



Elektrokardiyografi Sinyali ile Bazal Metabolizma Hızının Cinsiyet Bazlı Yapay Zekâ Tabanlı Tespiti

Ahmet Enes Yıldırım^{1,a}, Ömer Faruk Kadioğlu^{1,b}, Hamza Kavak^{1,c}, Kadir Salman^{1,d}, Muhammed Kürşat Uçar^{1,e*}, Zeliha Uçar², Mehmet Recep Bozkurt^{1,f}

¹Sakarya Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Sakarya, Türkiye

^ayildirim_1132@hotmail.com, ^bomerfaruk_kadioglu@hotmail.com, ^chamza.kavak@ogr.sakarya.edu.tr, ^dkadir.salman@ogr.sakarya.edu.tr, ^emucar@sakarya.edu.tr, ^fmbozkurt@sakarya.edu.tr

²İstanbul Okan Üniversitesi, Sağlık Bilimleri Enstitüsü, Beslenme ve Diyetetik Bölümü, İstanbul, Türkiye

zelihauguvenc@hotmail.com

Öz

Bazal Metabolizma Hızı (BMH) günlük harcanan ve alınması gereken enerji hakkında bilinmesi gereken en önemli unsurlardan biridir. Literatürde genellikle kalorimetreler ve birtakım denklemler tarafından tespit edilmektedir. Bu çalışmada BMH tahmini için elektrokardiyografi (ECG) sinyalleri ile yapay zekâ tabanlı bir model oluşturulmuştur. Öncelikle bireylerden toplanan ECG sinyalleri gürültülerden temizlenip filtrelenmiştir. Daha sonra özellik çıkartılıp özellik seçme algoritmaları yardımıyla azaltılmıştır. Elde kalan özelliklerle yapay zekâ algoritmaları sayesinde BMH tahmininde bulunulmuştur. Erkekler için $R = 0.91$, kadınlar için $R = 0.99$ değerlerine sahip modeller oluşturulmuştur. Performans değerlendirme kriterleri de göz önüne alınarak en iyi model kadınlar için de erkekler için de Linear Regression modeli seçilmiştir. Tüm bu sonuçlara bakıldığında günlük hayatta BMH tahmini için önerilen modelin kullanılabilirliği belirlenmiştir.

Anahtar kelimeler: Yapay Zekâ, Bazal Metabolizma Hızı, Elektrokardiyografi Sinyali

Gender-Based Artificial Intelligence Based Detection of Basal Metabolic Rate by Electrocardiography Signal

Abstract

Basal Metabolic Rate (BMR) is one of the most important factors that should be known about the energy consumed and taken daily. It is usually determined by calorimeters and some equations in the literature. In this study, an artificial intelligence-based model was created with electrocardiography (ECG) signals for BMR prediction. First of all, ECG signals collected from individuals are cleaned from noise and filtered. Later, the feature was removed and reduced with the help of feature selection algorithms. BMR predictions have been made with the remaining features thanks to artificial intelligence algorithms. Models with $R = 0.91$ for men and $R = 0.99$ for women were created. Considering the performance evaluation criteria, the Linear Regression model was chosen as the best model for both women and men. Considering all these results, it was determined that the proposed model could be used for BMR estimation in daily life.

Keywords: Artificial Intelligence, Basal Metabolic Rate, Electrocardiography Signal

* Sorumlu yazar.
E-posta adresi: mucar@sakarya.edu.tr

Alındı : 03 Nisan 2021
Kabul : 21 Ağustos 2021

1. Giriş (Introduction)

Bazal Metabolizma Hızı (BMH) genellikle yaşamı sürdürmek için gerekli temel süreçlerle uyumlu minimum metabolizma hızı olarak kabul edilir (Speakman, Król, and Johnson 2004). Günlük harcanan ve alınması gereken enerji hakkında bilinmesi gereken en önemli parametrelerden biridir. Ancak günlük hayatta ölçümünü yapmak oldukça zahmetli ve maliyetli bir iştir. Literatürde kullanılan en yaygın BMH ölçüm yöntemi dolaylı kalorimetredir. Dolaylı kalorimetre, oksijen tüketimi ve karbondioksit üretimi ölçümlerinden bazal metabolizma hızını tespit eder (Ferrannini 1988).

Bir diğer BMH tespiti için kullanılan yöntem de BMH denklemleridir (Müller et al. 2001). Bu denklemlerin BMH tespitinde kullanılması oldukça pratiktir. Ancak yapılan araştırmalar gösteriyor ki denklemlerin sonucunda elde edilen değerler, gerçek BMH değerlerinden oldukça farklıdır (Flanckbaum et al. 1999). Tüm bu durumlar göz önüne alındığında BMH tespiti için yeni yöntemlere ihtiyaç duyulduğu gözlemlenmiştir.

