

Farklı Ağırlıklar ile Yapılan Squat Sıçramanın Makine Öğrenme Yöntemleri ile Değerlendirilmesi

Serkan USLU¹ , Emel ÇETİN ÖZDOĞAN² 

DOI: <https://doi.org/10.38021/asbid.1071466>

ORJİNAL ARAŞTIRMA

Öz

¹Akdeniz Üniversitesi, Tıp Fakültesi, Temel Tıp Bilimleri Bölümü,

Antalya/Türkiye

²Akdeniz Üniversitesi, Spor Bilimleri Fakültesi, Antalya/Türkiye

Kuvvet-Hız profili sporcunun performansının ve uygun olan antrenman programının belirlenmesi için hem antrenörler hem de araştırmacılar tarafından sıklıkla kullanılan bir test yöntemidir. Ancak test protokolünde sporcunun yüksek ağırlıklar ve çok sayıda tekrar yapması hem sporcu yaralanmasına hem de yorgunluk kaynaklı performansın doğru ölçülememesine sebep olmaktadır. Bu sebeple çalışma kapsamında farklı ağırlıklardaki sıçrama yüksekliğinin tek tekrarlı ölçüm verisi kullanılarak makine öğrenme modeller ile tahmin edilmesi amaçlanmıştır. Çalışmaya Akdeniz Üniversitesi Spor Bilimleri Fakültesi'nde öğrenim gören 52 sporcu katılmıştır. Tüm katılımcıların öncelikle demografik özellikleri ölçülmüş ardından dikey sıçrama protokolüne göre dört farklı ağırlıkta sıçrama yükseklikleri belirlenmiştir. Ölçülen veriler normalize edilerek makine öğrenme modellerine girdi olarak verilmiş ve dikey sıçrama yükseklikleri tahmin edilmiştir. Beş farklı makine öğrenme modeli arasında dikey sıçrama yüksekliğini en yüksek başarı ile tahmin eden makine öğrenme modeli Gaussian Süreç Regresyonu olduğu gözlenmiştir.

Anahtar kelimeler: Kuvvet-Hız Profili, Dikey Sıçrama, Makine Öğrenme

Sorumlu Yazar: Emel ÇETİN ÖZDOĞAN
emelcetin@akdeniz.edu.tr

Evaluation of Squat Jumping with Different Weights by Machine Learning

Abstract

The Force-Velocity profile is a test method that is frequently used by both trainers and researchers to determine the athlete's performance and the appropriate training program. However, performing a large number of repetitions under high weights in the test protocol causes both athlete injury and failure to measure performance due to fatigue. For this reason, within the scope of the study, it is aimed to predict the jump height at different weights with machine learning models using single repetitive measurement data. 52 athletes studying at Akdeniz University, Faculty of Sports Science participated in the study. First of all, demographic characteristics of all participants were measured, and then jump heights were determined at four different weights according to the vertical jump protocol. The measured data were normalized and given as input to the machine learning models and the vertical jump heights were estimated. It has been observed that the machine learning model that predicts the vertical jump distance with the highest success among the five different machine learning models is the Gaussian Process Regression.

Keywords: Force-Velocity Profile, Vertical Jump, Machine Learning

Yayın Bilgisi

Gönderi Tarihi:
10.02.2022

Kabul Tarihi:
26.02.2022

Online Yayın Tarihi:
28.02.2022

Giriş

Kuvvet-hız (F-V) profili oluşturma yöntemi, sporcunun bireysel antrenman programının oluşturulmasında (Jiménez-Reyes vd., 2017) ya da bir antrenman programının etkinliğinin değerlendirilmesinde (Colyer vd., 2018) sıklıkla kullanılmaktadır. Bu profil oluşturma kavramı, iskelet kaslarının temel özelliği olan kuvvet ve hız parametreleri arasındaki ters ilişkiye dayanır (Samozino, 2018). Çok eklemlili hareketlerde, F-V ilişkisi genellikle doğrusal tanımlanırken, izole kaslarda veya tek eklemlili hareketlerde ise hiperbolik olarak tanımlanmaktadır (Alcazar vd., 2019; Alcazar vd., 2021). Eğrinin daha dik olması sporcunun düşük hızlarda yüksek kuvvet üretmede daha iyi olduğunu, eğrinin daha az dik olması ise sporcunun düşük kuvvette daha yüksek hız üretmede daha iyi olduğunu gösterir (Jaric, 2015; Jiménez-Reyes vd., 2017). F-V profili genellikle sprint ve dikey sıçrama performansları (squat jump (SJ)) ile belirlenmektedir.

