



Maksimum Oksijen Tüketiminin Adım Kinematikleri Kullanılarak Makine Öğrenme Yöntemleriyle Belirlenmesi

Determination of Maximum Oxygen Consumption By
Machine Learning Methods Using Step Kinematics

Serkan USLU¹, İbrahim Ethem HİNDİSTAN², Emel Çetin ÖZDOĞAN³

¹ Akdeniz Üniversitesi Tıp Fakültesi, Biyofizik ABD, Antalya
• serkanuslu@akdeniz.edu.tr • ORCID > 0000-0002-0875-5905

²Akdeniz Üniversitesi Spor Bilimleri Fakültesi, Hareket ve Antrenman ABD, Antalya
• ehindistan@akdeniz.edu.tr • ORCID > 0000-0003-3437-1144

³Akdeniz Üniversitesi Spor Bilimleri Fakültesi, Spor Sağlık ABD, Antalya
• emelcetin@akdeniz.edu.tr • ORCID > 000-0002-0918-1560

Makale Bilgisi / Article Information

Makale Türü / Article Types: Arařtırma Makalesi / Research Article

Geliř Tarihi / Received: 02 Nisan / April 2022

Kabul Tarihi / Accepted: 02 Ağustos / August 2022

Yıl / Year: 2022 | **Cilt – Volume:** 13 | **Sayı – Issue:** 2 | **Sayfa / Pages:** 201-216

Atıf/Cite as: Uslu, S., Hindisatan, İ, E., Özdoğan Çetin, E. "Maksimum Oksijen Tüketiminin Adım Kinematikleri Kullanılarak Makine Öğrenme Yöntemleriyle Belirlenmesi Ondokuz Mayıs Üniversitesi Spor ve Performans Arařtırmaları Dergisi 13(2), April 2022: 201-216.

Sorumlu Yazar / Corresponding Author: Emel ÇETİN ÖZDOĞAN

Etik Kurul İzin Raporları: 'Arařtırma için Akdeniz Üniversitesi Tıp Fakültesi Klinik Arařtırmalar Etik Kurulu'ndan 10/02/2016 tarihli ve 66 karar sayısı ile etik kurul izni alınmıştır.'

MAKSİMUM OKSİJEN TÜKETİMİNİN ADIM KİNEMATİKLERİ KULLANILARAK MAKİNE ÖĞRENME YÖNTEMLERİYLE BELİRLENMESİ

ÖZ:

Maksimal oksijen tüketimi ($\max\text{VO}_2$) aerobik kapasitenin doğrudan göstergesidir. Bu sebeple hem spor branşlarında hem de klinikte $\max\text{VO}_2$ ölçümü oldukça büyük öneme sahiptir. Ancak $\max\text{VO}_2$ ölçüm sistemlerinin maliyetli oluşu farklı analiz yöntemlerinin belirlenmesi ihtiyacını ortaya çıkarmıştır. Bu çalışmada da antropometrik, kinematik, kalp atım hızı ve adım parametreleri kullanılarak makine öğrenme modelleri ile $\max\text{VO}_2$ değerlerinin tahmin edilmesi amaçlanmıştır. Çalışmaya katılan 52 erkek sporcunun koşu bandında yapılan üç farklı koşu hızında $\max\text{VO}_2$ değerleri ve kalp atım hızları belirlenmiş, antropometrik ve kinematik veriler ile birlikte değerlendirilmiştir. Yaş, boy, vücut ağırlığı, kalp atım hızı, bacak uzunluğu, uyluk uzunluğu, hız, adım frekansı, adım uzunluğu parametreleri makine öğrenme modellerine girdi olarak sunularak $\max\text{VO}_2$ değerinin hesaplanması istenmiştir. Ayrıca dört farklı makine öğrenme modeli (lineer regresyon, destek vektör makineleri, karar ağaçları ve gauss süreç regresyonu) deneneren en başarılı yaklaşımın hangisi olduğu incelenmiştir. Gauss Süreç Regresyonu modelinin en başarılı tahmin ($R^2=0.99$) ve en düşük hata oranı ($\text{RMSE}=0.012$) ile $\max\text{VO}_2$ değerini tahmin ettiği belirlenmiştir. Sonuç olarak çalışma kapsamında temel antropometrik ölçümler (boy, vücut ağırlığı, bacak ve uyluk uzunluğu), kalp atım hızı, hız ve adım parametreleri (adım frekansı ve adım uzunluğu) kullanılarak $\max\text{VO}_2$ değerleri hem submaksimal hem de maksimal değerlerde başarılı olarak tahmin edilmiştir.

Anahtar Kelimeler: Aerobik Kapasite, Makine Öğrenmesi, Maksimal Oksijen Tüketimi.



DETERMINATION OF MAXIMUM OXYGEN CONSUMPTION BY MACHINE LEARNING METHODS USING STEP KINEMATICS

ABSTRACT

Maximal oxygen consumption ($\max\text{VO}_2$) is a direct indicator of aerobic capacity. For this reason, $\max\text{VO}_2$ measurement is of great importance both in sport branches and also in clinic. However, the fact that $\max\text{VO}_2$ measurement systems are costly has led to the need to determine different analysis methods. In this study, it was aimed to predict $\max\text{VO}_2$ values with machine learning models using anthropometric, kinematic, heart rate and step parameters. $\max\text{VO}_2$ values and heart rates of 52 male athletes participating in the study at three different running speeds

on the treadmill were determined and evaluated together with anthropometric and kinematic data. Age, height, body weight, heart rate, leg length, thigh length, running speed, stride frequency, stride length parameters were presented as input to the machine learning models and the calculation of the $\max\text{VO}_2$ value was made. In addition, four different machine learning models (Linear Regression, Support Vector Machines, Decision Trees, and Gaussian Process Regression) were used and the most successful approach was examined. The Gaussian Process Regression model was able to determine the $\max\text{VO}_2$ value with the most successful prediction ($R^2=0.99$) and the lowest error rate (RMSE=0.012). As a result, $\max\text{VO}_2$ values were successfully estimated in both submaximal and maximal values using basic anthropometric measurements (height, body weight, leg and thigh length), heart rate, speed and stride parameters (stride frequency and stride length) within the scope of the study.

