Çalışmada verileri kullanılan bireylerin boy, vücut ağırlığı ve vücut kas yüzdesi dağılımlarının grafiksel gösterimi Şekil 3.2.'de verilmiştir. Grafik, cinsiyet bazlı modellerin kurulması durumunda daha iyi performans gözlenebileceği hususunda izlenim oluşturmaktadır. Bu sebeple çalışmada önerilmiş olan modeller cinsiyet bazlı gerçekleştirilmiştir.



Şekil 3.2. Erkek ve kadınların boy uzunluğu / vücut ağırlığı / vücut kas yüzdesi (VKY) dağılımı

3.3. Sinyal Önileme


EKG sinyalinin üzerinde bulunan gürültünün temizlenmesi için 0,1-20 Hz IIR-Chebyshev Type II bant geçiren filtresi kullanılmıştır.

Literatürde QRS kompleksinin 7 farklı frekans bandında hesaplandığını gösteren çalışmalar mevcuttur (Tablo 3.2.). Sinyal işleme sürecinde ki verimin artırılması amacıyla, literatürde var olan 7 farklı QRS frekans bandı bu çalışmada kullanılmıştır.


Tablo 3.2. QRS frekans bant aralığı

İsim	Referans	Frekans Bandı (Hz)
QRS 1	1	5-15
QRS 2	2	5-11
QRS 3	3	8-58.5
QRS 4	4	3-40
QRS 5	5	8-20
QRS 6	6	9-30
QRS 7	7	2-40

Tablo 3.2.'de verilen QRS frekans bantlarını elde edebilmek için, EKG sinyaline her frekans aralığı için IIR-Chebyshev Type II bant geçiren filtresi uygulanmıştır. İşlem sonunda EKG ve yeni QRS bileşenlerini içeren sinyaller (7 adet) olmak üzere toplam sekiz sinyal meydana gelmiştir. Elde edilen sinyallerin erkek ve kadın bireyler için örnek gösterimi Şekil 3.3 ve 3.4'te verilmiştir. Sinyallerin frekans bileşenleri ve genlikleri benzerlik göstermektedir.



Şekil 3.3. Kadınlara ait filtrelenmiş EKG ve QRS sinyalleri



Şekil 3.4. Erkekler için filtrelenmiş EKG ve QRS sinyalleri

3.4. Özellik Çıkarma

Bu adıma kadar elde edilen toplam 8 sinyalin her birinden ayrı ayrı olmak üzere 25 adet özellik çıkartılmıştır (Tablo 3.3.). Formülde geçen x sinyali temsil etmektedir. ‘*’ olarak belirtilen özellikler, MATLAB kütüphanesi kullanılarak hesaplanmıştır. Sekiz sinyalden toplan 200 özellik çıkartılmıştır (Tablo 3.4.)

Tablo 3.3. Özelliklere ait eşitlikler

No	Özellikler	Denklem
1	Basıklık (Kurtosis)	$x_{kur} = \left(\sum_{i=1}^n (x(i) - \bar{x})^4 \right) / ((n-1) S^4)$
2	Çarpıklık (Skewness)	$x_{ske} = \sum_{i=1}^n (x_i - \bar{x})^3 / ((n-1) S^3)$
3	* Çeyrekler arası genişlik	$IQR = iqr(x)$
4	Değişim 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	Hjort parametresi - Aktivite	$A = S^2$
8	Hjort parametresi - Hareketlilik	$M = S^2 / S^2$
9	Hjort parametresi - Karmaşıklık	$C = \sqrt{(S_2^2 / S_1^2)^2 - (S_1^2 / S^2)^2}$
10	* Maksimum	$x_{max} = \max(x_i)$

Tablo 3.3. (Devamı)

No	Özellikler	Denklem
11	Medyan	$\tilde{x} = \begin{cases} x_{\frac{n+1}{2}} & : x \text{ odd} \\ \frac{1}{2} (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & : x \text{ even} \end{cases}$
12	* Ortalama ya da meydan mutlak sapma	$MAD = mad(x)$
13	* Minimum	$x_{min} = \min(x_i)$
14	* Moment, merkezi moment	$CM = moment(x, 10)$
15	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
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	$SF = X_{rms} / (\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i })$
22	* Tekil değer ayrışımı	$SVD = svd(x)$
23	* %25 kırpılmış ortalama	$T25 = trimmean(x, 25)$
24	* %50 kırpılmış ortalama	$T50 = trimmean(x, 50)$
25	Ortalama Teager enerjisi	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$

* Matlab fonksiyonu kullanılarak elde edilmiştir.

Tablo 3.4. Özellik Sayıları

Sinyal	EKG	QRS 1	QRS 2	QRS 3	QRS 4	QRS 5	QRS 6	QRS 7
	25	25	25	25	25	25	25	25

3.5. Özellik Seçme ve Sınıflandırma Algoritmaları

Bu çalışma kapsamında özellik seçim işlemi için Spearman Özellik Seçme Algoritması kullanılmıştır.

3.5.1. Spearman özellik seçme algoritması

Spearman Özellik Seçme Algoritması'nda özellikler korelasyon katsayılarına göre sıralanmakta ve kullanıcının seçilecek özellik miktarını belirlemesi mümkün olmaktadır. Spearman Korelasyon Katsayısı r_s , iki değişken grubu arasında ilişkinin incelenmesi için kullanılmakta olup, Denklem 3.1.'e göre hesaplanmaktadır. Denklemde bulunan d_i , i.nci gözlemlerin sıra numaraları arasında ki farkı, n ise gözlem sayısını ifade etmektedir.

$$r_s = 1 - 6 \sum_{i=1}^n \frac{d_i^2}{n(n^2 - 1)} \quad (3.1)$$

Algoritmanın kullanılmasıyla, özellikler ile tahmin edilecek parametre arasında ilişki düzeni belirlenmektedir. Bu sayede her bir özellik için 0-1 aralığında değişen korelasyon katsayısı r_s hesaplanmaktadır[35]. r_s değerinin büyükten küçüğe doğru sıralanmasıyla istenilen sayıda özellik seçimi yapılabilir.

Değişkenler arasında ilişkinin var olup olmadığını göstermek amacıyla Hypothesis testi uygulanmaktadır.

$H_0 = \rho_s = 0$ (İki değişken arasında ilişki bulunmamaktadır.)

$H_1 = \rho_s \neq 0$ (İki değişken arasında ilişki mevcuttur ve ilişki katsayısı 0'dan farklıdır.)

Gözlem sayısı (n) $n > 30$ olması durumunda ve değişkenlerin sıralanması(rank) işlemleri sonrasında aynı sıra numarasını alan fazla sayıda gözlem yoksa r_s değerinin anlamlılığını kontrol etmek amacıyla Denklem 3.2'den faydalanılır.

$$t = \frac{r_s}{\sqrt{\frac{1 - r_s^2}{n - 2}}} \quad (3.2)$$

İstatistiksel karar verilirken $n < 30$ olması durumunda, hesaplanarak bulunan r_s değeri, değişik α yanılma düzeyleri ile $n-2$ serbestlik derecesine göre r_s değerlerinin

bulunduğu kritiklik tablosu ile karşılaştırılmaktadır[35]. Eğer hesaplanan r_s değeri, tablodan tespit edilen r_s değerinden büyükse ($r_s > r_{s-tablo}$), H_0 hipotezi reddedilmektedir.

$n > 30$ olması halinde Denklem 3.2 ile hesaplanan t istatistik değeri, seçilen α yanılma düzeyinde bulunan $n-2$ serbestlik dereceli , tablodan tespit edilen t istatistiği ile karşılaştırılır. Hesaplanan t değeri, tabloda yazan t değerinden büyükse ($t_{hesaplanan} > t_{tablo}$), bu durumda H_0 hipotezi reddedilmektedir.

Çalışmada özellikler %5-50 aralığında seçilerek VKY tahmini yapılmıştır. Seçilen özellik miktarı ve yüzdesi Tablo 3.5.'de özetlenmiştir.

Tablo 3.5. Seçilen Özellik Dağılımı

Level	Yüzde (%)	Özellik Sayısı
1	5	10
2	10	21
3	15	31
4	20	41
5	25	52
6	30	62
7	35	72
8	40	82
9	45	93
10	50	103
	100	205

Seçilen özelliklerin hangi verilerde bulunduğu bilgisine Tablo 3.6.'dan ulaşılabilir. Örneğin tüm bireylerde özelliklerin %5 'i seçildiğinde (10 özellik) , özelliklerin ECG, QRS-2 , QRS-7 ve demografik bilgilerde bulunduğu görülmektedir.Özellik seçim işlemi sonrasında, anlamlı çıkmayan özellikler tabloda '-' olarak gösterilmiştir.