Bu çalışmanın amacı maliyetli ve ölçümü zor olan yöntemler yerine yapay zekâ tabanlı güvenilir yeni bir yöntem geliştirmektir. Bu çalışmada, literatürdeki yöntemlerin aksine kalorimetreler yerine elektrokardiyografi (ECG) sinyalleri kullanarak BMH tahmini yapılmıştır. ECG sinyali kalbin elektriksel faaliyeti sonucu oluşan ve deriden elektrotla ölçülebilen biyopotansiyel sinyallerdir (Nur Göz et al. 2017). Bu çalışmada 324 farklı kişiden ECG sinyalleri alınarak 3 farklı filtreleme sonucunda gürültüleri en aza indirilmiş bir sinyal elde edilmiştir. Bu sinyalden çıkarılan 23 özelliğe demografik bilgiler de eklenerek toplamda 27 özellik elde edilmiştir. Spearman özellik seçme algoritması yardımıyla makine öğrenmesinde kullanılacak özellikler belirlenmiştir. Makine öğrenmesi algoritmaları kullanılarak seçilen özellikler yardımıyla BMH tahmini yapılmıştır ve performans değerlendirme kriterleri göz önüne alınarak en iyi sonuç veren model belirlenmiştir. Bütün süreç kadın ve erkek için ayrı ayrı tekrar edilmiştir ve cinsiyet bazlı modeller geliştirilmiştir.

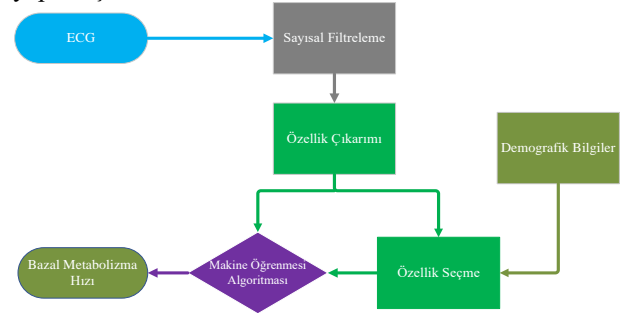
Bu çalışma literatürle kıyaslandığında birçok yenilik içermektedir. (1) Literatürde BMH hesaplamaları için denklemler kullanılırken, bu çalışmada yapay zekâ tabanlı algoritmalar kullanılmıştır. (2) Ölçümlerde zahmetli ve maliyetli kalorimetreler kullanılırken bu çalışmada ECG sinyalleri kullanılmıştır. (3) Özellik seçme algoritmaları kullanılarak modelin doğruluk oranları artırılmıştır ve güvenilirliği yüksek bir tahmin modeli oluşturulmuştur. Tüm bu çalışmalar göz önüne alındığında literatüre yenilik katmaktadır.

Çalışmada kadın/erkek/kadın-erkek olmak üzere 3 farklı model geliştirilmiştir. Erkekler için geliştirilen model $R = 0.91$, kadınlar için $R = 0.99$, kadın-erkek için $R = 0.87$ değerlerine sahiptir. Sonuçlar göz önüne alındığında cinsiyet bazlı oluşturulan modellerin

doğruluk oranlarının daha yüksek olduğu gözlemlenmiştir.

2. Materyal ve Yöntem (Material and Method)

Araştırmada izlenen yol şu şekilde açıklanabilir (Şekil 1). İlk olarak bireylerden alınan ECG sinyalleri filtrelenmiştir ve bu filtrelenmiş sinyallerden özellik çıkarımı yapılmıştır. Daha sonra bu özelliklere demografik bilgiler eklenmiştir. Bir sonraki adımda özellik seçme algoritması kullanılarak özellik sayısı azaltılmıştır. Son olarak bu özelliklerden makine öğrenmesi algoritmaları sayesinde BMH tahmini yapılmıştır.



Şekil 1. Çalışma akış diyagramı (work flow diagram)

2.1. Verilerin toplanması (Data collection)

Bu çalışmada kullanılan veriler Sakarya Üniversitesi Sağlık Beslenme ve Danışmanlık Birimi'ne beslenme ve danışmanlık hizmeti için Eylül 2019 – Şubat 2020 tarihleri arasında başvuru yapan gönüllülerden alınmıştır. Çalışmanın yapılabilmesi için gerekli etik kurul onay ve veri kullanım izni alınmıştır.


Çalışmada 324 bireyden alınan ECG sinyali ve BMH verileri toplanmıştır. Bu veriler ve sinyaller kullanarak BMH'nın yüksek doğruluk oranında tahmin edilmesi amaçlanmaktadır.

Cinsiyete göre demografik bilgiler ve BMH dağılımları farklılık gösterdiği için BMH'nın cinsiyet bazlı hesaplanması gerektiği anlaşılmıştır. Bu sebeple, BMH'nın hesaplanması hem kadın ve erkek için ayrı ayrı, hem de tüm veriler kullanılarak yapılmıştır.