Keywords: *Aerobic Capacity, Machine Learning, Maximal Oxygen Consumption.*



GİRİŞ

Egzersiz dayalı metabolik ihtiyaçları karşılayabilmek için kardiyopulmoner sistemin normale göre daha fazla çalışması gerekir. Bu durum kalbin dakikadaki atım sayısını arttırarak periferik gönderdiği debiyi arttırmasına ve debideki bu artış kaynaklı olarak da pulmoner sistemin daha fazla çalışarak oksijen ihtiyacını karşılaması ile sağlanır. Hem kalbin atım sayısındaki artış hem pulmoner sistemin çalışmasındaki artış doğrudan maksimum oksijen tüketimi ile ilişkilidir (Abut ve Akay, 2015). Maksimum oksijen tüketimi ($\max\text{VO}_2$), yapılan işte artış olmasına rağmen alınan oksijende artışın olmadığı durum olarak tanımlanmaktadır (George ve ark., 2009; Akay ve ark., 2014). Aerobik kapasitenin tanımının oksijenin kardiyopulmoner sistem tarafından kaslara iletilmesi ve kas tarafından yapılan işte oksijenin kullanılması olduğu göz önünde bulundurulduğunda $\max\text{VO}_2$, aerobik kapasitenin doğrudan göstergesidir (Yaprak ve Aslan, 2008). Yapılan çalışmalarda $\max\text{VO}_2$ 'nin aerobik kapasitenin belirlenmesinde en güvenilir test olduğu belirtilmektedir (Sinirkavak ve ark., 2004).

$\max\text{VO}_2$ 'nin belirlenmesi için kullanılan yöntemler en basit haliyle doğrudan ve dolaylı ölçümler olmak üzere iki başlık altında incelenmektedir (Harrison ve ark., 1980). Doğrudan ölçüm yönteminde, laboratuvar koşullarında maksimal yüklenme sırasında gaz analizörleriyle ekspirasyondaki oksijen ve karbondioksit miktarlarının belirlenmesi temel alınır (Lakomy ve Lakomy, 1993). Dolaylı ölçüm yöntemlerinde ise önceden hazırlanmış protokoller aracılığıyla koşu bandı veya bisiklet ergometresinde maksimal veya submaksimal egzersiz sırasında EKG takibi ile $\max\text{VO}_2$ belirlenir (Silva ve ark., 2021). Maksimal aerobik kapasitenin kardiy-

respiratuvar sisteminin dayanıklılığını gösteren en iyi kriter olması ve aerobik kapasitenin belirlenmesinde en güvenilir yöntem olması nedeniyle $\max\text{VO}_2$ ölçümünü hem spor branşlarında hem de klinikte geniş kullanım alanına sahiptir (Bundy ve Leaver, 2012). Ekipmanların oldukça yüksek maliyetli ve testlerin yorucu olması gibi maksimal testlerin dezavantajları, maksimum efor gerektirmeyen yeni yöntemlerin arayışına neden olmaktadır (Abut ve Akay, 2015).

Makine öğrenmesi, en yalın ifadesiyle karar alma süreçleri için geliştirilen veriden öğrenme yöntemidir (Jalil ve ark., 2019). Verilerdeki örüntünün tespit edilmesi ve buna bağlı olarak algoritmanın daha iyi karar vermesi temel amaçtır (Uslu ve Çetin, 2022). Makine öğrenme modelleri son yıllarda $\max\text{VO}_2$ 'nin belirlenmesi için sıklıkla kullanılan yöntemlerden birisi haline gelmiştir. Billinger ve ark. (2012) vücut ağırlığı, yaş, kalp atım hızı (nabız) ve iş oranı parametrelerini girdi olarak kullanarak $\max\text{VO}_2$ 'yi $R^2=0.91$ başarı oranı ile tahmin etmişlerdir. Abut ve ark. (2016) yaş, vücut kitle indeksi, test bitiş zamanı ve nabız parametrelerini girdi olarak kullanarak $R^2=0.88$ başarı oranı ile $\max\text{VO}_2$ 'yi belirlemişlerdir. Akay ve ark. (2014) $\max\text{VO}_2$ 'nin submaksimal performansta farklı makine öğrenme algoritmaları ile yaş, boy, vücut ağırlığı, nabız ve egzersiz sürelerini girdi olarak kullanarak $\max\text{VO}_2$ 'yi $R^2=0.86$ doğruluk oranı ile tahmin etmişlerdir. Aynı ekip bir başka çalışmada yapay sinir ağı kullanarak benzer girdi parametreleri ile daha yüksek başarı elde etmişlerdir (Akay ve ark., 2011).

Daha önceki yapılan çalışmalardan anlaşılacağı üzere başarılı tahminde önemli bir husus girdi parametrelerinin belirlenmesidir. $\max\text{VO}_2$, tüm enerji sistemleri (aerobik ve anaerobik), hemoglobin kütlesi, atım hacmi, kas liflerinin değişimi, vücut kompozisyonu ve kas kılcal yoğunluğu gibi birçok fizyolojik değişkenden etkilenir ve bu değişkenler birleşerek performansı oluşturur (Jung, 2003; Saunders ve ark., 2004). Koşu ya da yürüyüş sırasında ise performansı belirleyen önemli diğer kinematik parametreler adım uzunluğu ve adım frekansdır (Chatzilazaridis ve ark., 2012; Cetin ve ark., 2018). Submaksimal ve maksimal yürüyüş ya da koşu sırasında farklı adım frekansını ve uzunluğunun ölçülen fizyolojik parametrelere özellikle oksijen tüketimi ve kan laktat düzeyine olan etkileri yıllar boyunca araştırmacıların ilgisini çekmiştir (Tartaruga ve ark., 2021). Adım frekansındaki uyarlamalar kuvvet üretimini, kas kasılmasının uzunluğunu, hızlarını ve dolayısıyla enerji maliyetlerini etkileyebilir (Barclay, 1994). Submaksimal hızlarda, elit koşucular, acemi koşuculara göre oksijen tüketimi için minimuma daha yakın bir adım frekansı seçerek koşu performansında anlamlı iyileştirmeler elde etmişlerdir (De Ruyter ve ark., 2014). Ayrıca, sonuçlar optimal adım frekansının, sabit hızda koşu sırasında adım frekansı ve kalp atım sayıları (KAS) arasındaki ilişkiden kurulabileceğini göstermektedir (De Ruyter ve ark., 2014).

Bu nedenle çalışmada, sporcuların koşu kinematik parametreleri (adım uzunluğu, adım frekansı), fiziksel ve antropometrik özellikleri (yaş, boy, vücut ağırlığı,

bacak uzunluğu, uyluk uzunluğu) ve nabız parametreleri girdi olarak kullanılarak farklı makine öğrenme modelleri ile $\max\text{VO}_2$ değerinin bulunması, sahada kolaylıkla belirlenebilen adım parametrelerinin etkisini belirlemek amaçlanmıştır.

YÖNTEM

Araştırma Grubu

Araştırmaya Akdeniz Üniversitesi'nde öğrenim gören farklı branşlardan 52 erkek sporcu katılmıştır (Tablo 1). Katılımda gönüllük ilkesi dikkate alınmış ve testler ile çalışmanın detayları olası risk ve faydalarını anlatan Aydınlatılmış Onam Formu verilerek onaylamaları istenmiştir. Çalışma, Akdeniz Üniversitesi Etik Kurulu tarafından onaylanmış olup tüm araştırmacılar Helsinki bildirgesini kabul etmişlerdir (10/02/2016/66).