Tablo 3.6. Erkekler, kadınlar ve tüm bireylerde seçilen özellikler

ÖN	ECG				QRS																												Demografik Bilgiler			
					1				2				3				4				5				6				7							
	Derece				Derece				Derece				Derece				Derece				Derece				Derece				Derece							
	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K	ÖN	T	E	K
1	1	11	29	37	26	23	101	193	51	82	7	39	76	75	89	197	101	74	3	40	126	69	72	159	151	72	35	194	176	19	2	190	201	1	-	-
2	2	14	99	72	27	106	70	77	52	5	86	66	77	81	197	65	102	140	96	185	127	65	160	11	152	152	156	98	177	12	140	164	202	53	-	-
3	3	70	201	126	28	122	164	55	53	79	38	93	78	85	139	16	103	107	173	14	128	146	73	62	153	88	200	20	178	169	155	63	203	20	23	9
4	4	61	165	155	29	108	94	171	54	199	92	29	79	170	132	162	104	101	159	2	129	62	143	5	154	30	175	4	179	155	149	158	204	2	1	1
5	5	-	-	-	30	129	183	44	55	83	36	111	80	86	145	19	105	104	154	17	130	143	78	73	155	89	199	25	180	148	163	68	205	-	147	127
6	6	-	-	-	31	159	174	96	56	182	114	137	81	67	153	99	106	171	187	146	131	167	148	198	156	179	193	188	181	188	166	38				
7	7	196	105	128	32	93	176	48	57	42	13	174	82	173	57	78	107	36	39	88	132	109	30	141	157	189	119	57	182	54	81	106				
8	8	119	103	201	33	33	125	181	58	41	157	134	83	21	126	192	108	34	144	149	133	26	134	166	158	24	130	186	183	35	131	152				
9	9	133	150	70	34	195	192	114	59	131	27	170	84	114	141	85	109	136	74	120	134	178	87	157	159	115	181	97	184	144	116	138				
10	10	145	91	183	35	63	71	125	60	77	6	151	85	98	138	104	110	118	9	54	135	180	62	161	160	137	104	139	185	87	22	27				
11	11	6	195	22	36	127	52	3	61	9	21	148	86	90	169	47	111	147	172	56	136	27	97	28	161	141	194	26	186	16	80	116				
12	12	157	137	74	37	117	185	42	62	60	24	147	87	134	102	32	112	73	93	33	137	186	49	105	162	130	167	30	187	100	168	86				
13	13	164	124	103	38	50	53	118	63	92	11	135	88	120	117	154	113	151	37	67	138	168	51	173	163	160	95	156	188	78	20	23				
14	14	103	47	199	39	52	79	95	64	31	4	168	89	158	77	124	114	71	10	131	139	139	28	165	164	184	56	136	189	28	12	133				
15	15	32	189	75	40	121	142	84	65	125	98	71	90	132	162	100	115	128	198	121	140	183	111	187	165	47	108	123	190	48	171	140				
16	16	194	129	184	41	126	191	167	66	163	48	172	91	68	190	36	116	172	69	117	141	185	67	163	166	102	161	102	191	91	196	122				
17	17	201	112	112	42	94	177	49	67	43	14	175	92	174	58	79	117	37	40	89	142	110	31	142	167	190	120	58	192	55	82	107				
18	18	202	113	113	43	95	178	50	68	44	15	176	93	175	59	80	118	38	41	90	143	111	32	143	168	191	121	59	193	56	83	108				
19	19	197	106	129	44	96	179	51	69	45	16	177	94	176	60	81	119	39	42	91	144	112	33	144	169	192	122	60	194	57	84	109				
20	20	198	107	130	45	97	180	52	70	46	17	178	95	177	61	82	120	40	43	92	145	113	34	145	170	193	123	61	195	58	85	110				
21	21	105	100	160	46	187	188	180	71	161	26	195	96	149	118	189	121	166	44	196	146	200	88	200	171	165	146	179	196	142	50	191				
22	22	162	110	132	47	66	158	41	72	15	18	169	97	123	46	53	122	17	45	87	147	76	25	119	172	138	109	45	197	22	76	101				
23	23	10	182	69	48	64	68	46	73	3	5	83	98	59	133	18	123	156	63	115	148	29	135	24	173	153	90	153	198	7	55	35				
24	24	8	186	31	49	124	54	7	74	4	19	150	99	51	152	15	124	181	128	94	149	25	115	21	174	135	127	76	199	13	75	64				
25	25	150	136	6	50	49	151	34	75	18	8	182	100	99	170	8	125	84	65	10	150	116	64	43	175	154	184	12	200	80	66	13				

ÖN Özellik No, 201 Cinsiyet, 202 Yaş, 203 Kilo, 204 Boy, 205 Vücut Kütle İndeksi

3.6. Makine Öğrenmesi

Bu çalışmada aşağıdaki makine öğrenmesi algoritmaları kullanılmıştır.

- 1) Karar Ağaçları (KA)
- 2) Karar Ağaçları Toplulukları (KAT)
- 3) Destek Vektör Regresyonu (SVR)

Bu algoritmalar göstermiş oldukları yüksek performans ile birlikte eğitim sürelerinin kısa olması sebebiyle literatürde sıklıkla tercih edilmektedirler. [36]–[38]

3.6.1. Karar ağaçları

Karar ağaçları sınıflandırma ve regresyon problemleri için kullanılabilen bir makine öğrenmesi algoritmasıdır [39]–[41]. Karar ağaçları, kural tabanlı sistemler oluşturduklarından dolayı farklı sistemlere entegrasyonu edilmeleri kolaydır. Algoritmanın isminde de anlaşılabilceği üzere yapı bir ağaç şeklindedir. Gövdeden yapraklara kadar giden dallanmalar ile birlikte bir dağılımı bulunmaktadır. Dallanmalar değişkenlerin değerlerine göre yapılmakta olup, yapraklar ise en son etiketleri ifade etmektedir.

Çalışma kapsamında kullanılan Karar Ağaçları makine öğrenmesi algoritması için Matlab’te yer alan fitrtree algoritmasından faydalanılmıştır. Fitrtree algoritmasına ait denklemler aşağıdaki gibidir [40], [42], [43].

Bir t düğümünde bulunan ağırlıklı ortalama karesel hata (ϵ_t) Denklem 3.3.’e göre hesaplanmaktadır. Denklem 3.3.’te yer alan w_j , j gözleminin ağırlığını, T ise t düğümündeki tüm gözlem indislerinin kümesini ifade etmektedir. y_j , j gözleminin değerini, $\bar{y}_t$ ise t düğümündeki yanıtın ağırlıklı ortalamasını ifade etmektedir.

$$\epsilon_t = \sum_{j \in T} w_j (y_j - \bar{y}_t)^2 \quad (3.3)$$

Bir t düğümündeki gözlemin olasılık tahmini $P(T)$ Denklem 3.4.'e göre hesaplanmaktadır.

$$P(T) = \sum_{j \in T} w_j \quad (3.4)$$

Fitrtree algoritmasında özellikler x_i artan şekilde sıralamaktadır. Sıralanan her bir özellik, bir bölme adayını veya kesme noktasını temsil etmektedir. Fitrtree, bölünmemiş küme olan T_U kümesindeki eksik değerlerin karşılığı olan tüm indeksleri kaydetmektedir.

Fitrtree algoritması t düğümündeki gözlemleri, sağ alt düğüm (t_R) ve sol alt düğüm (t_L) olarak ayırmaktadır. Sağ alt düğüm (t_R) ile sol alt düğüm (t_L)'e ait gözlem indeksi kümeleri ise sırasıyla T_R ve T_L 'dir. Eğer özellik x_i de herhangi bir eksik değer yoksa, ΔI (MSE 'de ki azalma) Denklem 3.5.'e göre hesaplanmaktadır.

$$\Delta I = P(T) \varepsilon_t - P(T_L) \varepsilon_{t_L} - P(T_R) \varepsilon_{t_R} \quad (3.5)$$

Eğer özellik x_i eksik değerler içeriyorsa bu durumda, ΔI_U Denklem 3.6.'ya göre hesaplanmaktadır. Burada bulunan $T-T_U$ ifadesi, t düğümündeki eksik olmayan tüm indekslerin kümesini ifade etmektedir.

$$\Delta I_U = P(T - T_U) \varepsilon_t - P(T_L) \varepsilon_{t_L} - P(T_R) \varepsilon_{t_R} \quad (3.6)$$

3.6.2. Destek vektör regresyonu

Destek vektör regresyonu (SVR) sınıflandırma ve regresyon problemlerinde kullanılan yüksek performanslı bir makine öğrenmesi algoritmasıdır [44]. Lineer ve nonlinear problemlerde sıklıkla kullanılmaktadır. Bu algoritmada veriler özelliklere göre eksen üzerinde ayrıldıktan sonra, sınıfları birbirinden ayıran eğri oluşmaktadır. Sonrasında, oluşturulan eğriye göre sınıflandırma işlemi gerçekleştirilmektedir [45].

Çalışma kapsamında kullanılan Destek Vektör Regresyonu makine öğrenmesi algoritması için Matlab'te yer alan fitrsvm algoritmasından faydalanılmıştır. Fitrsvm algoritmasına ait denklemler , Denklem 3.7 - 3.11 'de verilmiştir[45]–[49].

Özelliklere ait ağırlıklı ortalamalar Denklem 3.7.'ye göre hesaplanmaktadır. x_j özelliği, μ_j^* özelliğin ağırlıklı ortalamasını , σ_j^* ise özelliğin ağırlıklı standart sapmasını temsil etmektedir.

$$x_j^* = \frac{x_j - \mu_j^*}{\sigma_j^*} \quad (3.7)$$

Ağırlıklı ortalamalar μ_j^* Denklem 3.8'e göre hesaplanmaktadır. Denklemde bulunan w_k , k gözlemine ait ağırlığı , x_{jk} ise j özelliğine (sütun) karşılık gelen k gözlemini (satır) ifade etmektedir.

$$\mu_j^* = \frac{1}{\sum_k w_k} \sum_k w_k x_{jk} \quad (3.8)$$

Ağırlıklı standart sapma σ_j^* Denklem 3.9'a göre hesaplanmaktadır. v_1 ve v_2 özelliklerin ağırlıklı değerlerini temsil etmektedir. Sırasıyla Denklem 3.10 ve 3.11 'e göre hesaplanmaktadır.

$$(\sigma_j^*)^2 = \frac{v_1}{v_1^2 - v_2} \sum_k w_k (x_{jk} - \mu_j^*)^2 \quad (3.9)$$

$$v_1 = \sum_j w_j \quad (3.10)$$

$$v_2 = \sum_j (w_j)^2 \quad (3.11)$$

3.6.3. Karar ağaçları toplulukları

Karar Ağaçları Toplulukları regresyon modellerinin oluşturulmasında sıklıkla tercih edilen yüksek performanslı bir makine öğrenmesi algoritmasıdır [39], [41]. Model, özellik sayısı kadar (L) karar ağacından oluşmaktadır.

Çalışmada LSBoost (Least Squares Boosting Ensemble) yöntemi kullanılmıştır. Gradyan Boosting Ensemble yöntemi, bir sonlu zayıf öğreniciler kümesinden ve her bir öğreniciye ağırlık atayan , regresyon problemleri için daha iyi tahmin sonuçları sağlamak amacıyla oylama yöntemlerini kullanarak her birinin tahmin sonuçlarını birleştiren bir meta öğreniciden (öğrenmeyi öğrenme) oluşur. Boosting, verinin eğitim, doğrulama ve test setlerine ayrıldığı denetlebilir (supervised) bir makine öğrenmesi yöntemidir. Algoritma, karar ağaçları şeklinde olan özgün zayıf öğreniciler eğiterek başlamaktadır ve daha iyi performansa ulaşmak için hata kalıntılarına uyum sağlar. LSBoost yöntemi, kayıp kriteri olarak en küçük kareleri kullanır. Friedman tarafından sunulan yöntemin algoritması aşağıdaki şekildedir [50], [51].