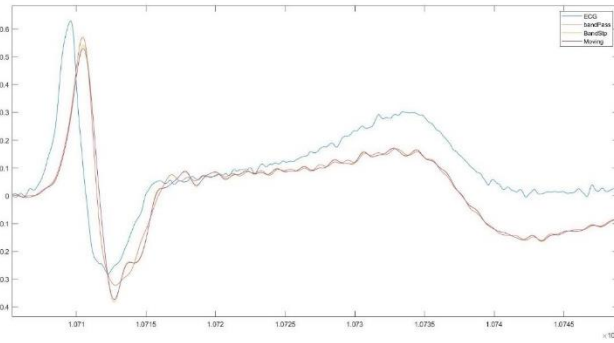
2.2. Sinyal ön işleme (Signal preprocessing)

ECG sinyali üzerinde oluşan gürültülerin temizlenmesi amacıyla sayısal filtre tasarlanmış ve uygulanmıştır. Gürültü temizleme işlemi için 3 farklı filtre çeşidi kullanılmıştır. İlk önce IIR Chebyshev Type 2 Band Geçiren Filtre (0.25-100 Hz) kullanılmıştır (Şekil 2). Ardından IIR Chebyshev Type 2 Band Durduran Filtre (49-51 Hz) kullanılmıştır (Şekil 2). En son olarak ise gürültülerin en aza indirilmesi için Moving Filtresi uygulanarak gürültüler en aza indirilmiştir (Şekil 3).

Toplam 324 adet ECG verisini filtreleyerek bir sonraki adımda kullanmak için hazırlanmıştır.



Şekil 2. Moving filtresi henüz uygulanmamış sinyal (Moving filter not yet applied signal)



Şekil 3. Moving filtresi uygulanmış sinyal (Moving filter applied signal)

2.3. Özellik çıkarımı (Feature extraction)

Filtreleme işleminden sonra en iyi filtrelenmiş sinyaller dosyasını seçilmiştir. Seçilen dosyada her bir sinyal bir kişiye ait olan 324 sinyalin özelliklerini formüllerine göre hesaplayarak sinyallerin özellikleri çıkarılmıştır. Bu özelliklere ek olarak yapay zekanın bazal metabolizma hızını daha sağlıklı hesaplayabilmesi için bu özelliklere ek olarak kişilerin yaşı, boyu, kilosu gibi özellikleri de ekleyerek toplamda 23'ü formül hesaplamasıyla bulunan (Çizelge 1) sinyal özellikleri 4 tanesi kişisel özellik olmak üzere toplamda 27 özellik çıkarılarak özellik çıkarma işlemi sonlandırılmıştır.

2.4. Spearman özellik seçme algoritması (Spearman feature selection algorithm)

Orijinal veri setini temsil edebilecek en iyi altkümenin seçimi olarak tanımlanmaktadır. Özellik seçimi (diğer adıyla nitelik seçimi veya değişken seçimi), kullanılan algoritmaya göre özellikleri değerlendirerek veri setindeki n adet özellik arasından en iyi k adet özelliği seçme işlemidir (Forman 2003). Özellik seçimi, ilgilenilen problem için en faydalı ve en önemli özellikleri seçerek veri kümesindeki özellik sayısının azaltılmasını amaçlamaktadır. Bu çalışmada

Spearman korelasyon katsayısı tabanlı özellik seçme algoritması kullanılmıştır.

Tablo 1. Sinyallerden çıkarılmış özellikler ve formülleri (Properties and formulas extracted from signals)

No	Özellik	Formül
1	Basıklık	$\frac{\sum_{i=1}^n (x(i) - \bar{x})^4}{(n-1)S^4}$
2	Çarpıklık	$\frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)S^3}$
3	IQR	$IQR = iqr(x)$
4	DK	$DK = (S/\bar{x})100$
5	Geometrik Ortalama	$G = \sqrt[n]{x_1 \cdot \dots \cdot x_n}$
6	Harmonik Ortalama	$H = n / (\frac{1}{x_1} + \dots + \frac{1}{x_n})$
7	Activity- Hjort Parameters	$A = S^2$
8	Maksimum	$x_{max} = \max(x_i)$
10	Ortalama Mutlak Sapma	$MAD = mad(x)$
11	Minimum	$x_{min} = \min(x_i)$
12	Merkez Anlar	$CM = moment(x, 10)$
13	Ortalama	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
14	Ortalama Eğri Uzunluğu	$CL = \frac{1}{n} \sum_{i=2}^n x_i - x_{i-1} $
15	Ortalama Enerji	$E = \frac{1}{n} \sum_{i=1}^n x_i^2$
16	RMS-(Karekök Ortalama)	$X_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i ^2}$
17	Standart Hata	$S\bar{x} = S/\sqrt{n}$
18	Standart Sapma	$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
19	Şekil Faktörü	$SF = X_{rms} / (\frac{1}{n} \sum_{i=1}^n \sqrt{ x_i })$
20	Tekil Değer Ayrışımı	$SVD = svd(x)$
21	%25 Kesilmiş Ortalama	$T25 = trimmean(x, 25)$
22	%50 Kesilmiş Ortalama	$T50 = trimmean(x, 50)$
23	Ortalama Teager Enerjisi	$TE = \frac{1}{n} \sum_{i=3}^n (x_{i-1}^2 - x_i x_{i-2})$