Tablo 1. Araştırma grubunun fiziksel özellikleri ve spor branşlarının dağılımı

Değişkenler	Futbol (n=17)	Basketbol (n=16)	Hentbol (n=19)
Yaş (yıl)	21.90±1.79	22.80±1.81	20.38±2.02
Boy (cm)	179.10±1.79	177.60±5.58	174.00±9.30
Ağırlık (kg)	71.70±12.67	74.80±10.06	71.69±15.42
Antrenman yaşı (yıl)	9.02±2.05	7.54±1.98	8.70±1.70

Veri Toplama Araçları

Çalışmada ilk olarak katılımcıların boy, ağırlık ve antropometrik ölçümleri alınmıştır. Daha sonra $\max\text{VO}_2$ ortalama değerini belirlemek amacıyla koşu bandında (Viasys Healthcare, LE 200 CE, h/p/cosmos sports and medical gmbh, Germany) Balke Koşu Bandı Protokolü uygulanmış, protokol için geliştirilen eşitlik kullanılarak, test süresinden $\max\text{VO}_2$ ortalama değeri tahmin edilmiştir.

Test sırasında katılımcıların KAS değerleri takip edilmiş, submaksimal ve maksimal değerleri hesaplanarak $\max\text{VO}_2$ ' nin %80, %85 ve %90'a denk gelen hız değerimleri belirlenmiştir.

Kırk sekiz saat sonra, 5 dakikalık ısınma protokolünün (0 derece eğimde, 3 mil/sa (4.8 km/sa) hızda) ardından, katılımcılar belirlenen her bir hız değeri için 3 dakika koşu bandında koşmuşlardır. Performans sırasında adım frekansını ve adım uzunluğunu belirlemek amacıyla bir adet dijital kamera (Sony HDR-SR12E, 50 Hz), katılımcıyı ve koşu bandını görecektir şekilde sagittal düzleme ve yaklaşık olarak vücut ağırlık merkezi yüksekliğinde olacak şekilde tripod üzerine yerleştirilmiştir. Test sonunda kamera kayıtları bilgisayar ortamına aktarılmış, her bir üç dakikalık koşu performansı için ikinci dakika boyunca (toplam bir dakika) adım parametre-

leri için değerlendirilmiştir. Adım frekans değerleri için bir dakika boyunca adım sayıları belirlenirken, adım uzunluğu için bir dakika boyunca analiz edilen adım uzunluk değerlerinin aritmetik ortalaması kaydedilmiştir.

Verilerin Toplanması/İşlem Yolu:

Antropometrik ölçümler

Boy: Boy duvar skalası kullanılarak yapıldı. Katılımcılar ayakları çıplak ya da kalınlığı göz ardı edilebilecek bir çorap giydiler. Katılımcı düz bir zeminde duvar skalasına doğru bir açıda durdu. Katılımcıdan ağırlığı iki ayağına eşit dağıtılmış, topuklar birleşik ve duvar ile temasta, baş sabit, kollar omuzlardan serbestçe yanlara sarkıtılmış durumda olması istendi. Ölçüm esnasında katılımcıdan derin bir nefes alınmasını ve dik pozisyonunu topukları yerden ayrılmaksızın durması istendi, saçlar yeterli miktarda sıkıştırılarak duvar skalası yardımıyla ölçüm 1 mm'ye kadar not edildi (Özer,1993).

Vücut Ağırlığı: Katılımcıların vücut ağırlığı atlet ve şort ile basküle ile belirlenmiş, ölçümler kg cinsinden kaydedildi (Özer, 1993).

Bacak Uzunluğu: Bacak uzunluğu, katılımcının ayakta anatomik pozisyondayken kalça eklemi ile yer arasındaki trochanter yüksekliğinin mezura ile ölçülmesiyle belirlendi(Özer, 1993).

Üst Bacak (Uyluk) Uzunluğu: Bu uzunluk anatomik olarak kalça-diz uzunluğu olarak tanımlanır. Direkt uyluk uzunluğu oturma yüksekliği ölçümünde önerilen pozisyonda, patellanın proksimal ucu ile inguinal ligamentin orta noktası arasındaki uzaklık olarak ölçülmüştür. Ölçüm için esnek olmayan mezura kullanılmıştır (Özer, 1993).

Kinematik parametreler

Adım Uzunluğu: Bir topuğun yere temas eden noktası ile diğer topuğun yere temas noktası arasındaki mesafe olarak belirlenerek, Kinovea 0.9.5 programı ile analiz belirlendi.

Adım Frekansı: Test sırasında bir dakika boyunca adım sayısından belirlendi.

Balke Koşu Bandı Protokolü

Balke ve Ware tarafından geliştirilen bu test protokolünde hem eğim hem hız artar (Balke ve Ware, 1959). Eğim %0, hız 3.3 km/sa ile test başlar. Bir dakika sonra eğim %2 artırılır ve sonraki her bir dakikada eğim %1 artırılır. Hız ise sabit kalır.

Katılımcının sonlandırmayı istediği ana kadar test devam eder. Protokol için geliştirilen eşitlik kullanılarak, egzersiz süresinden $\max VO_2$ ortalama değeri tahmin edilir. Balke testine göre $\max VO_2$ değeri Tablo 2'de gösterilen eşitlikler kullanılarak hesaplanır (Heyward & Kotarski, 1992).

Tablo 2. Balke Koşu Bandı Protokolü eşitlikleri

Protokol	Referans	Eşitlik
Balke Aktif ve sedanter erkek	Pollock ve ark. (1976)	$VO_{2max} = 1.444 (\text{süre}) + 14.99$
Aktif ve sedanter kadın	Pollock ve ark. (1982)	$VO_{2max} = 1.38 (\text{süre}) + 5.22$

VERİLERİN ANALİZİ

Makine Öğrenme Modelleri

Makine öğrenmesi, en yalın ifadesiyle karar alma süreçleri için geliştirilen veriden öğrenme yöntemidir (Jalil ve ark., 2019). Verilerdeki örüntünün tespit edilmesi ve buna bağlı olarak algoritmanın daha iyi karar vermesi temel amaçtır (Uslu ve Çetin, 2022). Çalışmada $\max VO_2$ 'nin belirlenmesi için dört farklı makine öğrenmesi modeli (Temel Lineer Regresyon, Karar Ağaçları, Destek Vektör Makineleri, Gauss Süreç Regresyonu) kullanılmıştır.