Açıklanabilir değişkenler olarak x_i ve y_i tanımlanır. M iterasyonların numarasını göstermektedir. Eğitim seti Denklem 3.12 ile , kayıp fonksiyonu Denklem 3.13 ve regresyon fonksiyonu olarak $F_m(x)$ tanımlanır.

$$\text{Eğitim Seti : } \left\{ (x_i, y_i) \right\}_{i=1}^n \quad (3.12)$$

$$\text{Kayıp Fonksiyonu: } L(y, F) = \frac{(y - F)^2}{2} \quad (3.13)$$

Başlangıçta $F_0(x) = \bar{y}$ olarak kabul edilir. Burada ki $\bar{y}$ tahmin edilen değeri göstermektedir.

m, 1 den başlatılıp iterasyon sayısına (M) kadar arttırılarak Denklem 3.14 uygulanır. F_{m-1} , m.nci iterasyondaki kestirimini ifade etmektedir. Denklem 3.15 ve Denklem 3.16 için daha detay bilgiye [50], [51] numaralı referanslardan ulaşılabilir.

$$\bar{y}_i = y_i - F_{m-1}(x_i) \quad , \quad i=1,2,3,\dots,N \quad (3.14)$$

$$(\rho_m, \alpha_m) = \operatorname{argmin}_{\rho, \alpha} \sum_{i=1}^N [\bar{y}_i - \rho h(x_i, \alpha)]^2 \quad (3.15)$$

$$F_m(x) = F_{m-1}(x) + \rho_m h(x; \alpha_m) \quad (3.16)$$

3.7. Performans Değerlendirme Kriterleri

Çalışmada geliştirilen modellerin değerlendirilmesinde yedi adet performans değerlendirme kriteri kullanılmıştır. Kullanılan performans değerlendirme kriterleri: (1) Mean Absolute Percentage Error (MAPE), (2) Root Mean Square Error (RMSE), (3) Mean Absolute Difference (MAD), (4) Standart Error (SE), (5) Korelasyon Katsayısı (R), (6) Açıklayıcılık Katsayısı (R^2) ve (7) Mean Squared Error (MSE)'dir.

İki değişken arasındaki korelasyon değeri $|r| < 0,70$ ise sistemin tahmin etme hata oranının oldukça yüksek olduğu söylenebilir. $0,5 < |r| < 0,7$ olması durumunda sistemin kestirimi düşük, $0,7 < |r| < 0,9$ ise sistemin kestirimi orta, $0,9 < |r|$ ise sistemin kestiriminin yüksek olduğu söylenebilir [52].

Ham artıklar (e_i), gerçek değerler (t_i) ile tahmin edilen değerler (y_i) arasındaki farktan meydana gelmektedir (Denklem 3.17). e_i sifıra ne kadar yakın olursa, makine öğrenmesi yöntemi ile geliştirilen sistemin başarısının o kadar yüksek olduğu söylenebilir[52].

$$e_i = t_i - y_i \quad (3.17)$$

Standart Hata (s) geliştirilen yöntemin verilere uyumunu göstermektedir [52] (Denklem (3.18)). Korelasyon değerinin 1'den küçük olması, sistemin %100 doğruluk ile tahmin yapamadığını ve gerçek değerlerden sapmalar (e_i) meydana geldiğini göstermektedir. Geliştirilen sistemin standart hatası s, bu sapmaların standard sapmasıdır. (e_i) azalmasıyla birlikte s de azalır. s 'in azalmasıyla sistem güvenilirliği artmaktadır [52].

$$s = \sqrt{\frac{\sum_{i=1}^n (t_i - y_i)^2}{n-2}} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n-2}} \quad (3.18)$$

Açıklayıcılık Katsayısı (R^2), regresyon modeli ile açıklanabilen değişimin, toplam değişim içindeki payını yüzde olarak tanımlamaktadır (Denklem 3.19)[52]. Başka bir ifadeyle, R^2 bağımlı değişkendeki toplam değişimin yüzde kaçının bağımsız değişken tarafından açıklanabildiğini göstermektedir.

$$R^2 = r^2 = \frac{KT_R}{KT_T} \quad (3.19)$$

R^2 açıklayıcı denklemi; Gerçek değerler (t_i), Tahmin edilen değerler (y_i), verisayısı (n), Kareler Toplamı T (KT_T), Kareler Toplamı R (KT_R), Kareler Toplamı A (KT_A) elemanlarından oluşmaktadır. Denklemde yer alan hesaplamalar, Denklem 3.20'ye göre yapılmaktadır.

$$KT_T = KT_R + KT_A \quad (3.20)$$

$$KT_T = \sum_{i=1}^n (t_i - \bar{t})^2 = \sum_{i=1}^n t_i^2 - \frac{(\sum_{i=1}^n t_i)^2}{n}$$

$$KT_R = \sum_{i=1}^n (y_i - \bar{t})^2$$

$$KT_A = \sum_{i=1}^n (t_i - y_i)^2$$

MSE, hataların karelerinin ortalamasını ifade etmektedir. (Denklem 3.21). Denklemde bulunan e_i , hataları ifade etmekte olup, Denklem 3.17.'ye göre hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3.21)$$

RMSE, MSE'nin karakökünü ifade etmektedir. MSE ve RMSE parametreleri 0 'a ne kadar yakın olursa hata oranının o kadar az olduğu söylenebilir(Denklem 3.22).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3.22)$$

Hata Oranı, gerçek değer ile tahmin edilen değer arasındaki değişimin yüzdelik olarak ifade edilmesidir. (Denklem (3.23)).

$$H_{err} = \frac{1}{n} \sum_{i=1}^n \frac{|t_i - y_i|}{t_i} \times 100 \quad (3.23)$$

Makine öğrenmesi eğitim ve test süreçlerinde veri seti, eğitim %80, test %20 olmak üzere iki parçaya ayrılmıştır. İşlem sonucu veri dağılımı Tablo 3.7.'de verilmiştir.

Tablo 3.7. Eğitim ve test veri seti dağılımı

Veri Seti	Eğitim (%80)	Test (%20)	Toplam
Erkek&Kadın	240	60	300
Erkek	128	32	160
Kadın	112	28	140

BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu çalışmada EKG sinyali kullanılarak, biyomedikal sinyal ve makine öğrenmesi tabanlı VKY tahmin modeli geliştirilmesi amaçlanmıştır (Şekil 3.1.). Çalışmada 300 bireyden alınan EKG sinyalleri filtrelenerek sinyallerde ki gürültüler giderilmiş ve EKG'lere ait 7 adet QRS bandına göre frekans bantlarına ayrılmıştır (Bölüm 3.3.). EKG sinyali ve elde edilen 7 adet QRS bandının (toplam 8 sinyalin) her birinden 25 adet olmak üzere toplam 200 adet istatistiksel özellik çıkarımı yapılmıştır (Bölüm 3.4.). Demografik bilgilerinde eklenmesiyle toplam 205 özellik elde edilmiştir (Tablo 3.1.). Özellik seçme algoritması kullanılarak elde edilen 205 özellik belirli seviyelerde seçilmiştir (Bölüm 3.5.). Her seviye için yapay zeka tabanlı modeller oluşturulmuştur (Bölüm 3.6.). Literatürde kullanılan 7 parametre yardımıyla, geliştirilen modellerin performansları incelenmiştir. (Bölüm 3.7.).

Çalışmada öncelikle tüm veri seti ve tüm özellikler kullanılarak erkek, kadın ve tüm bireyler için makine öğrenmesi algoritmaları ile üçer model oluşturulmuştur (Tablo 4.1.). Erkekler ve kadınlar için KA modelinin daha başarılı olduğu gözlemlenirken, tüm bireyler için ise Karar Ağaçları Toplulukları modelinin daha başarılı olduğu görülmektedir. Model MAPE performans değerinin sırasıyla erkek, kadın ve tüm bireyler için 5,06, 6,34 ve 4,18 olduğu görülmüştür. Cinsiyet ayrımı yapılmadan oluşturulan modellerde arasında Karar Ağaçları Topluluğu tabanlı model en başarılıdır. Cinsiyet bazlı modellerle karşılaştırıldığında, tüm bireyler için geliştirilen modelin performansı $MAPE=4,18$ 'dir. Tüm bireyler için geliştirilen modellerin performansının, cinsiyet bazlı modellere göre daha iyi olduğu görülmektedir. Bu farklılığın sebebinin, makine öğrenmesi algoritmaları ile veri setlerinde arasındaki uyumdan kaynaklandığı değerlendirilmektedir. (Tüm özellikler kullanılarak (%100 özellik seçimi) oluşturulan modellerin performans değerlerinin grafiksel gösterimi, tüm bireyler (Şekil 4.4.) , erkekler (Şekil 4.5.) ve kadınlar için (Şekil 4.6.) mevcuttur.)

Tablo 4.1. Tüm özellikler ile performans değerleri

Model		MAPE	RMSE	MAD	SH	R	R ²
Erkek	KA	5,06	4,57	3,85	4,72	0,77	0,59
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	4,65	4,69	3,69	4,84	0,82	0,67
Kadın	KA	6,34	5,15	3,99	5,35	0,80	0,65
	SVR	9,62	7,95	5,88	8,25	-	-
	KAT	6,95	5,43	4,59	5,63	0,88	0,77
Tüm	KA	4,66	4,11	3,18	4,18	0,91	0,84
	SVR	-	-	-	-	-	-
	KAT	4,18	3,82	2,91	3,88	0,92	0,85

QRS frekans bantlarından çıkarılan özelliklerin hangisinin daha verimli olduğunu tespit edebilmek için her bir QRS bant özellikleri üç sınıflandırıcı ile sınıflandırılmıştır (Tablo 4.2., Tablo 4.3.). Elde edilen sonuçlar pek verimli olmamakla birlikte genel anlamda verilerin bilgi içerdiği izlenimi oluşmaktadır. R performans değeri 0-0,47 arasında değişmektedir. Performansın kötü olması sebebiyle hesaplanamayan model değerleri “-” ile gösterilmiştir. Performansın düşük oluşu, QRS bantlarına göre verilerin ayrıştırılması sırasında bilgi kaybedilmiş olabileceğiyle açıklanabilir. Genel değerlendirme yapmak gerekirse farklı çalışmalarda QRS7 frekans bileşenleri kullanılarak yeni modeller oluşturulabilir. Sınıflandırıcılar veri setine göre farklı performans sergilemektedir. Ancak genel değerlendirme yapılırsa KAT modelleri daha başarılıdır. Kullanılan QRS frekans bant frekanslarının performans değerlerini

gösteren grafikler tüm bireyler (Şekil 4.1.), erkekler (Şekil 4.2.) ve kadınlar (Şekil 4.3.) için verilmiştir.