İki sayısal ölçüm arasında doğrusal bir ilişki olup olmadığını, varsa bu ilişkinin yönünü ve şiddetinin ne olduğunu belirlemek için kullanılan bir istatistiksel yöntemdir. Bu sebeple çalışmamızda veri dağılımları normal dağılımdan uzak olduğundan Spearman

Korelasyonu kullanılmaktadır. Yönteme ait denklemler şu şekilde özetlenebilir:

Çift Yönlü Test

$H_0: \rho_s=0$

$H_1: \rho_s \neq 0$

Test İstatistiği

$$r_s = 1 - \frac{6 \sum di^2}{n(n^2-1)} \quad (1)$$

$di=ui-vi$

ui : 1. Örneklemden i . ölçümün sıra numarası

vi : 2. Örneklemden i . ölçümün sıra numarası

Ret Bölgesi

$rs > rs, a/2$ veya $rs < -rs, a/2$ ise H_0 reddedilir.

Denklemden elde edilen r_s ilişki düzeni gösterir ve özellik seçiminde temel parametre olarak kullanılır. Her özellik için r_s değeri hesaplandıktan sonra en iyi %20 özellik seçilerek sistem tekrar modellenmiştir.

2.5. Makine öğrenmesi (Machine learning)

Makine öğrenmesi algoritmaları, kullandığı tekniklere göre denetimli ve denetimsiz öğrenme olmak üzere iki gruba ayrılırlar. Denetimsiz öğrenme, sadece giriş verilerinin olduğu bir öğrenme yöntemidir. Genellikle etiketsiz veriler üzerinde çalışılırken tercih edilen bir uygulamadır. Denetimli öğrenme ise giriş ve çıkış verilerinin ikisini de barındırmaktadır ve etiketlenmiş veriler kullanılarak öğrenme sağlanmaktadır. Giriş ve çıkış verileri bilindiği için öğrenme süreci denetlemeye tabi tutulur. Bu yüzden denetimli öğrenme olarak adlandırılmaktadır. Denetimli öğrenme, sınıflandırma ve regresyon olarak gruplandırılabilir. Regresyon, bir bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi belirlemeye çalışan, nicel değişkenleri tahmin etmek için kullanılan bir denetimli öğrenmedir. Sınıflandırma ise tahmin edilen veriyi kategorilere atama ile ilgili bir denetimli öğrenmedir (Akay 2018).

Bu çalışmada kullanılan regresyon modelleri Lineer Regresyon, Gauss Süreç Regresyon, Destek Vektör Makineleri, Karar Ağaçları, Ensemble'dir. Bu sonuçlar çeşitli performans değerlendirme kriterleri göz önüne alınarak karşılaştırılmıştır. Karşılaştırma sonucunda en iyi sonucu veren model belirlenmiştir.

Verilerin %80'i eğitim, %20'si test sürecinde kullanılmıştır.

2.6. Performans değerlendirme kriterleri (Performance evaluation criteria)

Çalışmada kullanılan performans değerlendirme kriteri olarak R^2 , MSE, RMSE ve MAE kullanılmıştır. Bu performans kriterlerinden R^2 , modelin açıklayıcılık katsayısıdır. Bu katsayı, modelin tahmin ilişkisiyle doğru orantılıdır.

MSE, RMSE ve MAE birer hata ölçüleri olmaları sebebiyle modelin performansı ters orantılıdır. Yani düşük değerler, yüksek performansı göstermektedir (Wang and Xu 2004).

2.6.1. Ortalama karesel hata (Mean squared error – MSE)

MSE, modelin hatalarının karelerinin ortalamasını ifade eder. Tahmin edilen değerler gerçek değerlere ne kadar yaklaşırsa MSE değeri de o kadar küçülür.

e_i , gerçek değer (y_i) ile tahmin edilen değer (\hat{y}_i) arasındaki farktır.

$$e_i = y_i - \hat{y}_i \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3)$$

2.6.2. Ortalama karesel hata karekökü (Root Mean Squared Error – RMSE)

RMSE, tahmin hatalarının ne kadar yayıldığı ölçüsüdür. MSE değerinin kareköküdür.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (4)$$

2.6.3. Ortalama mutlak hata (Mean absolute error – MAE)

MAE, veri kümesi içindeki her bir örnek için gerçek değer ile tahmin edilen değer arasındaki farkın mutlak değerinin ortalamasıdır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (5)$$

2.6.4. Açıklayıcılık katsayısı (Coefficient of determination)

R^2 , bağımlı değişkendeki değişimin ne kadarının bağımsız değişken tarafından açıklanabildiğini gösteren bir katsayıdır. 1'e yakın olması beklenir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

3. Sonuçlar (Conclusions)

Bu çalışmada amaç ECG sinyali ile yapay zekayı kullanarak bireylere ait BMH değerini yüksek doğruluk oranında tahmin etmektir. Çalışmada izlenen yol şu şekildedir: İlk olarak bireylerden toplanan ECG sinyalleri filtrelenmiştir. Bu filtrelenmiş sinyallerden 23 adet özellik çıkarılmıştır ve demografik bilgiler eklenmiştir. Daha sonra kullanılacak özellikler özellik seçme algoritmaları yardımıyla belirlenmiştir.