Lineer regresyon (LR) en temel makine öğrenme modelidir. Girdi verileri ile çıktı verileri arasında lineer bir ilişki olduğunda sıklıkla kullanılmaktadır. Veri dağılımının karakteristiğini belirlemek için lineer regresyon ile tahmin yaptırıp sonuçların lineer dağılım gösterip göstermediğini gözlemlemek kullanılacak diğer modelleri belirlemek oldukça fayda sağlamaktadır. Denklem 1' de LR ifadesinin matematiksel eşleniği gösterilmiştir.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad \text{Denklem 1}$$

β_0 , y kesişim noktasını, β_1 eğim (regresyon katsayısı) ve ε hata terimini ifade etmektedir.

Gauss süreç regresyonu (GSR), bilinmeyen fonksiyonları tanımlamaya, aktif olarak öğrenmeye ve optimize etmeye yönelik bir yaklaşımdır (Gutierrez Becker ve ark., 2018). Bir Gauss süreci, herhangi bir sonlu sayısı ortak bir Gauss dağılımına sahip olan rastgele değişkenlerin bir koleksiyonu olarak tanımlanır ve bu koleksiyon çekirdek (kernel) fonksiyonu olarak da bilinen ortalama ve kovaryans fonksiyonu ile tamamen tanımlanabilir (Williams ve Rasmussen, 2006). Ortalama ve kovaryans fonksiyonunun seçimi, bilinmeyen fonksiyona düzgünlük varsayımları uygulamalar ve ilgili gözlem verisi noktaları arasındaki X öklid mesafenin bir fonksiyo-

nu olarak Y çıktı gözlemleri arasındaki korelasyonu belirler (Quinonero-Candela ve Rasmussen, 2005). Dolayısıyla GSR Denklem 2'de tanımlanan ortalama ($m(x)$, Denklem 3) ve kovaryans fonksiyonları ($k(x, x')$, Denklem 4) ile ifade olacak.

$$f(x) = GP(m(x), k(x, x')) \quad \text{Denklem 2}$$

$$m(x) = \mathbb{E}[f(x)] \quad \text{Denklem 3}$$

$$k(x, x') = \mathbb{E}[(f(x) - m(x)) - (f(x') - m(x'))] \quad \text{Denklem 4}$$

Destek vektör makinesi (DVM), ilk olarak sınıflandırma yapabilme amacıyla geliştirilmiş bir makine öğrenme algoritmasıdır. Verilerin dağılımını göz önünde bulundurarak farklı sınıflara ait destek vektörleri arasındaki uzaklığın maksimum olduğu bir hiper düzlem oluşturur (Vapnik, 1999). Veriler, oluşturulan bu hiper düzleme göre olan konumları itibarıyla farklı sınıflara ayrılır. DVM, algoritmayı karakterize eden tüm ana özellikleri (maksimum marj) koruyarak bir regresyon yöntemi olarak da kullanılabilir. Her iki tahmin yönteminde de benzer ilkeler kullanılır. Farklı çekirdek (kernel) fonksiyonlarının uygulanabilir olması ile DVM hem parametrik hem non-parametrik verilerde kullanılabilir (S. Raj ve Ananthi J, 2019). Non-parametrik verilerde sınıflandırma kernel (çekirdek) fonksiyonları aracılığıyla yapılır. Kernel fonksiyonları lineer olmayan dağılımların lineer olarak değerlendirilebilmelerine imkanı sağlar. Denklem 5' de temel DVM fonksiyonu gösterilmiştir. $K(x, x_i)$ farklı kernel fonksiyonlarını ifade edecek.

$$h(x) = \sum_{i=1}^n \alpha_i y_i k(x, x_i) + b \quad \text{Denklem 5}$$

n , eğitim setindeki veri sayısını; α , x' 'in lagrange çarpımını temsil etmektedir.

Karar Ağaçları (KA) yaptığı seçimlerde bulunulan durumun entropi değerini (rastgelelik derecesini) düşürmeyi amaçlayarak seçimler yapar ve bilgi kazancını (information gain) maksimize etmeye çalışır. Bunun için de her soruda (düğüm/node) hata fonksiyonunu tekrar hesaplayıp en düşük hataya sahip soruyu/durumu seçer. Sınıflandırma ve regresyon ağacı modeli, analiz edilen verilerin niteliğine göre farklı isimlendirilmektedir. Bağımlı değişkenin kategorik olması halinde sınıflandırma ağacı, sürekli değişken olması halinde de regresyon ağacı kullanılmaktadır (Xu, 2005).

Tüm makine öğrenme modellerine Tablo 3' de belirtilen sekiz özellikten oluşan veriler girdi olarak sunulmuştur. Girdi verileri geliştirilecek modelin yanlış öğrenmesine engel olmak amacıyla normalize edilmiştir. Normalize dağılımları Şekil 1'

de gösterilmiştir. Geliştirilen modellerde bir diğer önemli konu modelin başlangıç parametrelerin ve ilerlemesinin optimizasyonudur. Her makine öğrenmesi modeli için hiperparametre optimizasyonunda iteratif yaklaşım kullanılmıştır.

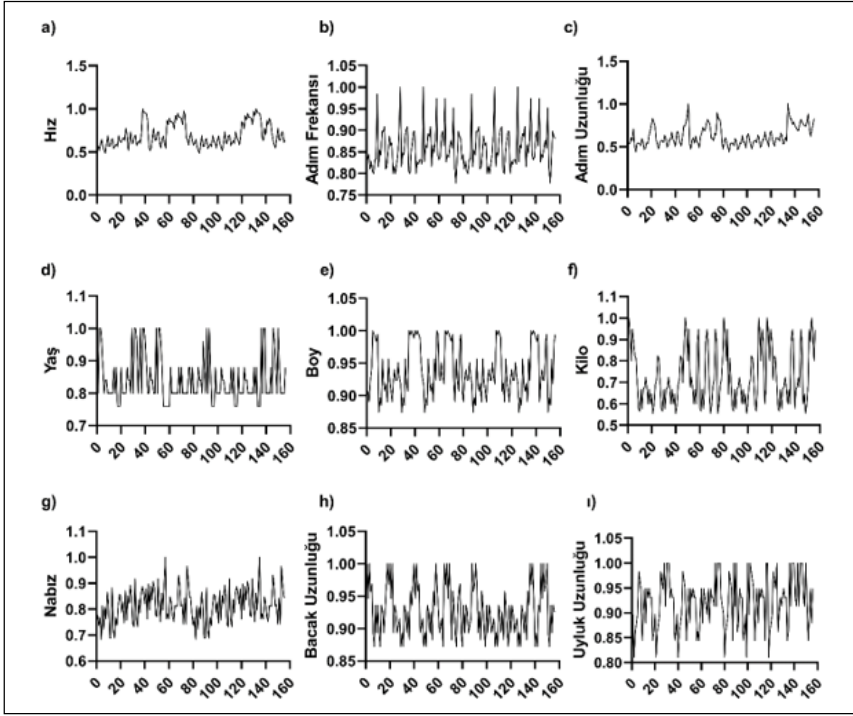
Makine öğrenme modellerinde sık karşılaşılan bir diğer problem ise modellerin eğitim setindeki veriye fazla uyum sağlamasıdır. Bu gibi durumlarda eğitim setinde başarı çok yüksek iken yeni bir girdi sunulduğunda modelin başarısında önemli bir düşüş gözlemlenir. Bu durumun önlenmesi için tüm modellere 10 katlı çapraz doğrulama uygulanmıştır. Verilerin %70'i eğitim için (n=109), %30'u validasyon için (n=47) rastgele olacak şekilde ayrılmıştır. Öğrenme seti ve test setindeki başarılar karşılaştırılarak modelde aşırı öğrenme (overfitting) durumunun olup olmadığı her denemede takip edilmiştir. Tüm analizler MATLAB programında gerçekleştirilmiştir.