Tablo 4.2. EKG ve QRS bant özelliklerine göre VKY hesaplama model performans değerleri - 1

Özellik	Model EKG							
		MAPE	RMSE	MAD	SH	R	R ²	
EKG	Erkek	KA	6,74	6,36	5,08	6,57	0,40	0,16
		SVR	7,07	6,70	5,31	6,92	-	-
		KAT	9,56	8,76	7,15	9,05	-0,04	0,00
	Kadın	KA	9,58	8,00	5,94	8,30	-0,08	0,01
		SVR	9,62	7,95	5,88	8,25	-	-
		KAT	8,63	7,71	5,56	8,00	0,41	0,17
	Erkek&Kadın	KA	10,22	8,90	6,93	9,05	0,12	0,01
		SVR	10,29	8,90	6,99	9,06	-	-
		KAT	10,61	9,59	7,36	9,76	0,26	0,07
QRS 1	Erkek	KA	7,35	6,94	5,55	7,17	-0,14	0,02
		SVR	7,07	6,70	5,31	6,92	-	-
		KAT	8,32	7,64	6,43	7,89	0,16	0,03
	Kadın	KA	8,98	7,59	5,54	7,88	0,29	0,09
		SVR	9,62	7,95	5,88	8,25	-	-
		KAT	10,39	8,80	6,81	9,13	0,25	0,06
	Erkek&Kadın	KA	10,37	8,98	7,07	9,14	0,09	0,01
		SVR	10,29	8,90	6,99	9,06	-	-
		KAT	11,35	9,66	7,90	9,83	0,24	0,06
QRS 2	Erkek	KA	6,75	6,52	5,04	6,73	0,31	0,10
		SVR	7,07	6,70	5,31	6,92	-	-
		KAT	7,53	7,08	5,71	7,31	0,33	0,11
	Kadın	KA	10,21	8,48	6,25	8,80	-0,26	0,07
		SVR	9,62	7,95	5,88	8,25	-	-
		KAT	10,81	8,45	6,61	8,77	0,15	0,02
	Erkek&Kadın	KA	10,00	8,78	6,80	8,93	0,25	0,06
		SVR	10,29	8,90	6,99	9,06	-	-
		KAT	10,39	9,92	7,15	10,09	0,22	0,05
QRS 3	Erkek	KA	7,43	6,86	5,64	7,08	-0,04	0,00
		SVR	7,07	6,70	5,31	6,92	-	-
		KAT	9,21	8,87	7,17	9,16	0,16	0,03

Tablo 4.2. (Devamı)


Özellik	Model EKG							
		MAPE	RMSE	MAD	SH	R	R ²	
QRS 3	Kadın	KA	10,10	8,35	6,32	8,67	-0,20	0,04
		SVR	9,62	7,95	5,88	8,25	-	-
		KAT	11,88	9,80	7,53	10,17	0,09	0,01
	Erkek&Kadın	KA	9,95	8,64	6,73	8,79	0,31	0,10
		SVR	9,95	8,69	6,81	8,84	0,45	0,20
		KAT	11,15	9,20	7,74	9,35	0,35	0,12

Tablo 4.3. EKG ve QRS bant özelliklerine göre VKY hesaplama model performans değerleri - 2


Özellik	Model EKG								
		MAPE	RMSE	MAD	SH	R	R ²		
QRS 4	Erkek	KA	6,50	6,36	4,94	6,56	0,33	0,11	
		SVR	7,07	6,70	5,31	6,92	-	-	
		KAT	6,87	6,64	5,11	6,86	0,45	0,20	
	Kadın	KA	9,85	7,87	6,08	8,16	0,06	0,00	
		SVR	9,62	7,95	5,88	8,25	-	-	
		KAT	10,09	8,62	6,20	8,94	0,06	0,00	
	Erkek&Kadın	KA	10,20	8,66	6,93	8,80	0,23	0,05	
		SVR	10,29	8,90	6,99	9,06	-	-	
		KAT	11,30	9,81	7,66	9,98	0,23	0,05	
	QRS 5	Erkek	KA	7,35	6,82	5,58	7,04	0,03	0,00
			SVR	7,85	7,29	5,92	7,53	0,10	0,01
			KAT	7,54	7,38	5,70	7,62	0,22	0,05
Kadın		KA	9,56	8,01	5,89	8,31	-0,04	0,00	
		SVR	9,62	7,95	5,88	8,25	-	-	
		KAT	11,50	9,62	7,28	9,99	0,05	0,00	
Erkek&Kadın		KA	10,17	8,82	6,94	8,97	0,19	0,04	
		SVR	10,29	8,90	6,99	9,06	-	-	
		KAT	11,34	10,23	7,86	10,40	0,16	0,03	
QRS 6	Erkek	KA	7,16	6,69	5,37	6,91	0,05	0,00	
		SVR	7,07	6,70	5,31	6,92	-	-	
		KAT	7,91	7,95	6,10	8,21	0,07	0,00	
	Kadın	KA	10,06	8,22	6,29	8,53	-0,15	0,02	
		SVR	9,62	7,95	5,88	8,25	-	-	
		KAT	10,35	8,29	6,61	8,61	0,33	0,11	

Tablo 4.3. (Devamı)


Özellik	Model EKG	MAPE	RMSE	MAD	SH	R	R ²
QRS6	KA	10,37	8,99	7,08	9,14	-0,04	0,00
	SVR	10,29	8,90	6,99	9,06	-	-
	KAT	11,44	10,73	8,16	10,92	0,24	0,06
Kadın	KA	6,62	6,41	5,10	6,62	0,34	0,11
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	6,61	6,85	5,27	7,08	0,46	0,21
QRS 7	KA	9,87	8,50	6,05	8,82	-0,12	0,01
	SVR	9,62	7,95	5,88	8,25	-	-
	KAT	10,43	8,62	6,42	8,94	0,11	0,01
Kadın	KA	10,97	9,43	7,51	9,59	-0,12	0,02
	SVR	10,09	8,57	6,86	8,71	0,27	0,07
	KAT	11,11	9,85	7,58	10,01	0,33	0,11



Şekil 4.1. Erkekler için QRS frekans bandı performans değerleri



Şekil 4.2. Kadınlar için QRS frekans bandı performans değerleri



Şekil 4.3. Tüm bireyler için QRS frekans bandı performans değerleri

Sonraki adımda tüm özellikler (205), özellik seçme algoritmaları ile seçilerek 10 seviyede farklı modeller oluşturulmuştur. Bu işlem hem cinsiyet bazlı olarak ve hem de tüm bireyler için yapılmıştır. (Tablo 4.4.).

Tüm bireylerde seçilmiş özellikler ile önerilen modellerde özellik miktarı belirli bir orana kadar artarken performansın da arttığı, sonrasında ise performansın azalmaya başladığı görülmektedir (Tablo 4.4.). Performansı en iyi model özelliklerin %45'i kullanılarak oluşturulan Karar Ağaçları Topluluğu modelidir ($R=0,91$). Diğer

seviyelerde ki başarı oranlarının da oldukça tatmin edici olduğu görülmektedir ($0,81 < R < 0,91$).

Cinsiyet ayrımı yapılmadan oluşturulan modele ait performans değerlerinin, özellik seçim işlemi yapılan modele yakın olduğu görülmektedir (Tablo 4.1., Tablo 4.4.). Özellikler seçim işlemi öncesi başarı değeri $R=0,92$ iken, seçim sonrası 0,91 olarak elde edilmiştir. Modellerde ki diğer performans parametrelerinde de değerlerin birbirine yakın olduğu görülmektedir. Modeller arası performans değerleri birbirlerine yakın olmalarına rağmen özellik seçimi yapılan modelde özelliklerin %45'i seçilmiştir. Bu durum işlem hacminde ciddi bir azalma sağlamanın yanında, kullanılan özellik seçme algoritmasının da başarılı olduğunu göstermektedir.


Tüm bireyler için yapılan özellik seçim işlemi sonrası gözlenen performans değerlerinin grafiksel gösterimi Şekil 4.4'te verilmiştir.

Tablo 4.4. Tüm bireylere (erkek ve kadın) ait vücut kas yüzdesi hesaplama modelleri performansları

ÖS Seviye	Model						
		MAPE	RMSE	MAD	SH	R	R ²
Seviye 1 %5	KA	7,98	7,21	5,50	7,33	0,62	0,38
	SVR	7,67	7,01	5,31	7,13	0,61	0,37
	KAT	8,94	8,07	6,45	8,21	0,57	0,32
Seviye 2 %10	KA	5,00	4,48	3,53	4,56	0,87	0,75
	SVR	4,86	4,36	3,40	4,44	0,91	0,82
	KAT	5,33	5,03	3,85	5,11	0,90	0,81
Seviye 3 %15	KA	5,00	4,48	3,53	4,56	0,87	0,75
	SVR	-	-	-	-	-	-
	KAT	5,32	4,96	3,86	5,04	0,91	0,82
Seviye 4 %20	KA	5,00	4,48	3,53	4,56	0,87	0,75
	SVR	-	-	-	-	-	-
	KAT	4,33	4,03	3,01	4,10	0,90	0,82

Tablo 4.4. (Devamı)

ÖS Seviye	Model						
		MAPE	RMSE	MAD	SH	R	R ²
Seviye 5 %25	KA	5,00	4,48	3,53	4,56	0,87	0,75
	SVR	-	-	-	-	-	-
	KAT	4,13	3,82	2,92	3,88	0,90	0,82
Seviye 6 %30	KA	5,10	4,52	3,57	4,59	0,87	0,75
	SVR	-	-	-	-	-	-
	KAT	5,31	4,94	3,86	5,02	0,91	0,82
Seviye 7 %35	KA	5,18	4,70	3,66	4,78	0,85	0,72
	SVR	-	-	-	-	-	-
	KAT	5,20	4,87	3,77	4,95	0,91	0,82
Seviye 8 %40	KA	5,27	4,64	3,72	4,71	0,87	0,76
	SVR	-	-	-	-	-	-
	KAT	3,93	3,68	2,72	3,74	0,92	0,85
Seviye 9 %45	KA	5,18	4,70	3,66	7,78	0,85	0,72
	SVR	10,29	8,90	6,99	9,06	-	-
	KAT	4,02	3,98	2,78	4,04	0,91	0,82
Seviye 10 %50	KA	5,18	4,70	3,66	4,78	0,85	0,72
	SVR	-	-	-	-	-	-
	KAT	4,87	4,43	3,36	4,50	0,91	0,84



Şekil 4.4. Tüm bireyler için özellik seçimi işlemi sonrası performans değerleri


Cinsiyet bazlı VKY tahmin modelleri için Spearman özellik seçme algoritması kullanılmıştır (Erkek Tablo 4.5., Kadın Tablo 4.6.). Özellik seçme işlemi cinsiyet bazlı oluşturulan modeller için de 10 seviyede gerçekleştirilmiştir (Seviye 1-10). Erkeklerde özellik seçim işlemi sonrası en iyi model $R=0,82$ başarı oranıyla, Seviye 3'te SVR ile elde edilmiştir (Tablo 4.5.). Özellik seçme işlemi olmadan önce bu değer $R=0,77$ olarak elde edilmişti (Tablo 4.1.). Özellik seçme işlemi sonrası erkekler için oluşturulan modelin başarı oranının arttığı görülmektedir. Oluşturulan modeller sinyal işleme iş yükü bakımından değerlendirildiğinde, özellik seçme algoritması sonrası seviye 3'te %15 özellik ile $R=0,82$ gibi yüksek performans değeri elde edilmiştir. Özellik seçme algoritmasının iş yükünü azaltmasıyla birlikte performansın artmasına katkısı olduğu görülmektedir. Başarı oranları diğer seviyeler için de oldukça tatmin edicidir ($0,70 < R < 0,82$). Tüm özellikler ile oluşturulan modelde en yüksek performans KA'da elde edilirken, özellikler seçim işlemi sonrası SVR'de elde edilmiştir. Burada ki farklılığın sebebi, özellik seçme algoritması yardımıyla ilgili özelliklerin seçilmesi ve yeni veri yapısının oluşturulmasıyla açıklanabilir. Cinsiyet bazlı yapılan özellik seçim işlemi sonrası gözlenen performans değerlerinin grafiksel gösterimi erkekler (Şekil 4.5) ve kadınlar (Şekil 4.6) için verilmiştir.