Belirlenen özellikler kullanılarak BMH tahmini için makine öğrenmesi algoritmaları kullanılmıştır. Son olarak modellerin karşılaştırılması için performans değerlendirme kriterleri kullanılmıştır.

Çalışmada, filtrelenmiş ECG sinyalinden özellikler çıkarılarak BMH tahmin edilmiştir. Bu tahminler ayrıca cinsiyet bazlı da yapılmıştır. Tahmin sonuçlarına bakıldığında, cinsiyet bazlı yapılmış tahminlerin daha iyi sonuç verdiği belirlenmiştir. Bütün veriler kullanıldığında (kadın-erkek) $R = 0.86$ bulunmuştur (Çizelge 4). Cinsiyet bazlı yapılan tahmin sonucunda erkek için $R = 0.85$ (Çizelge 2), kadınlarda ise $R = 0.98$ bulunmuştur (Çizelge 3). Buradaki sonuçlar göz önüne alındığında BMH tahminin cinsiyet bazlı tahminlerde daha iyi sonuçlar verdiği belirlenmiştir.

Sinyalden elde edilen bütün özellikler Spearman Özellik Seçme Algoritması kullanılarak azaltılmış ve BMH tahmin modeli hem cinsiyet bazlı hem de bütün veriler kullanılarak yeniden oluşturulmuştur. Cinsiyet gözetmeden yapılan tahmin modelinde $R = 0.87$ başarı oranı elde edilirken (Çizelge 7), cinsiyet bazlı tahmin modelinde erkekler için $R = 0.91$ (Çizelge 5), kadınlar için $R = 0.99$ bulunmuştur (Çizelge 6). Özellik seçimi öncesi bulunan R değerleri ile özellik seçimi sonrası elde edilen R değerleri karşılaştırıldığında, özellik seçme algoritmalarının elde edilen başarı oranını arttırdığı belirlenmiştir.

Tablo 2. Erkekler için tüm özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using all features for men)

Tüm Özellikler (Erkek)	RMSE	R ²	MSE	MAE	R
Linear Regression (Interactions Linear)	-	-	-	-	-
Linear Regression (Linear)	82,88	0,73	6869	27,844	0,854
Linear Regression (Robust Linear)	86,163	0,71	7424	21,133	0,842
SVM (Linear SVM)	86,099	0,71	7413,1	29,29	0,842
Gaussian Process Regression (Squared Exponential GPR)	87,775	0,69	7704,4	32,039	0,83
Gaussian Process Regression (Matern 5/2 GPR)	88,196	0,69	7778,5	32,41	0,83
Gaussian Process Regression (Rational Quadratic GPR)	87,775	0,69	7704,4	32,039	0,83
Stepwise Linear Regression	90,349	0,68	8162,9	36,431	0,824
Gaussian Process Regression (Exponential GPR)	89,297	0,68	7973,9	37,292	0,824
SVM (Quadratic SVM)	93,936	0,65	8824	40,095	0,806
SVM (Medium Gaussian SVM)	96,34	0,63	9281,4	52,088	0,793
SVM (Cubic SVM)	100,06	0,6	10011	43,383	0,774
SVM (Coarse Gaussian SVM)	109,41	0,52	11971	64,112	0,721
Ensemble (Boosted Trees)	111,81	0,5	12502	79,813	0,707
Tree (Medium Tree)	113,18	0,49	12810	48,804	0,7
Tree (Coarse Tree)	118,43	0,44	14025	59,449	0,663
Tree (Fine Tree)	120,51	0,42	14523	53,442	0,648
Ensemble (Bagged Trees)	139,85	0,22	19558	113,52	0,469
SVM (Fine Gaussian SVM)	151,17	0,09	22851	115,89	0,3

Tablo 3. Kadınlar için tüm özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using all features for women)

Tüm Özellikler (Kadın)	RMSE	R ²	MSE	MAE	R
Linear Regression (Interactions Linear)	-	-	-	-	-
Gaussian Process Regression (Squared Exponential GPR)	25,977	0,98	674,8	21,297	0,989
Gaussian Process Regression (Rational Quadratic GPR)	25,977	0,98	674,8	21,297	0,989
SVM (Linear SVM)	29,69	0,97	881,52	21,266	0,984
Gaussian Process Regression (Matern 5/2 GPR)	26,949	0,97	726,27	22,216	0,984
Linear Regression (Robust Linear)	34,975	0,96	1223,3	23,162	0,979
Linear Regression (Linear)	39,74	0,95	1579,3	31,505	0,974
Stepwise Linear Regression	37,43	0,95	1401	29,285	0,974
SVM (Quadratic SVM)	45,931	0,93	2109,6	35,588	0,964
Gaussian Process Regression (Exponential GPR)	53,074	0,9	2816,8	38,396	0,948
SVM (Medium Gaussian SVM)	83,709	0,76	7007,2	55,0731	0,871
Ensemble (Boosted Trees)	87,375	0,74	7634,5	69,402	0,86
Tree (Fine Tree)	96,378	0,68	9288,8	61,679	0,824
SVM (Coarse Gaussian SVM)	97,32	0,67	9471,2	75,636	0,818
SVM (Cubic SVM)	107,66	0,6	11590	67,981	0,774
Ensemble (Bagged Trees)	119,73	0,5	14336,7	82,219	0,707
Tree (Medium Tree)	133,39	0,38	17794	86,503	0,616
Tree (Coarse Tree)	133,18	0,38	17736	94,504	0,616
SVM (Fine Gaussian SVM)	155,64	0,16	24224	113,71	0,4