İstatiksel Analiz

Çalışmada makine öğrenme modeline sunulan girdi verileri aritmetik ortalama ve standart sapma ile değerlendirilmiştir. Tüm modellerin başarıları gerçek veri ve tahmin edilen veri arasındaki korelasyon (R2) ile değerlendirilmiştir. Modellerin kaybı ise gerçek veri ve tahmin edilen veri arasındaki kök ortalama kare hatası (RMSE) ile kıyaslanmıştır. Ayrıca tek bir veri setinden fazla öğrenme olup olmadığının anlaşılması için eğitim ve validasyon setlerindeki başarılar kıyaslanmıştır.

Tablo 3. Makine öğrenme modellerine girdi olarak sunulan veriler

Parametre	Ort. ± S.S.
Yaş (yıl)	21.08 ± 1.83
Boy (cm)	171.7 ± 7.19
Vücut Ağırlığı (kg)	65.54 ± 11.99
Bacak Uzunluğu (cm)	87.15 ± 3.65
Uyluk Uzunluğu (cm)	53.46 ± 3.02
Kalp atım sayısı (atım/dakika)	164.5 ± 13.54
Adım Frekansı (adım/dakika)	158.9 ± 8.83
Adım Uzunluğu (cm)	0.95 ± 0.17
Hız (km/saat)	9.02 ± 1.77



Şekil 1. Normalize edilmiş veriler


BULGULAR

Çalışma kapsamında $\max\text{VO}_2$ değerleri yaş, boy, vücut ağırlığı, nabız, bacak uzunluğu, uyluk uzunluğu, hız, adım frekansı, adım uzunluğu parametreleri kullanılarak LR, KA, DVM ve GSR olmak üzere dört farklı makine öğrenmesi modeli ile tahmin edilmeye çalışıldı. Ölçülen değer ile tahmin edilen değerler arasındaki korelasyon katsayısı ve RMSE belirlenerek modellerin başarısı karşılaştırıldı.

LR, 0.68 R^2 oranı ile en düşük korelasyon katsayısına sahip olduğu görüldü. KA modelinin R^2 ye göre daha yüksek R^2 oranına sahip olduğu görüldü ($R^2=0.80$). DVM modeli LR ve KA modellerine göre oldukça yüksek başarı oranına sahiptir ($R^2=0.96$). GSR modeli ise dört model içerisinde en yüksek başarı oranına sahip modeldir. $\max\text{VO}_2$ tahminini $R^2=0.99$ başarı oranı ile tahmin edebildi. Tüm modellerin başarı oranları Şekil 2’de gösterilmiştir.

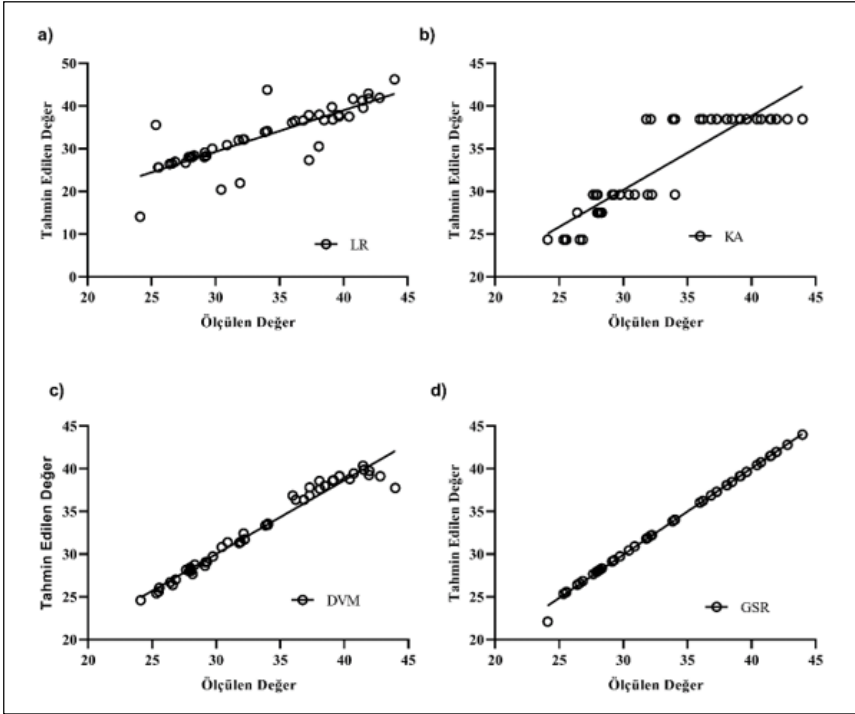
Modellerin başarılarının kıyaslandığı bir diğer parametre ise RMSE’ dir. RMSE ölçülen veri ile tahmin edilen veri arasındaki farkların karelerinin toplama-

mının kareköküne eşittir. Dolayısıyla birimi değerlendirilen parametrenin birimi ile aynı, büyüklüğü model çıktısı ile girdi arasındaki farklılıkla ilişkilidir. RMSE ayrıca modelin eğitimi ve validasyonu sırasındaki başarıların kıyaslanması için de sıklıkla kullanılmaktadır. Eğitim veri setindeki RMSE değerinin validasyon veri setindeki RMSE göre çok düşük olması modelin eğitim veri setinden fazla öğrendiğini (“overfit”) bu yüzden bilmediği bir veri geldiğinde yanlış tahminde bulunduğunu gösterir. Çalışmada en yüksek RMSE değeri, R^2 ’den farklı olarak KA modeline aitti (RMSEKA=3.85). Bu durum KA modelinin belirli değerler kümesi için benzer sonuçları vermesi ile ilişkili olabilir. DVM modelinin RMSE değeri (RMSEDVM=1.35) LR ve KA modellerine göre daha az ancak GSR modeline göre oldukça yüksekti. GSR modeli R^2 oranındaki başarısına benzer olarak RMSE’de en düşük hata değeri ile tahmin yapabildiğini gösterdi (RMSEGSR=0.012). Tüm modellerin RMSE değerleri eğitim setleri için Şekil 2b’de, validasyon setleri için Şekil 2c’de gösterilmiştir. Şekilden de anlaşılacağı üzere eğitim ve validasyon veri setlerindeki RMSE değerleri birbirlerine oldukça yakındır. Bu durum modelin herhangi bir veri setinden fazla öğrenme yapmadığını göstermektedir.