Tablo 4.5. Erkeklerle ait vücut kas yüzdesi hesaplama modelleri performansları

ÖS Seviye	Model						
		MAPE	RMSE	MAD	SH	R	R ²
Seviye 1 %5	KA	4,94	4,70	3,80	4,86	0,73	0,53
	SVR	4,48	4,34	3,44	4,48	0,77	0,59
	KAT	4,98	4,64	3,83	4,79	0,76	0,58
Seviye 2 %10	KA	5,64	5,25	4,36	5,43	0,62	0,38
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	5,30	4,91	4,03	5,08	0,75	0,56
Seviye 3 %15	KA	4,98	4,87	3,86	5,03	0,69	0,47
	SVR	3,91	4,05	3,01	4,19	0,82	0,67
	KAT	4,66	4,30	3,53	4,45	0,79	0,63

Tablo 4.5. (Devamı)

ÖS Seviye	Model						
		MAPE	RMSE	MAD	SH	R	R ²
Seviye 4 %20	KA	4,98	4,87	3,86	5,03	0,69	0,47
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	4,39	4,13	3,31	4,27	0,82	0,67
Seviye 5 %25	KA	5,42	5,06	4,17	5,22	0,65	0,42
	SVR	7,08	6,70	5,31	6,92	-	-
	KAT	4,48	4,33	3,40	4,47	0,79	0,62
Seviye 6 %30	KA	5,80	5,28	4,48	5,45	0,60	0,36
	SVR	4,91	4,89	3,76	5,05	0,74	0,55
	KAT	4,87	4,43	3,74	4,57	0,76	0,58
Seviye 7 %35	KA	4,98	4,87	3,86	5,03	0,69	0,47
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	5,18	4,74	3,94	4,89	0,78	0,61
Seviye 8 %40	KA	6,19	5,70	4,82	5,88	0,54	0,29
	SVR	7,07	6,70	5,31	6,92	-	-
	KAT	5,01	4,57	3,84	4,72	0,79	0,63
Seviye 9 %45	KA	5,03	4,79	3,89	4,95	0,70	0,49
	SVR	7,08	6,71	5,31	6,93	0,37	0,14
	KAT	4,70	4,57	3,00	4,72	0,78	0,61
Seviye10 %50	KA	6,19	5,70	4,82	5,89	0,54	0,30
	SVR	6,34	6,05	4,78	6,24	0,69	0,47
	KAT	4,68	4,62	3,64	4,77	0,77	0,59



Şekil 4.5. Erkekler için özellik seçimi işlemi sonrası performans değerleri


Kadınlarda özellik seçim işlemi sonrası en iyi model ile $R=0,90$ başarı oranıyla, seviye 2'de SVR'de elde edilmiştir (Tablo 4.6.). Özellik seçme işlemi olmadan önce $R=0,80$ başarı oranı elde edilmişti (Tablo 4.1.). Özellik seçme işlemi sonrası kadınlar için oluşturulan modelin başarı oranının arttığı görülmektedir. Oluşturulan modeller sinyal işleme iş yükü bakımından değerlendirildiğinde, özellik seçme işlemi sonrası seviye 2'de %10 özellik ile $R=0,90$ gibi yüksek performans değeri elde edilmiştir. Daha önce de belirtildiği gibi, özellik seçme algoritması iş yükünü azaltmasının yanında performansın artmasına da katkı sağladığı görülmektedir. Başarı oranları diğer seviyelerde de oldukça tatmin edici seviyelerdedir ($0,75 < R < 0,90$). Tüm özellikler ile oluşturulan modelde en yüksek performans KA'da elde edilirken, özellikler seçim işlemi sonrası SVR ile elde edilmiştir. Burada ki farklılığın sebebi, özellik seçme algoritması yardımıyla ilgili özelliklerin seçilmesi ve yeni veri yapısının oluşturulmasıyla açıklanabilir.

Tablo 4.6. Kadınlara ait vücut kas yüzdesi hesaplamamodelleri performansları

ÖS Seviye	Model	MAPE	RMSE	MAD	SH	R	R ²
Seviye 1 %5	KA	6,09	5,04	3,86	5,22	0,80	0,65
	SVR	6,50	5,85	4,21	6,07	0,68	0,47
	KAT	4,79	3,90	3,02	4,05	0,89	0,79

Tablo 4.6. (Devamı)

ÖS Seviye	Model						
		MAPE	RMSE	MAD	SH	R	R ²
Seviye 2 %10	KA	6,24	5,21	3,96	5,41	0,77	0,60
	SVR	4,54	3,66	2,83	3,80	0,90	0,80
	KAT	4,83	3,99	3,07	4,14	0,87	0,75
Seviye 3 %15	KA	6,24	5,21	3,96	5,41	0,77	0,60
	SVR	5,37	4,26	3,45	4,42	0,74	0,55
	KAT	5,35	4,51	3,39	4,68	0,83	0,70
Seviye 4 %20	KA	6,24	5,21	3,96	5,41	0,77	0,60
	SVR	4,75	4,09	2,96	4,25	0,82	0,68
	KAT	5,44	4,50	3,43	4,67	0,83	0,69
Seviye 5 %25	KA	6,46	5,24	4,09	5,44	0,77	0,59
	SVR	5,28	4,64	3,28	4,82	0,82	0,67
	KAT	5,73	4,68	3,58	4,86	0,82	0,67
Seviye 6 %30	KA	6,46	5,24	4,09	5,44	0,77	0,59
	SVR	9,62	7,95	5,88	8,25	-	-
	KAT	5,72	4,87	3,60	5,06	0,83	0,69
Seviye 7 %35	KA	6,39	5,21	4,04	5,41	0,78	0,61
	SVR	8,65	7,12	5,30	7,38	0,61	0,37
	KAT	6,19	5,25	4,05	5,45	0,84	0,70
Seviye 8 %40	KA	5,94	5,07	3,76	5,26	0,79	0,62
	SVR	6,52	5,57	4,20	5,78	0,65	0,42
	KAT	5,58	4,48	3,52	4,65	0,85	0,72
Seviye 9 %45	KA	6,10	5,22	3,87	5,42	0,77	0,59
	SVR	5,26	4,25	3,31	4,41	0,85	0,72
	KAT	5,83	4,83	3,67	5,01	0,85	0,72
Seviye 10 %50	KA	6,39	5,21	4,05	5,41	0,78	0,61
	SVR	6,58	5,31	4,12	5,51	0,72	0,51
	KAT	5,26	4,35	3,33	4,51	0,84	0,70



Şekil 4.6. Kadınlar için özellik seçimi işlemi sonrası performans değerleri

Çalışma kapsamında önerilen modeller, literatürde ki diğer çalışmalarla Tablo 4.7.'de karşılaştırılmıştır. Literatürdeki modellerin performans değerleri ile referans alınan yöntemler tabloda verilmiştir. E/K modelin tüm bireyler için geliştirildiğini, E modelin sadece erkekler için geliştirildiğini K modelin sadece kadınlar için geliştirildiğini göstermektedir. Önerilen modelin hangi yöntemle yapıldığı “Yöntem” başlığı altında verilmiştir. Örneğin bu tez çalışmasında EKG tabanlı bir yöntem önerilmiştir. Geliştirilen modellerin karşılaştırıldığı referans yöntemler “ReferansYöntem” sütununda verilmiştir. Bu tez çalışmasında BIA yöntemi referans alınarak geliştirme yapılmıştır. Modellerin performansları farklı parametreler ile gösterilebilir. Her çalışmada farklı parametreler sunulması sebebiyle uyumlu bir tablo hazırlamak adına tüm makalelerde verilen ortak performans değerlendirme kriteri olarak R ve R^2 kullanılmıştır. Bu çalışmada önerilen model, diğer çalışmalara kıyasla oldukça yüksek başarı oranına sahiptir. Buna ek olarak literatürdeki çalışmalarda antropometrik ölçümler kullanılmaktadır.

Tablo 4.7. Vücut kas kütlesi tahmininde kullanılan yöntemlerin performans değerleri

Referans	Cinsiyet	Yöntem	R	R ²	Referans Yöntem
[53]	E/K	MRI	0,99	0,98	Kadavra
[53]	E/K	CT	0,99	0,98	Kadavra
[54]	E/K	EIM	0,98	0,96	4 Bileşenli Model
[55]	E/K	Ultrasonografi	0,98	0,95	MRI
[56]	E/K	BIA	0,97	0,94	DXA
[57]	E/K	DXA	0,97	0,94	MRI
[58]	E	Total Vücut Potasyumu	0,97	0,94	CT
[59]	E/K	Antropometrik ölçümler	0,95	0,91	MRI
[60]	E/K	NAA	0,95	0,90	DXA
[61]	E/K	İdrar Kreatinin (24 saatlik)	0,95	0,90	DXA
Önerilen Model 1	E/K	EKG	0,92	0,85	BIA
[62]	E/K	D3 Kreatin Dilüsyonu	0,90	0,81	MRI
Önerilen Model 2	E	EKG	0,82	0,67	BIA
Önerilen Model 3	K	EKG	0,90	0,80	BIA
[63]	E	ADP	0,72	0,52	DXA
[64]	E/K	Serum Kreatinin	0,65	0,42	DXA
[61]	E/K	İdrar Kreatinin (spot)	0,40	0,16	DXA

BÖLÜM 5. TARTIŞMA VE SONUÇ

Cinsiyet bazlı olarak ve tüm bireylerde vücut kas yüzdesinin, biyomedikal sinyal kullanarak yapay zeka tabanlı hesaplanmasına yönelik bir model önerildi. Vücut kas yüzdesinin hesaplanması için literatürde bulunan yöntemler ile önerilen yöntem arasında ki kıyaslama bu bölümde verilecektir.