Tablo 4. Kadın – erkek için tüm özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using all features for men and women)

Tüm Özellikler (Kadın-Erkek)	RMSE	R ²	MSE	MAE	R
Linear Regression (Interactions Linear)	-	-	-	-	-
Linear Regression (Linear)	84,934	0,74	7213,8	63,327	0,86
Gaussian Process Regression (Squared Exponential GPR)	84,774	0,74	7186,6	61,157	0,86
Gaussian Process Regression (Matern 5/2 GPR)	84,585	0,74	7154,7	61,359	0,86
Gaussian Process Regression (Exponential GPR)	85,275	0,74	7271,9	62,132	0,86
Gaussian Process Regression (Rational Quadratic GPR)	84,774	0,74	7186,6	61,157	0,86
Linear Regression (Robust Linear)	87,334	0,72	7627,2	65,576	0,848
Stepwise Linear Regression	87,312	0,72	7623,4	67,402	0,848
SVM (Linear SVM)	89,967	0,71	8094	64,769	0,842
SVM (Quadratic SVM)	89,779	0,71	8060,3	67,073	0,842
Tree (Fine Tree)	94,131	0,68	8860,7	68,348	0,824
SVM (Medium Gaussian SVM)	100,17	0,64	10034	76,594	0,8
Tree (Medium Tree)	101,17	0,63	10234	74,288	0,793
SVM (Coarse Gaussian SVM)	106,13	0,59	11264	75,166	0,768
Ensemble (Bagged Trees)	108,23	0,58	11713	79,183	0,761
Tree (Coarse Tree)	115,19	0,52	13269	82,01	0,721
SVM (Cubic SVM)	118,92	0,49	14141	89,597	0,7
Ensemble (Boosted Trees)	120,28	0,48	14468	92,828	0,692
SVM (Fine Gaussian SVM)	158,77	0,09	25207	119,8	0,3

Tablo 5. Erkekler için seçilmiş özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using selected features for men)

Özellik Seçimi Sonrası (Erkek)	RMSE	R ²	MSE	MAE	R
SVM (Cubic SVM)	-	-	-	-	-
Linear Regression (Robust Linear)	41,755	0,84	1743,5	19,106	0,916
SVM (Linear SVM)	41,426	0,84	1716,1	18,553	0,916
SVM (Quadratic SVM)	42,868	0,83	1837,7	21,616	0,911
SVM (Coarse Gaussian SVM)	47,944	0,79	2298,7	26,141	0,888
Gaussian Process Regression (Exponential GPR)	47,718	0,79	2277	27,251	0,888
SVM (Medium Gaussian SVM)	49,063	0,78	2407,1	28,219	0,883
Gaussian Process Regression (Rational Quadratic GPR)	49,964	0,77	2496,4	28,405	0,877
Tree (Medium Tree)	51,241	0,76	2625,7	33,965	0,871
Gaussian Process Regression (Matern 5/2 GPR)	51,174	0,76	2618,8	30,306	0,871
Linear Regression (Linear)	52,191	0,75	2723,9	33,058	0,866
Linear Regression (Interactions Linear)	52,516	0,74	2758	32,105	0,86
Stepwise Linear Regression	52,517	0,74	2758	32,969	0,86
Gaussian Process Regression (Squared Exponential GPR)	53,927	0,73	2908,1	32,678	0,854
Tree (Fine Tree)	69,971	0,55	4854	44,723	0,741
Ensemble (Bagged Trees)	70,754	0,53	5006,1	47,88	0,728
Tree (Coarse Tree)	86,786	0,3	7531,7	69,151	0,547
SVM (Fine Gaussian SVM)	86,482	0,3	7479,2	59,048	0,547
Ensemble (Boosted Trees)	103,22	0,01	10655	86,678	0,1

Tablo 6. Kadınlar için seçilmiş özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using selected features for women)