Şekil 2. Makine modellerinin R^2 , RMSE değerleri, KA, Karar Ağacı, LR, Lineer Regresyon, DVM, Destek Vektör Makinesi, GSR, Gaussian Süreç Regresyonu

Yöntem kısmında bahsedildiği üzere tüm verinin %30'u (n=47) validasyon için ayrılmıştı. Bu veriler modelin eğitim sırasında hiç görmediği veri grubunu oluşturmaktadır ve model eğitimini tamamladıktan sonra test için modele verilmektedir. Tüm modellerin validasyon veri setindeki tahminleri Şekil 3'de sırasıyla gösterilmiştir. Ölçülen ve makine öğrenme modelleri ile tahmin edilen $\max\text{VO}_2$ değerleri grup ortalamaları \pm standart sapma şeklinde Tablo 4' de sunulmuştur.



Şekil 3. Makine modellerinin tahminleri ve ölçülen gerçek değerler, KA, Karar Ağacı, LR, Lineer Regresyon, DVM, Destek Vektör Makinesi, GSR, Gaussian Süreç Regresyonu

Tablo 4. Ölçülen ve makine öğrenme modelleri ile tahmin edilen $\max\text{VO}_2$ değerlerinin grup ortalamaları

	$\max\text{VO}_2$ (ml $\text{kg}^{-1}\text{min}^{-1}$)
Ölçülen	33.53 \pm 5.81
LR	32.70 \pm 6.80
KA	33.22 \pm 5.60
DVM	33.05 \pm 5.10
GSR	33.48 \pm 5.89

Ölçülen ve makine öğrenme modelleri ile tahmin edilen $\max\text{VO}_2$ değerleri grup ortalamaları \pm standart sapma şeklinde sunulmuştur. KA, Karar Ağacı, LR, Lineer Regresyon, DVM, Destek Vektör Makinesi, GSR, Gaussian Süreç Regresyonu

TARTIŞMA

Bu çalışma kapsamında $\max\text{VO}_2$ submaksimal performans testi sırasında elde edilen kinematik parametreler ve antropometrik özellikler kullanarak makine öğrenme yöntemleri ile belirlenmeye çalışılmıştır. Çalışmada elde ettiğimiz bulgular adım parametrelerinin eklenmesinin makine öğrenme yöntemlerinin $\max\text{VO}_2$ 'yi tahmin etmede başarı oranını arttırdığını göstermektedir. Ayrıca makine öğrenme modeline girdi olarak sunulan verilerin ölçümünün oldukça kısa sürmesi ve submaksimal performansın kullanılması yöntemin kullanılabilirliği hedef kitleyi genişletmektedir.

$\max\text{VO}_2$ aerobik kapasitenin en güvenilir göstergesi olarak kabul edilmektedir (Ashfaq ve ark., 2022). Bu sebeple $\max\text{VO}_2$ 'nin belirlenmesi hem spor branşlarında hem de klinikte büyük önem kazanmaktadır (Bundy ve Leaver, 2012). Ölçüm sistemlerinin maliyetli ve kompleks sistemler olması nedeniyle farklı yöntemler ile $\max\text{VO}_2$ 'nin değerlendirilebilmesi literatürde uzun süredir araştırılan bir konudur (Abut ve ark., 2015). Ayrıca maksimal testlerin yüksek maliyetlerinin yanı sıra tecrübeli personele ihtiyaç duyması da önemli bir sınırlılık oluşturmaktadır (Ashfaq ve ark., 2022, Abut ve Akay, 2015). Bu durum uygulanabilirliği daha kolay ve ölçümü kalifiye personele ihtiyaç duymayacak yöntemlerden yararlanarak farklı matematiksel yaklaşımlar ile $\max\text{VO}_2$ 'nin belirlenmesi ihtiyacını doğurmuştur.

Yakın dönemde birçok farklı alanda oldukça yüksek başarı oranı sunan makine öğrenme yöntemlerinin özellikle tekrar edilebilirlik, geçerlilik ve güvenilirliklerinin yüksek olması bu algoritmaların tercih edilmesi içinde en önemli avantajlardır (Richter ve ark., 2021). Bunun yanı sıra makine öğrenme modelinin istenilen başarı oranı ile bir kez eğitilmesinin ardından kullanımının oldukça kolay olması da sağladığı bir diğer önemli avantajdır (Richter ve ark., 2021). Bu nedenle $\max\text{VO}_2$ 'nin makine öğrenme algoritmaları ile belirlenmesi için farklı çalışmalar yapılmıştır. Mevcut çalışmalarda farklı girdi parametreleri ve farklı makine öğrenme modelleri kullanılarak belirli bir oranın üstünde başarı ile $\max\text{VO}_2$ 'nin tahmin edilebildiği gösterilmiştir. Ashfaq ve ark. (2022) $\max\text{VO}_2$ 'nin tahmin edilmesinde en sık kullanılan parametreleri yaş, cinsiyet, maksimal kalp atım hızı ve vücut kitle indeksi olarak belirtmişlerdir (Ashfaq ve ark., 2022). Akay ve ark. (2011) tarafından yapılan çalışmada modele yaş, boy, vücut ağırlığı ve nabız verileri girildiğinde başarının yaş, boy, vücut ağırlığı, nabız ve test süreleri verildiğindeki başarıya kıyasla düşük olduğu gösterilmiştir. Aynı parametrelerin verildiği başka bir çalışmada ise kullanılan makine öğrenme modelinin farklı olması sebebiyle başarı oranının daha düşük olduğu görülmüştür (Akay ve ark., 2014). Buradan da