Kas kütleinde yaşanacak arzu edilmeyen kayıpların sağlık üzerinde olumsuz sonuçlar doğuracağı bilindiğinden dolayı kas kütleinin güvenilir yöntemlerle doğru şekilde ölçülmesi, değerlendirmenin doğru yapılmasını da etkilemektedir. Vücut kas yüzdesinin belirlenmesinde kullanılan yöntemler genel olarak maliyet, nitelikli personel ihtiyacı gibi çeşitli dezavantajlara sahiptir. Mevcut yöntemlerin bu dezavantajlarından dolayı , daha düşük maliyetli, uygulaması kolay ve güvenilir yeni yöntemlere ihtiyaç bulunmaktadır.

Vücut kas kütleinin en doğru ve güvenilir tespiti doğrudan kadavra üzerinden yapılan ölçümlerde görülmektedir. Kadavradan yapılan ölçüme kıyasla, vücut kas yüzdesinin belirlenmesi için MRI ve CT ile yapılan ölçümlerin de performans değerlerinin yüksek olduğu görülmüştür [53] . Güvenilir ve yüksek performans değerleri gösteren bu yöntemler maliyet, nitelikli personel ihtiyacı, geniş alan gereksinimleri ve uygulama süreleri açısından dezavantajlara sahiptir. Ayrıca bu yöntemlerde ki radyasyon maruziyeti sebebiyle kansere yakalanma riski artmaktadır[4], [20], [21], [65]. Yapılan bu çalışmada tüm bireyler için vücut kas yüzdesi tahmini başarı oranı $R=0,92$, $MAPE=4,18$ ve $RMSE=3,82$ elde edilerek yüksek performans gözlenmiştir (Tablo 4.1.). EKG sinyalinin bireylerden non-invaziv olarak alınabilmesi ve EKG işleminin bireylerde herhangi bir olumsuzluğa sebep olmaması bu çalışmanın öne çıkan özelliklerini oluşturmaktadır.

MRI ile kıyaslandıklarında, vücut kas yüzdesinin tahmininde kullanılan DXA ($R=0,97$) ve ultrasonografi ($R=0,976$) yöntemlerinin tüm bireylerin vücut kas yüzdesinin hesaplanmasında daha iyi performans değerleri gösterdikleri görülmektedir [55], [57]. Yalnız DXA ve ultrasonografi yöntemlerinde nitelikli personel ihtiyacı, ölçüm sonuçlarının dehidrasyon ve doku kalınlığı gibi parametrelerden etkilenebilir oluşu gibi bazı dezavantajlar mevcuttur [20], [23]. Ayrıca DXA yönteminde kullanılan cihazın kısıtlarından dolayı bu yöntem tüm bireylerde de uygulanamamaktadır [25]. Önermiş olduğumuz yöntem ise güvenilir, kolay uygulanabilir ve vücut kas yüzdesi tahmin edilecek bireyin fiziksel özelliklerinden etkilenmediği için bu yönleriyle avantaja sahiptir.

Vücut kas yüzdesinin hesaplanmasında kullanılan diğer yöntemlerden NAA($R=0,95$) VE BIA($R=0,97$) yüksek performans değerlerine sahiptir [56], [60]. Bu yöntemler DXA yöntemi ile kıyaslandığında başarılı gözükseler de NAA yönteminde radyasyon maruziyeti , BIA yönteminde de hesaplamaların varsayımlara ve denklemlere dayalı olmasından dolayı ölçüm sonuçların doğruluğunun etkilenmesi gibi bir takım dezavantajlar mevcuttur [21], [26], [28], [31]. İstatik temelli yöntemlerle oluşturulan modellerde, modelin tüm verileri önceden görmesi sebebiyle performans değerinin gerçek değerden daha yüksek çıkması ve dahil edilecek yeni verilere tepkinin ölçülememesi gibi durumlar söz konusudur. Bu durumların önüne geçebilmek amacıyla çalışmamızda makine öğrenmesi algoritması kullanılmıştır. Eğitim ve test için kullanılan verilerle modelin yeni verilere göstermiş olduğu tepki ölçülerek, model performansı test başarı oranı ile uygun şekilde değerlendirilmiştir. Çalışma kapsamında uygulanan süreçler ve önerilmiş olan model güvenilir olmakla birlikte gerçekçidir.

Kullanılan diğer bir yöntem ADP ise DXA yöntemi ile kıyaslandığında, erkek bireylerde ADP yönteminin başarı oranının ($R=0,72$) düşük olduğu görülmektedir [63]. ADP yöntemi maliyetli olması sebebiyle ve kapalı alan korkusu bireylerde kullanılamaması gibi dezavantajlara da sahiptir[3], [4]. Bu çalışmada ise cinsiyet bazlı VKY tahmin modeli performans değerleri erkekler için $R=0,82$, $MAPE=3,91$, $RMSE=4,05$, kadınlar için $R=0,90$, $MAPE=4,54$, $RMSE=3,66$ olarak bulunmuştur

(Erkek Tablo 4.5., Kadın Tablo 4.6.). Düşük maliyetli bir yöntem olan EKG sinyali ile elde edilen bu performans değerleri ise literatüre kıyasla başarılıdır [63].

Vücut kas yüzdesinin hesaplanmasında kullanılan antropometrik ölçümler düşük maliyetli olmalarının yanı sıra, MRI yöntemiyle kıyaslandıklarında başarılarının yüksek olduğu ($R=0,95$) görülmektedir. Fakat antropometrik ölçüm yönteminin güvenilirliği ve sonuçların doğruluğu uygulayıcı kişiye direkt bağlıdır. Bunun yanında antropometrik ölçümde kullanılan denklemler de vücut kas yüzdesi tahmin sonucunu doğrudan etkilemektedir [21], [66]. Çalışmada kullanılan EKG sinyali ise uygulayıcı kişiye bağlı olmamakla birlikte, kolaylıkla tekrar elde edilebilir. Antropometrik ölçüm için oluşturulan modellerde birden fazla antropometrik ölçümün kullanılması, modelin iş gücü ve performansının etkilenmesine sebep olmaktadır. Bu çalışmada kullanılan algoritma ile işlem yükü hem büyük ölçüde azalmış (Tablo 4.1., Tablo 4.4.) hem de performans değerinin artması sağlanmıştır.

Literatürde bulunan D3 kreatin dilüsyonu ($R=0,90$) ve 24 saatlik idrar kreatinin ($R=0,95$) yöntemleriyle vücut kas yüzdesi tahminlerinde de performansların yüksek olduğu görülmektedir. Yalnız bu yöntemlerde örnek toplanması gerekliliğiyle birlikte, yöntemlerin analiz süreçleri karmaşık ve zaman alıcıdır [21], [61], [62]. EKG sinyalinden VKY hesaplanmasına yönelik oluşturulan bu çalışmada performans değerinin $R=0,92$ olarak elde edilmesinin yanında (Tablo 4.1.), EKG sinyalinin bireylerden alınması işleminin süre açısından kısa olması ve kolaylığı gibi ön plana çıkan etkenler de bulunmaktadır. Literatürde bulunan diğer çalışmalardan spot idrar kreatinin ($R=0,40$) ve invaziv işlem gerektiren serum kreatinin ($R=0,65$) yöntemlerinin performans değerlerinin düşük olduğu görülmektedir [61], [64]. Bu çalışmada ise elde edilen başarı oranı ($R=0,95$) literatüre göre hem daha yüksektir, hem de kullanılan yöntem non-invazivdir [64].

Bu çalışmada önerilen modelin performans değeri tüm bireyler için $R=0,92$, erkekler için $R=0,82$ ve kadınlar için ise $R=0,90$ olarak elde edilmiştir. Bu çalışmada elde edilen performans değerlerinin, literatürde kullanılan ve referans kabul edilen yöntemlerle yakın oldukları gözlenmektedir [53], [55]–[57], [66].

Literatürde kullanılan yöntemlerin sahip oldukları çeşitli dezavantajlar sebebiyle, önerilen modelin düşük maliyetli, non-invaziv, kolay, taşınabilir ve hızlı olmasının yanında tüm bireylerde uygulanabilir, güvenilir ve gerçekçi olması ön plana çıkmaktadır. Modelin sahip olduğu bu avantajlar ile performansı göz önüne alındığında VKY tahmininde kullanılabileceği düşünülmektedir.

Kas kütlesi ve gücünün yeterli seviyede olmaması sağlık üzerinde olumsuz etkilere sebep olduğundan dolayı, bu parametrelerin ölçülmesi ve takip edilmesi öneme sahiptir. Vücut kompozisyonunun değerlendirmesinde kullanılan BT ve MRI yöntemleri güvenilir olmalarına rağmen çeşitli dezavantajlara sahip olduklarından dolayı yüksek teknolojili, ucuz ve kullanımı kolay yeni modellere ihtiyaç bulunmaktadır. Literatürdeki çalışmalarda genellikle klasik regresyon yöntemlerine ve antropometrik ölçümlere dayalı modellerin önerildiği görülmektedir.

Yapılan çalışmada, EKG sinyalinin biyomedikal sinyal işleme teknikleriyle çıkarılmış olan 200 adet özelliğe, 5 adet demografik bilgiler de eklenerek, yapay zeka tabanlı vücut kas yüzdesi tahmin modeli geliştirilmiştir. Önerilmiş olan VKY tahmin modeli tüm bireyler için $R=0,92$, erkekler için $R=0,82$ ve kadınlar için $R=0,90$ performans değerlerine sahiptir.

Önerilen model gündelik hayatta pek çok cihazda yazılım olarak kullanılabilir. Örneğin; EKG ölçümü gerçekleştiren cihazlara yapılacak bir modifikasyonla EKG sinyaliyle birlikte VKY 'nin de hesaplanabileceği, önerilen çalışmanın pratikte de kullanılabileceği değerlendirilmektedir. Buna ek olarak hastanlerde rutin kontroller sırasında çekilen EKG'lerin e-Nabız uygulamasına atılması ile farklı bir uygulama gerçekleştirilebilir.

EKG sinyalinin farklı QRS bileşenleri için modeller geliştirilmiştir. Geliştirilen modeller incelendiğinde QRS7 bandının daha fazla bilgi içerdiği söylenebilir. Ayrıca makine öğrenmesi modelleri kıyaslandığında KAT modellerinin performansının bir adım önde olduğu söylenebilir.