Özellik Seçimi Sonrası (Kadın)	RMSE	R ²	MSE	MAE	R
Linear Regression (Interactions Linear)	-	-	-	-	-
Linear Regression (Robust Linear)	19,025	0,99	361,97	12,796	0,994
SVM (Linear SVM)	17,309	0,99	299,6	11,796	0,994
Linear Regression (Linear)	26,185	0,98	685,66	22,097	0,989
Gaussian Process Regression (Squared Exponential GPR)	33,432	0,96	1117,7	26,242	0,979
Gaussian Process Regression (Matern 5/2 GPR)	33,448	0,96	1118,7	26,077	0,979
Gaussian Process Regression (Rational Quadratic GPR)	33,432	0,96	1117,7	26,242	0,979
SVM (Quadratic SVM)	38,096	0,95	1451,3	28,163	0,974
Stepwise Linear Regression	42,587	0,94	1813,6	29,613	0,969
Gaussian Process Regression (Exponential GPR)	47,351	0,93	2242,1	33,013	0,964
SVM (Medium Gaussian SVM)	71,894	0,83	5168,7	53,372	0,911
SVM (Cubic SVM)	94,385	0,71	8908,6	58,26	0,842
Tree (Coarse Tree)	97,264	0,7	9460,3	72,294	0,836
Ensemble (Boosted Trees)	99,623	0,68	9924,8	79,491	0,824
Tree (Medium Tree)	112,68	0,59	12697	81,429	0,768
SVM (Coarse Gaussian SVM)	112,52	0,59	12662	89,811	0,768
Tree (Fine Tree)	113,55	0,58	12893	76,206	0,761
Ensemble (Bagged Trees)	118,06	0,55	13939	85,497	0,741
SVM (Fine Gaussian SVM)	161,8	0,16	26180	124,83	0,4

Tablo 7. Kadın- erkek için seçilmiş özellikler kullanılarak yapılmış tahmin sonuçları (Estimation results using selected features for men and women)

Özellik Seçimi Sonrası (Kadın-Erkek)	RMSE	R ²	MSE	MAE	R
Linear Regression (Interactions Linear)	-	-	-	-	-
Linear Regression (Linear)	86,275	0,77	7443,4	63,878	0,877
Linear Regression (Robust Linear)	85,866	0,77	7373	63,638	0,877
SVM (Linear SVM)	85,128	0,77	7246,7	63,016	0,877
Gaussian Process Regression (Squared Exponential GPR)	87,952	0,76	7735,6	65,767	0,871
Gaussian Process Regression (Matern 5/2 GPR)	87,647	0,76	7682,1	65,916	0,871
Gaussian Process Regression (Rational Quadratic GPR)	87,953	0,76	7735,6	65,767	0,871
Stepwise Linear Regression	88,807	0,75	7886,7	67,225	0,866
Gaussian Process Regression (Exponential GPR)	91,971	0,73	8458,7	65,723	0,854
SVM (Coarse Gaussian SVM)	94,226	0,72	8878,6	68,319	0,848
SVM (Quadratic SVM)	99,105	0,69	9821,8	71,61	0,83
Ensemble (Bagged Trees)	107,56	0,64	11570	79,021	0,8
Tree (Fine Tree)	108,3	0,63	11729	80,284	0,793
Tree (Medium Tree)	107,74	0,63	11607	76,41	0,793
SVM (Medium Gaussian SVM)	112,71	0,6	12704	74,559	0,774
Ensemble (Boosted Trees)	115,53	0,58	13347	87,643	0,761
Tree (Coarse Tree)	120,82	0,54	14598	84,6	0,734
SVM (Fine Gaussian SVM)	157,97	0,21	24955	105,4	0,458
SVM (Cubic SVM)	169,95	0,09	28882	94,595	0,3

Elde edilen sonuçlar göz önüne alındığında en iyi modeli belirlemek için performans değerlendirme kriterlerinden RMSE, MSE ve MAE değerlerinin 0'a yakın olması istenirken R ve R² değerlerinin 1'e yakın olması istenmektedir. Özellik seçimi sonrası bulunan değerlere bakıldığında en iyi modelin Linear Regression modeli olduğu anlaşılmaktadır (Çizelge 5-6-7). ECG sinyali kullanılarak bir çalışma yapıldığında Linear Regression modeli cinsiyet bazlı uygulanırsa performans olumlu bir şekilde etkilenecektir.

4. Tartışma ve Sonuç (Discussion and Conclusion)

Araştırmada bulunan BMH değerleri ECG sinyalinin işlenmesiyle elde edilmiştir. Bireylerden toplanan ECG verileri işlenerek makine öğrenmesi algoritmaları yardımıyla BMH değerlerine ulaşılmıştır.

BMH günlük alınması gereken kalori miktarı hakkında en önemli yol göstericilerden biridir. Günümüzde BMH tespiti için kullanılan yöntemler oldukça zahmetli ve maliyetli olduğu için alternatif yöntemler aranmaktadır.

Literatürde BMH tespiti için genellikle dolaylı kalorimetre kullanılmaktadır (Arslan 1984). Dolaylı kalorimetre, kişinin oksijen alıp vermesini inceleyerek

BMH ölçümü yapmaktadır (LIU, LU, and CHEN 1995). Oluşturulan yeni tahmin modeli, literatürdeki yöntemle kıyaslandığında daha pratik ve maliyetsiz bir yöntem olduğu belirlenmiştir.