anlaşılacağı üzere başarı oranlarındaki değişim seçilen performans testi, kullanılan makine öğrenme modeli ve modele sunulan girdi parametreleri ile ilişkilidir (Abut ve Akay, 2015). Submaksimal performans testleri grubunda yer alan belirli süreli, %60-80 performans testlerinin sadece antropometrik ya da demografik özelliklere göre daha yüksek başarı sağladığı daha önceki çalışmalarda gösterilmiştir (Abut ve Akay, 2015). Shandhi ve ark. (2021) tarafından yapılan çalışmada günlük yaşam aktivitesi sırasında EKG ve seismo kardiyogram sinyallerini kullanarak $\max\text{VO}_2$ lineer regresyon ile tahmin edilmeye çalışıldığında başarı oranı nispeten düşüktür ($R=0.64$). Beltrame ve ark. (2017) ise günlük yaşam aktiviteleri sırasında EKG ve akselerometre sinyallerini rastgele orman algoritması ile kullandığında daha yüksek başarı oranı ($R=0.87$) elde etmişlerdir. Bu çalışmalarda elde edilen başarı oranları iki farklı sonuca işaret etmektedir; lineer regresyon $\max\text{VO}_2$ 'nin tahmini için diğer algoritmalara kıyasla daha düşük başarı oranı sağlamaktadır ve test performansları günlük yaşam aktivitelerine kıyasla daha başarılı girdi verilerini elde edilmesini sağlamaktadır. Borrer ve ark. (2019) ise bisiklet testi sırasında kalp hızı ve vücut kitle indeksi değerlerine kadans değerlerini eklediğinde $R=0.91$ başarı oranı elde etmişlerdir. Başarı oranındaki bu artış performansın ve biyomekanik parametrelerin $\max\text{VO}_2$ 'nin tahmininde etkili olabileceğini işaret etmektedir.

Bu nedenle çalışma kapsamında hem aerobik kapasiteye etki ettiği bilinen adım frekansı ve adım uzunluğu eklenmiş hem de literatür araştırması sonucu dört farklı makine öğrenme modeli kullanılmıştır (Ashfaq ve ark., 2022). LR modelinde düşük başarı oranı girdi verileri ile $\max\text{VO}_2$ arasındaki ilişkinin doğrusal olmadığını göstermektedir. KA modelinde diğer iki modele göre daha düşük başarı çıkması ise hangi parametrenin etkin olduğuna model tarafından tam karar verilememesi sonucu benzer çıktı değerlerine sahip olması ile ilişkili olabilir.

Bunun yanı sıra elde ettiğimiz bulgular aynı model kullanıldığında bile daha yüksek R^2 oranına sahip olduğumuzu göstermektedir. Bu durum adım frekansı ve adım uzunluğunun $\max\text{VO}_2$ 'nin belirlenmesinde önemi olduğunu göstermektedir. Adım parametrelerinin de teste eklenmesi gerekli parametre sayısında artış olduğunu düşündürse de gelişen teknolojik imkanlar sayesinde gündelik yaşamda sıklıkla kullanılan mobil cihazlardan da kolaylıkla adım parametrelerinin elde edilebilmesi test açısından fazladan bir mali yük oluşturmayacaktır (Ashfaq ve ark., 2022, Abut ve Akay, 2015). Yüksek başarı oranının bir diğer sebebi ise kullanılan makine öğrenme modellerinin farklılığıdır. DVM modeli daha önce yapılan çalışmalarda sıklıkla kullanıldığı için bu çalışmada da kullanılmıştır. Ancak en yüksek başarı oranı DVM'de değil GSR modelinde elde edildi. Her ne kadar DVM ve GSR modellerinin her ikisi de parametrik olmayan verilerde çekirdek fonksiyonu uygulaması sayesinde yüksek başarı oranına sahip olsa da GSR modelinin göreceli olarak daha küçük veri kümelerinde daha başarılı çalıştığı bilinmektedir (Rasmussen, 2003). GSR modelinde elde ettiğimiz yüksek başarılı tahmin oranı ($R^2=0.99$) bu durum ile ilişkili olabilir.

SONUÇ VE ÖNERİLER

Sonuç olarak çalışma kapsamında temel antropometrik ölçümler (boy, vücut ağırlığı, bacak ve uyluk uzunluğu), nabız, hız ve adım parametreleri (adım frekansı ve adım uzunluğu) kullanılarak $\max\text{VO}_2$ değerleri makine öğrenme yöntemleri ile hem submaksimal hem de maksimal değerlerde başarılı olarak tahmin edilmiştir. Adım parametrelerinin tahmin etme başarı oranı üzerindeki etkisi, ileriki çalışmalarda daha az girdi parametresi kullanarak $\max\text{VO}_2$ 'nin belirlenmesini sağlayabilir. Bu da yorucu ve zaman alan egzersiz testi yapma ihtiyacını azaltarak, özellikle yaşlılarda ve klinik çalışmalarda basit, hızlı şekilde tahmin edilmesine olanak veren maksimum çaba gerektirmeyen ölçüm yöntemlerinin geliştirilmesinde yol gösterici olabilir.

Teşekkür ve Bilgi Beyanı

Çalışmada yer alan tüm gönüllü katılımcılara teşekkür ederiz.

Çıkar Çatışması Beyanı

Makalenin yazarları arasında, çalışma kapsamında herhangi bir kişisel ve finansal çıkar çatışması bulunmamaktadır.

Yazar Katkı Oranları:

Çalışma Dizaynı (Design of Study): SU (%40), İEH (%20), EÇÖ (%40)

Veri Toplama (Data Acquisition): İEH (%20), EÇÖ (%40)

İstatistiksel Analiz (Statistical Analysis): SU (%40), EÇÖ (%40)

Makalenin Hazırlanması (Preparation of the Article): SU (%40), İEH (%20), EÇÖ (%40)

KAYNAKLAR

- Abut, F., & Akay, M. F. (2015). Machine learning and statistical methods for the prediction of maximal oxygen uptake: recent advances. *Medical Devices (Auckland, NZ)*, 8, 369.
- Abut, F., Akay, M. F., George, J. (2016). Developing new $\text{VO}_{2\max}$ prediction models from maximal, submaximal and questionnaire variables using support vector machines combined with feature selection. *Comput Biol Med*, 79, 182-192. <https://doi.org/10.1016/j.combiomed.2016.10.018>
- Abut, F., Akay, M. F., Yıldız, I., & George, J. (2015). Performance comparison of different machine learning methods for prediction of maximal oxygen uptake from submaximal data. *Proceedings of the Eighth Engineering and Technology Symposium, Ankara, Turkey*.
- Akay, M. F., Özsert, G., George, J. (2014). Destek Vektör Makineleri Kullanılarak Submaksimal Verilerden Maksimum Oksijen Tüketiminin Tahmin Edilmesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 42-48.
- Akay, M. F., Zayid, E. I. M., Aktürk, E., & George, J. D. (2011). Artificial neural network-based model for predicting $\text{VO}_{2\max}$ from a submaximal exercise test. *Expert Systems with Applications*, 38(3), 2007-2010. <https://doi.org/10.1016/j.eswa.2010.07.135>