Literatürdeki diğer çalışmalara kıyasla önerilen yöntem bir çok yeniliğe sahiptir. (1) Literatürdeki çalışmalarda istatistiksel yöntemlerin kullanıldığı görülmektedir, bu çalışma da ise makine öğrenmesi algoritması kullanılmıştır. (2) Literatürdeki mevcut modellerin antropometrik ölçümlere dayandıkları görülmektedir, bu çalışmada ise biyomedikal sinyal tabanlı bir ölçüm gerçekleştirilmiştir. (3) Literatürdeki çalışmalardan farklı olarak bu çalışmada model performanslarının artırılması için özellik seçme algoritması kullanılmıştır. Bu hususların yanı sıra önerilen yöntemin düşük maliyetli olması, kolay uygulanabilirliği ve performansının yüksek olması sebebiyle EKG tabanlı VKY tahmin modellerinin kullanılabileceği düşünülmektedir.



KAYNAKLAR

- [1] R. Kuriyan, “Body composition techniques”, *Indian J Med Res*, c. 148, sayı 5, ss. 648–658, 2018, doi: 10.4103/ijmr.IJMR_1777_18.
- [2] G. Mazzocchi, “Body composition: Where and when”, *Eur J Radiol*, c. 85, sayı 8, ss. 1456–1460, 2016, doi: 10.1016/j.ejrad.2015.10.020.
- [3] C. E. Orsso vd., “Low muscle mass and strength in pediatrics patients: Why should we care?”, *Clin Nutr*, c. 38, sayı 5, ss. 2002–2015, 2019, doi: 10.1016/j.clnu.2019.04.012.
- [4] M. Borga vd., “Advanced body composition assessment: from body mass index to body composition profiling”, *J Investig Med*, c. 66, sayı 5, ss. 1–9, 2018, doi: 10.1136/jim-2018-000722.
- [5] R. Li vd., “Associations of Muscle Mass and Strength with All-Cause Mortality among US Older Adults”, *Med Sci Sport. Exerc*, c. 50, sayı 3, ss. 458–467, 2018, doi: 10.1249/mss.0000000000001448.
- [6] D. Willoughby, S. Hewlings, ve D. Kalman, “Body Composition Changes in Weight Loss: Strategies and Supplementation for Maintaining Lean Body Mass, a Brief Review”, *Nutrients*, c. 10, sayı 12, 2018, doi: 10.3390/nu10121876.
- [7] K. H. Collins vd., “Obesity, Metabolic Syndrome, and Musculoskeletal Disease: Common Inflammatory Pathways Suggest a Central Role for Loss of Muscle Integrity”, *Front Physiol*, c. 9, s. 112, 2018, doi: 10.3389/fphys.2018.00112.
- [8] Y. Taniguchi vd., “The Association between Osteoporosis and Grip Strength and Skeletal Muscle Mass in Community-Dwelling Older Women”, *Int J Env. Res Public Heal*, c. 16, sayı 7, 2019, doi: 10.3390/ijerph16071228.
- [9] V. E. Baracos, V. C. Mazurak, ve A. S. Bhullar, “Cancer cachexia is defined by an ongoing loss of skeletal muscle mass”, *Ann Palliat Med*, c. 8, sayı 1, ss. 3–12, 2019, doi: 10.21037/apm.2018.12.01.
- [10] W. Looijaard, J. Molinger, ve P. J. M. Weijs, “Measuring and monitoring lean body mass in critical illness”, *Curr Opin Crit Care*, c. 24, sayı 4, ss. 241–247, 2018, doi: 10.1097/mcc.0000000000000511.
- [11] P. JafariNasabian, J. E. Inglis, W. Reilly, O. J. Kelly, ve J. Z. Ilich, “Aging human body: changes in bone, muscle and body fat with consequent changes in nutrient intake”, *J Endocrinol*, c. 234, sayı 1, ss. R37-r51, 2017, doi: 10.1530/joe-16-0603.

- [12] A. Trombetti vd., “Age-associated declines in muscle mass, strength, power, and physical performance: impact on fear of falling and quality of life”, *Osteoporos Int*, c. 27, sayı 2, ss. 463–471, 2016, doi: 10.1007/s00198-015-3236-5.
- [13] D. J. Wilkinson, M. Piasecki, ve P. J. Atherton, “The age-related loss of skeletal muscle mass and function: Measurement and physiology of muscle fibre atrophy and muscle fibre loss in humans”, *Ageing Res Rev*, c. 47, ss. 123–132, 2018, doi: 10.1016/j.arr.2018.07.005.
- [14] A. Granic, A. A. Sayer, ve S. M. Robinson, “Dietary Patterns, Skeletal Muscle Health, and Sarcopenia in Older Adults”, *Nutrients*, c. 11, sayı 4, 2019, doi: 10.3390/nu11040745.
- [15] E. Cava, N. C. Yeat, ve B. Mittendorfer, “Preserving Healthy Muscle during Weight Loss”, *Adv Nutr*, c. 8, sayı 3, ss. 511–519, 2017, doi: 10.3945/an.116.014506.
- [16] B. Mathew, L. Francis, A. Kayalar, ve J. Cone, “Obesity: effects on cardiovascular disease and its diagnosis.”, *J. Am. Board Fam. Med.*, c. 21, sayı 6, ss. 562–8, Kas. 2008, doi: 10.3122/jabfm.2008.06.080080.
- [17] M. A. Fraley, J. A. Birchem, N. Senkottaiyan, ve M. A. Alpert, “Obesity and the electrocardiogram”, *Obesity Reviews*, c. 6, sayı 4. *Obes Rev*, ss. 275–281, Kas. 2005, doi: 10.1111/j.1467-789X.2005.00199.x.
- [18] P. K., L. K., L. M., W. J.K., ve G. J.H., “Obesity and heart rate variability in men with myocardial infarction”, *Cardiol. J.*, c. 15, sayı 1, ss. 43–49, 2008, doi: 10.1016/j.yjmcc.2011.04.006.
- [19] A. Helvacı, F. F. Tipi, ve E. Belen, “Cardiovascular Diseases Related with Obesity”, *Med. J. Okmeydani Train. Res. Hosp.*, c. 30, sayı Supplement 1, ss. 5–14, Ağu. 2014, doi: 10.5222/otd.suppl.2014.005.
- [20] K. Lee vd., “Recent Issues on Body Composition Imaging for Sarcopenia Evaluation”, *Korean J Radiol*, c. 20, sayı 2, ss. 205–217, 2019, doi: 10.3348/kjr.2018.0479.
- [21] M. Tosato vd., “Measurement of muscle mass in sarcopenia: from imaging to biochemical markers”, *Aging Clin Exp Res*, c. 29, sayı 1, ss. 19–27, 2017, doi: 10.1007/s40520-016-0717-0.
- [22] M. J. Müller, W. Braun, M. Pourhassan, C. Geisler, ve A. Bosy-Westphal, “Application of standards and models in body composition analysis”, *Proc Nutr Soc*, c. 75, sayı 2, ss. 181–187, 2016, doi: 10.1017/s0029665115004206.
- [23] G. D. Ceniccola vd., “Current technologies in body composition assessment: advantages and disadvantages”, *Nutrition*, c. 62, ss. 25–31, 2019, doi: 10.1016/j.nut.2018.11.028.

- [24] A. W. Frank-Wilson, J. D. Johnston, W. P. Olszynski, ve S. A. Kontulainen, "Measurement of muscle and fat in postmenopausal women: precision of previously reported pQCT imaging methods", *Bone*, c. 75, ss. 49–54, 2015, doi: <https://doi.org/10.1016/j.bone.2015.01.016>.
- [25] J. A. Shepherd, B. K. Ng, M. J. Sommer, ve S. B. Heymsfield, "Body composition by DXA", *Bone*, c. 104, ss. 101–105, 2017, doi: [10.1016/j.bone.2017.06.010](https://doi.org/10.1016/j.bone.2017.06.010).
- [26] M. Marra vd., "Assessment of Body Composition in Health and Disease Using Bioelectrical Impedance Analysis (BIA) and Dual Energy X-Ray Absorptiometry (DXA): A Critical Overview", *Contrast Media Mol Imaging*, c. 2019, s. 3548284, 2019, doi: [10.1155/2019/3548284](https://doi.org/10.1155/2019/3548284).
- [27] M. C. Gonzalez, T. G. Barbosa-Silva, ve S. B. Heymsfield, "Bioelectrical impedance analysis in the assessment of sarcopenia", *Curr Opin Clin Nutr Metab Care*, c. 21, sayı 5, ss. 366–374, 2018, doi: [10.1097/mco.0000000000000496](https://doi.org/10.1097/mco.0000000000000496).
- [28] C. Beaudart vd., "Equation models developed with bioelectric impedance analysis tools to assess muscle mass: A systematic review", *Clin Nutr ESPEN*, c. 35, ss. 47–62, 2020, doi: [10.1016/j.clnesp.2019.09.012](https://doi.org/10.1016/j.clnesp.2019.09.012).
- [29] O. Deniz vd., "Role of Ultrasonography in Estimating Muscle Mass in Sarcopenic Obesity", *JPEN J Parenter Enter. Nutr*, c. 44, sayı 8, ss. 1398–1406, 2020, doi: [10.1002/jpen.1830](https://doi.org/10.1002/jpen.1830).
- [30] F. Buckinx vd., "Concordance between muscle mass assessed by bioelectrical impedance analysis and by dual energy X-ray absorptiometry: a cross-sectional study", *BMC Musculoskelet Disord*, c. 16, s. 60, 2015, doi: [10.1186/s12891-015-0510-9](https://doi.org/10.1186/s12891-015-0510-9).
- [31] L. C. Ward, "Bioelectrical impedance analysis for body composition assessment: reflections on accuracy, clinical utility, and standardisation", *Eur J Clin Nutr*, c. 73, sayı 2, ss. 194–199, 2019, doi: [10.1038/s41430-018-0335-3](https://doi.org/10.1038/s41430-018-0335-3).
- [32] L. D. Hobson-Webb vd., "Point of Care Quantitative Assessment of Muscle Health in Older Individuals: An Investigation of Quantitative Muscle Ultrasound and Electrical Impedance Myography Techniques", *Geriatr.*, c. 3, sayı 4, 2018, doi: [10.3390/geriatrics3040092](https://doi.org/10.3390/geriatrics3040092).
- [33] P. M. Cawthon vd., "Strong Relation Between Muscle Mass Determined by D3-creatine Dilution, Physical Performance, and Incidence of Falls and Mobility Limitations in a Prospective Cohort of Older Men", *J Gerontol A Biol Sci Med Sci*, c. 74, sayı 6, ss. 844–852, 2019, doi: [10.1093/gerona/gly129](https://doi.org/10.1093/gerona/gly129).
- [34] B. Buehring vd., "Comparison of muscle/lean mass measurement methods: correlation with functional and biochemical testing", *Osteoporos Int*, c. 29, sayı 3, ss. 675–683, 2018, doi: [10.1007/s00198-017-4315-6](https://doi.org/10.1007/s00198-017-4315-6).
- [35] Reha Alpar, Spor, Sağlık ve Eğitim Bilimlerinden Örneklerle Uygulamalı İstatistik ve Geçerlik - Güvenirlik. Detay Yayıncılık, 2016.