Dolaylı kalorimetre ile bulunan BMH değerlerinin doğru olabilmesi için deneklerin uyması gereken bazı koşullar vardır (12 saat aç kalınması, deney sırasında hareket edilmemesi, uyku düzeni vb.) (Tverskaya et al. 1998). Ancak oluşturulan yeni yöntemde herhangi bir koşul istenmemektedir. Bu da kişiden kaynaklı hataların minimuma indirilmesini sağlamaktadır. Bununla birlikte de yöntemin doğruluk oranı artmaktadır.

Sonuç olarak ECG sinyalleri ile BMH tahmini yapan bir sistem geliştirilmiş olup gündelik hayatta kullanılabileceği düşünülmektedir. Bu sistemin avantajları zahmetsiz ve maliyetsiz olması, kişi kaynaklı hataları ortadan kaldırması ve ispatlanmış doğruluk oranı sayesinde güvenilir sonuçlar elde eden bir sistem olmasıdır. Tüm bu değerlendirmeler dikkate alındığında literatüre katkı sağlayacağı düşünülmektedir.

Çıkar Çatışması

Yazar, bu makalenin yayımlanmasıyla ilgili herhangi bir çıkar çatışması olmadığını beyan eder.

Bilgilendirme

Finansal Destek

Bu çalışma Sakarya Üniversitesi Bilimsel Araştırma Projeleri Komisyonu Tarafından Desteklenmiştir. Proje Numarası: 2019-5-19-244.

Etik Kurul Onayı

Bu çalışmanın gerçekleştirilebilmesi için Sakarya Üniversitesi Tıp Fakültesi'nden eti kurulu onayı alınmıştır. Onay tarih ve numarası 03/05/2019 - 71522473/050.01.04/112.

Veri Kullanım İzni

Bu çalışmanın gerçekleştirilebilmesi için Sakarya Üniversitesi Rektörlüğü'nden veri toplama ve kullanım izni alınmıştır. İzin tarih ve numarası 27/08/2019 - 35955870/604.02.

Kaynaklar (References)

- Akay, Ebru Çağlayan. 2018. "Ekonometride Yeni Bir Ufuk: Büyük Veri ve Makine Öğrenmesi." *Social Sciences Research Journal* 7(2): 41–53.
- Arslan, Perihan. 1984. "BAZAL METABOLİZMA HIZININ SAPTANMASINDA KULLANILAN YÖNTEMLERİN KIYASLANMASI VE BAZAL METABOLİZMA ENERJİSİNİN VÜCUDUN YAĞSIZ DOKU KÜTLESİ İLE İLİŞKİSİ ÜZERİNDE BİR ARAŞTIRMA." *Beslenme ve Diyet Dergisi*.
- Ferrannini, Eleuterio. 1988. "The Theoretical Bases of Indirect Calorimetry: A Review." *Metabolism* 37(3): 287–301.
- Flancbaum, Louis et al. 1999. "Comparison of Indirect Calorimetry, the Fick Method, and Prediction Equations in Estimating the Energy Requirements of Critically Ill Patients." *The American Journal of Clinical Nutrition* 69(3): 461–66. <https://academic.oup.com/ajcn/article/69/3/461/4694179> (January 30, 2021).
- Forman, George. 2003. *3 Journal of Machine Learning Research An Extensive Empirical Study of Feature Selection Metrics for Text Classification*.
- LIU, HSIU YING, YI FA LU, and WEI JAO CHEN. 1995. "Predictive Equations for Basal Metabolic Rate in Chinese Adults. A Cross-Validation Study." *Journal of the American Dietetic Association* 95(12): 1403–8.
- Müller, B., S. Merk, U. Bürgi, and P. Diem. 2001. "Berechnung Des Grundumsatzes Bei Schwerer Und Morbider Adipositas." *Praxis* 90(45): 1955–63. <https://europepmc.org/article/med/11817239> (January 30, 2021).
- Nur Göz, Ayşe et al. 2017. *EKG İŞARETLERİ YARDIMIYLA BİR OTOMATİK ARİTMİ DEDEKTÖRÜ*. Fatih Sultan Mehmet Vakıf Üniversitesi Biyomedikal Elektronik Tasarım, Uygulama ve Araştırma Merkezi. <http://acikerisim.fsm.edu.tr:8080/xmlui/handle/11352/2491> (January 30, 2021).
- Speakman, John R., Elzbieta Król, and Maria S. Johnson. 2004. "The Functional Significance of Individual Variation in Basal Metabolic Rate." In *Physiological and Biochemical Zoology*, The University of Chicago

Press, 900–915. <https://www.journals.uchicago.edu/doi/abs/10.1086/427059> (January 30, 2021).

Tverskaya, Rozalia, Russell Rising, Debra Brown, and Fima Lifshitz. 1998. "Comparison of Several Equations and Derivation of a New Equation for Calculating Basal Metabolic Rate in Obese Children." *Journal of the American College of Nutrition* 17(4): 333–36. <https://pubmed.ncbi.nlm.nih.gov/9710841/> (January 30, 2021).

Wang, Wenjian, and Zongben Xu. 2004. "A Heuristic Training for Support Vector Regression." *Neurocomputing* 61(1–4): 259–75.