- Ashfaq, A., Cronin, N., & Müller, P. (2022). Recent advances in machine learning for maximal oxygen uptake (VO_{2max}) prediction: A review. *Informatics in Medicine Unlocked*, 100863.
- Balke, B., & Ware, R. W. (1959). An experimental study of physical fitness of Air Force personnel. *U.S. Armed Forces Med J* 10:675-688
- Beltrame, T., Amelard, R., Wong, A., & Hughson, R. L. (2017). Prediction of oxygen uptake dynamics by machine learning analysis of wearable sensors during activities of daily living. *Scientific reports*, 7(1), 1-8.
- Billinger, S. A., Van Swearingen, E., McClain, M., Lentz, A. A., & Good, M. B. (2012). Recumbent stepper submaximal exercise test to predict peak oxygen uptake. *Medicine and Science in Sports and Exercise*, 44(8), 1539.
- Borror, A., Mazzoleni, M., Coppock, J., Jensen, B. C., Wood, W. A., Mann, B., & Battaglini, C. L. (2019). Predicting oxygen uptake responses during cycling at varied intensities using an artificial neural network. *Biomedical Human Kinetics*, 11(1), 60-68.
- Bundy, M., & Leaver, A. (2012). *A Guide to Sports and Injury Management E-Book*. Elsevier Health Sciences.
- Cetin, E., Hindistan, I. E., & Ozkaya, Y. G. (2018). Effect of different training methods on stride parameters in speed maintenance phase of 100-m sprint running. *The Journal of Strength & Conditioning Research*, 32(5), 1263-1272.
- Chatzilazaridis, I., Panoutsakopoulos, V., & Papaiakevou, G. (2012). Stride characteristics progress in a 40-m sprinting test executed by male preadolescent, adolescent and adult athletes. *Biol Exerc* 8: 58-77.
- De Ruiter C, Verdijk PWL, Werker W, Zuidema MJ, & De Haan A. (2014). Stride frequency in relation to oxygen consumption in experienced and novice runners. *European Journal of Sport Science*, 14(3):251-258.
- George, J. D., Paul, S. L., Hyde, A., Bradshaw, D. I., Vehrs, P. R., Hager, R. L., & Yanowitz, F. G. (2009). Prediction of maximum oxygen uptake using both exercise and non-exercise data. *Measurement in Physical Education and Exercise Science*, 13(1), 1-12.
- Gutierrez Becker, B., Klein, T., Wachinger, C., Alzheimer's Disease Neuroimaging, I., the Australian Imaging, B., ve Lifestyle flagship study of, a. (2018). Gaussian process uncertainty in age estimation as a measure of brain abnormality. *Neuroimage*, 175, 246-258. <https://doi.org/10.1016/j.neuroimage.2018.03.075>
- Harrison, M., Brown, G., Cochrane, L. (1980). Maximal oxygen uptake: its measurement, application, and limitations. *Aviation, Space, and Environmental Medicine*, 51(10), 1123-1127.
- Heyward, V. H., & Kotarski, M. (1992). *Advanced Fitness Assessment and Exercise Prescription*, ed. 2. *Journal of Cardiopulmonary Rehabilitation and Prevention*, 12(6), 445
- Jalil, N. A., Hwang, H. J., Dawi, N. M. (2019). Machines learning trends, perspectives and prospects in education sector. *Proceedings of the 2019 3rd International Conference on Education and Multimedia Technology*,
- Jung, A. P. (2003). The impact of resistance training on distance running performance. *Sports Med*, 33(7), 539-552. <https://doi.org/10.2165/00007256-200333070-00005>
- Lakomy, H., ve Lakomy, J. (1993). Estimation of maximum oxygen uptake from submaximal exercise on a Concept II rowing ergometer. *Journal of sports sciences*, 11(3), 227-232.
- Quinonero-Candela, J., Rasmussen, C. E. (2005). A unifying view of sparse approximate Gaussian process regression. *The Journal of Machine Learning Research*, 6, 1939-1959.
- Rasmussen, C. E. (2003, February). Gaussian processes in machine learning. In *Summer school on machine learning* (pp. 63-71). Springer, Berlin, Heidelberg.
- Raj, J. S., & Ananthi, J. V. (2019). Recurrent neural networks and nonlinear prediction in support vector machines. *Journal of Soft Computing Paradigm (JSCP)*, 1(01), 33-40.
- Richter, C., O'Reilly, M., & Delahunt, E. (2021). Machine learning in sports science: challenges and opportunities. *Sports Biomechanics*, 1-7.
- Shandhi, M. M. H., Bartlett, W. H., Heller, J. A., Etemadi, M., Young, A., Plöt, T., & Inan, O. T. (2020). Estimation of instantaneous oxygen uptake during exercise and daily activities using a wearable cardio-electromechanical and environmental sensor. *IEEE Journal of Biomedical and Health Informatics*, 25(3), 634-646.
- Saunders, P. U., Pyne, D. B., Telford, R. D., & Hawley, J. A. (2004). Factors affecting running economy in trained distance runners. *Sports Med*, 34(7), 465-485. <https://doi.org/10.2165/00007256-200434070-00005>
- Silva, H. S. d., Nakamura, F. Y., Papoti, M., Da Silva, A. S., & Dos-Santos, J. W. (2021). Relationship between heart rate, oxygen consumption, and energy expenditure in futsal. *Frontiers in Psychology*, 2896.
- Sinirkavak, G., Dağ, U., & Çetinkaya, Ö. (2004). Elit sporcularda vücut kompozisyonu ile maksimal oksijen kapasitesi arasındaki ilişki. *Cumhuriyet Üniversitesi Tıp Fakültesi Dergisi*, 26, 171-176.

- Tartaruga, L. A., Dewolf, A. H., di Prampero, P. E., Fábrika, G., Malatesta, D., Minetti, A. E., ... & Zamparo, P. (2021). Mechanical work as a (key) determinant of energy cost in human locomotion: recent findings and future directions. *Experimental Physiology*, 106(9), 1897-1908.
- Uslu S., Çetin E. (2022). Farklı ağırlıklar ile yapılan squat sıçramanın makine öğrenme yöntemleri ile değerlendirilmesi, 5(1):1-12. <https://doi.org/10.38021/asbid.1071466>.
- Vapnik, V. (1999). *The nature of statistical learning theory*. Springer Science and Business Media.
- Williams, C. K., Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2). MIT press Cambridge, MA.
- Xu, M., Watanachaturaporn, P., Varshney, P. K., Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322-336.
- Yaprak, Y., Aslan, A. (2008). Üniversite Badminton Takımı Oyuncularının Kalp debisi, VO_{2max} ve solunum fonksiyon testlerinin Karşılaştırılması. *Sportmetre Beden Eğitimi ve Spor Bilimleri Dergisi*, 6(2), 69-74.