- [36] M. K. Uçar, M. R. Bozkurt, C. Bilgin, ve K. Polat, “Automatic detection of respiratory arrests in OSA patients using PPG and machine learning techniques”, *Neural Comput. Appl.*, c. 28, sayı 10, 2017, doi: 10.1007/s00521-016-2617-9.
- [37] M. Akman, M. K. Uçar, Z. Uçar, K. Uçar, B. Baraklı, ve M. R. Bozkurt, “Determination of Body Fat Percentage by Gender Based with Photoplethysmography Signal Using Machine Learning Algorithm”, *IRBM*, Oca. 2021, doi: 10.1016/j.irbm.2020.12.003.
- [38] R. U. Rasool, U. Ashraf, K. Ahmed, H. Wang, W. Rafique, ve Z. Anwar, “Cyberpulse: A Machine Learning Based Link Flooding Attack Mitigation System for Software Defined Networks”, *IEEE Access*, c. 7, ss. 34885–34899, 2019, doi: 10.1109/ACCESS.2019.2904236.
- [39] L. Breiman, “Random forests”, *Mach. Learn.*, c. 45, sayı 1, ss. 5–32, Eki. 2001, doi: 10.1023/A:1010933404324.
- [40] L. Breiman, J. H. Friedman, R. A. Olshen, ve C. J. Stone, “Classification and regression trees”, *Classif. Regres. Trees*, ss. 1–358, Oca. 2017, doi: 10.1201/9781315139470/CLASSIFICATION-REGRESSION-TREES-LEO-BREIMAN-JEROME-FRIEDMAN-RICHARD-OLSHEN-CHARLES-STONE.
- [41] L. Breiman, “Bagging predictors”, *Mach. Learn.*, c. 24, sayı 2, ss. 123–140, 1996, doi: 10.1007/BF00058655.
- [42] W.-Y. Loh ve Y.-S. Shih, “Split selection methods for classification trees”, *Stat. Sin.*, ss. 815–840, 1997.
- [43] W.-Y. Loh, “Regression tress with unbiased variable selection and interaction detection”, *Stat. Sin.*, ss. 361–386, 2002.
- [44] M. K. Uçar, M. Nour, H. Sindi, ve K. Polat, “The Effect of Training and Testing Process on Machine Learning in Biomedical Datasets”, *Math. Probl. Eng.*, c. 2020, ss. 1–17, 2020, doi: 10.1155/2020/2836236.
- [45] R. E. Fan, P. H. Chen, ve C. J. Lin, “Working set selection using second order information for training support vector machines”, *J. Mach. Learn. Res.*, c. 6, 2005.
- [46] W. J. Nash, T. L. Sellers, S. R. Talbot, A. J. Cawthorn, ve W. B. Ford, “The population biology of abalone (*haliotis* species) in tasmania. i. blacklip abalone (*h. rubra*) from the north coast and islands of bass strait”, *Sea Fish. Div. Tech. Rep.*, c. 48, s. p411, 1994.
- [47] D. Clark, Z. Schreter, ve A. Adams, “A quantitative comparison of dystal and backpropagation”, 1996.
- [48] V. Kecman, T.-M. Huang, ve M. Vogt, “Iterative Single Data Algorithm for Training Kernel Machines from Huge Data Sets: Theory and Performance”, 2005.

- [49] S. G. Waugh, “Extending and benchmarking Cascade-Correlation: extensions to the Cascade-Correlation architecture and benchmarking of feed-forward supervised artificial neural networks”. University of Tasmania, 1995.
- [50] J. H. Friedman, “Greedy Function Approximation: A Gradient Boosting Machine”, *Ann. Stat.*, c. 29, sayı 5, ss. 1189–1232, Şub. 2001, [Çevrimiçi]. Available at: <http://www.jstor.org/stable/2699986>.
- [51] M. S. Alajmi ve A. M. Almeshal, “Least Squares Boosting Ensemble and Quantum-Behaved Particle Swarm Optimization for Predicting the Surface Roughness in Face Milling Process of Aluminum Material”, *Appl. Sci.* 2021, Vol. 11, Page 2126, c. 11, sayı 5, s. 2126, Şub. 2021, doi: 10.3390/APP11052126.
- [52] R. Alpar, *Applied Statistic and Validation - Reliability*. Detay Publishing, 2010.
- [53] N. Mitsiopoulos, R. N. Baumgartner, S. B. Heymsfield, W. Lyons, D. Gallagher, ve R. Ross, “Cadaver validation of skeletal muscle measurement by magnetic resonance imaging and computerized tomography”, *J. Appl. Physiol.*, c. 85, sayı 1, ss. 115–122, 1998, doi: 10.1152/jappl.1998.85.1.115.
- [54] A. J. Graybeal, M. L. Moore, M. R. Cruz, ve G. M. Tinsley, “Body Composition Assessment in Male and Female Bodybuilders: A 4-Compartment Model Comparison of Dual-Energy X-Ray Absorptiometry and Impedance-Based Devices”, *J. strength Cond. Res.*, c. 34, sayı 6, ss. 1676–1689, Haz. 2020, doi: 10.1519/JSC.0000000000002831.
- [55] T. Abe vd., “Magnetic resonance imaging-measured skeletal muscle mass to fat-free mass ratio increases with increasing levels of fat-free mass”, *J. Sports Med. Phys. Fitness*, c. 59, sayı 4, ss. 619–623, Nis. 2019, doi: 10.23736/S0022-4707.18.08683-8.
- [56] M. Kim, S. Shinkai, H. Murayama, ve S. Mori, “Comparison of segmental multifrequency bioelectrical impedance analysis with dual-energy X-ray absorptiometry for the assessment of body composition in a community-dwelling older population”, *Geriatr. Gerontol. Int.*, c. 15, sayı 8, ss. 1013–1022, Ağu. 2015, doi: 10.1111/ggi.12384.
- [57] P. U. Freda vd., “Skeletal muscle mass in acromegaly assessed by magnetic resonance imaging and dual-photon X-ray absorptiometry”, *J. Clin. Endocrinol. Metab.*, c. 94, sayı 8, ss. 2880–2886, 2009, doi: 10.1210/jc.2009-0026.
- [58] Z. M. Wang vd., “Skeletal muscle mass: Evaluation of neutron activation and dual-energy X-ray absorptiometry methods”, *J. Appl. Physiol.*, c. 80, sayı 3, ss. 824–831, 1996, doi: 10.1152/jappl.1996.80.3.824.
- [59] H. Valensise, A. Andreoli, S. Lello, F. Magnani, C. Romanini, ve A. De Lorenzo, “Total-body skeletal muscle mass: Development and cross-validation of anthropometric prediction models”, *Am. J. Clin. Nutr.*, c. 72, sayı 3, ss. 796–803, 2000, doi: 10.1093/ajcn/72.3.796.

- [60] R. D. Hansen, C. Raja, A. Aslani, R. C. Smith, ve B. J. Allen, “Determination of skeletal muscle and fat-free mass by nuclear and dual- energy X-ray absorptiometry methods in men and women aged 51-84 y”, *Am. J. Clin. Nutr.*, c. 70, sayı 2, ss. 228–233, 1999, doi: 10.1093/ajcn.70.2.228.
- [61] S. K. Jassal, C. L. Wassel, G. A. Laughlin, E. Barrett-Connor, D. E. Rifkin, ve J. H. Ix, “Urine creatinine-based estimates of fat-free mass in community-dwelling older persons: The Rancho Bernardo study”, *J. Ren. Nutr.*, c. 25, sayı 2, ss. 97–102, Mar. 2015, doi: 10.1053/j.jrn.2014.07.005.
- [62] T. E. Morris-Paterson vd., “Total body skeletal muscle mass estimated by magnetic resonance imaging and creatine (methyl-d3) dilution in athletes”, *Scand. J. Med. Sci. Sport.*, c. 30, sayı 3, ss. 421–428, Mar. 2020, doi: 10.1111/sms.13585.
- [63] R. F. Hartmann Nunes vd., “Assessing body composition in rugby players: Agreement between different methods and association with physical performance”, *J. Sports Med. Phys. Fitness*, c. 60, sayı 5, ss. 733–742, May. 2020, doi: 10.23736/S0022-4707.20.10487-0.
- [64] E. Vinge, B. Lindergård, P. Nilsson-Ehle, ve A. Grubb, “Relationships among serum cystatin C, serum creatinine, lean tissue mass and glomerular filtration rate in healthy adults”, *Scand. J. Clin. Lab. Invest.*, c. 59, sayı 8, ss. 587–592, 1999, doi: 10.1080/00365519950185076.
- [65] T. R. Goodman, A. Mustafa, ve E. Rowe, “Pediatric CT radiation exposure: where we were, and where we are now”, *Pediatr Radiol*, c. 49, sayı 4, ss. 469–478, 2019, doi: 10.1007/s00247-018-4281-y.
- [66] R. C. Lee, Z. Wang, M. Heo, R. Ross, I. Janssen, ve S. B. Heymsfield, “Total-body skeletal muscle mass: development and cross-validation of anthropometric prediction models”, *Am J Clin Nutr*, c. 72, sayı 3, ss. 796–803, 2000, doi: 10.1093/ajcn/72.3.796.

ÖZGEÇMİŞ

Adı Soyadı : Samet Oğuz Akseki

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü /Elektrik Elektronik Mühendisliği	Devam ediyor
Lisans	Sakarya Üniversitesi / Mühendislik Fakültesi/ Elektrik-Elektronik Mühendisliği	2015
Lise	Çorlu Mimar Sinan Lisesi	2010

İŞ DENEYİMİ

Yıl	Yer	Görev
2017-2021	THY Teknik A.Ş	Aviyonik Sistem Mühendisi

YABANCI DİL

İngilizce

ESERLER (makale, bildiri, proje vb.)

- Artificial Intelligence-Based Estimation of Body Muscle Percentage
(International Conference on Engineering Technologies (ICENTE'21), 18-20
November 2021)

HOBİLER

Süs bitkisi yetiştiriciliği