Uygulamada, dikey sıçrama veya benzeri çok eklemlili hareketler sırasında F-V profili oluşturulurken, sporculardan farklı yüklerle karşı maksimum performans, göstermeleri istenir. Bunun için, yüksüz durum da dahil olmak üzere toplam 5 ya da 6 farklı harici yük ile sıçrama yapılmalıdır (Zivkovic vd., 2017). Farklı yüklerle yapılan sıçrama sayısı ne kadar azsa, mekanik çıktılarının potansiyel ölçüm hatalarına duyarlılığı o kadar yüksek olur (Morin vd., 2018). Uygulama sırasında her denemenin en az iki kere tekrar edilmesi gerektiği, bu denemelerin birbirinden çok farklı olması durumunda sporcunun başka bir deneme yapması gerektiği protokolda belirtilmiştir. Yükler vücut kütlelerinin yüzdelik değerlerinde veya mutlak değerlerde olabilir (Samozino vd., 2014; Samozino vd., 2008). Uygulama sırasında en yüksek yük kuvvet antrenmanına aşına olmayan sporcular için vücut kütlelerinin %75'i, diğerleri için vücut kütlelerinin %100'ü kadardır (Morin vd., 2018). Ayrıca deneme sonunda elde edilen sıçrama yüksekliğinin 8-10 cm den az olma durumunda geçerli olmayacağı ve tekrarlanması gerektiği düşünüldüğünde, tekrar sayısının ve harici yüklerin artması sporcunun yaralanma riskini de beraberinde getirmektedir.

Literatürde farklı ağırlıklar ile yapılan dikey sıçrama protokolleri incelendiğinde arttırılan ağırlıkla ilişkili olarak akut kas hasarının oluştuğu gösterilmiştir (Falvo ve Bloomer, 2006). Bu durumun en belirgin özelliği kasta oluşan hasara bağlı olarak kuvvet kaybının oluşmasıdır (Eston vd., 2003; Page, 1995). Kuvvet kaybı, hasarın geri dönüşümlü ya da kalıcı olduğunun belirlenmesi, hasarın büyüklüğünün belirlenmesi açısından hem klinik hem de sporcu performansı açısından farklı ölçüm parametreleri ile değerlendirilen önemli bir çıktıdır (Eston vd., 2003; Uslu vd., 2018). Bunun dışında yüksek ağırlıklar ile dikey sıçrama yapılmasının kasın intrensek özelliklerinde de hasara yol açabildiği gösterilmiştir (Powers ve

Jackson, 2008). Byren ve Eston tarafından yapılan çalışmada vücut ağırlığının %70' i değerlere çıkıldığında kreatin kinaz seviyesinin ertesi gün %600' e kadar çıktığını ve normal seviyeye geri dönmesinin yedi günü bulabildiği gösterilmiştir (Byrne ve Eston, 2002; Eston vd., 2003). Bu sırada sporcudan testin devamlılığı için yeni bir ölçüm alınsa bile ölçümün gerçek performansı yansıtmayacağı başka çalışmalarda da gösterilmiştir (Kotani vd., 2021).

Makine öğrenmesi yöntemi klasik istatistiksel yöntemlere kıyasla non-lineer yaklaşım sunması sebebiyle birçok veride paterni tanıma amaçlı sıklıkla kullanılmaktadır (Jalil vd., 2019). Spor bilimlerinde performans tahmini, branş belirlenmesi, yaralanma riskinin belirlenmesi gibi farklı amaçlar ile son yıllarda yaygın olarak kullanılmaya başlanmıştır (REF). Lineer regresyon (LF) girdi verisi ile oluşturduğu matematiksel ilişki ile çıktı verisinin tahmini sebebiyle makine öğrenmenin temelleri arasında yer almaktadır. Ancak bu yaklaşımın sadece girdi verisi ile çıktı verisi arasında doğrusal bir ilişki olduğunda başarılı sonuç vermesi sebebiyle birçok problemde yeterli gelmemektedir. Destek vektör makinesi (DVM), makine öğrenme yöntemlerinin kullanımının artmasında büyük gelişme sağlayan yenilikçi bir yaklaşımdır. Temel çıkış noktası verilerin kümeleneşine bağlı olarak farklı kümelerdeki verilerin uç noktalarını belirleyip bu veriler arasında bir düzlem oluşturmasına dayanır. Oluşturulan bu düzleme uzaklıkların tanımlanması için destek vektörleri tanımlanmakta ve bu sayede verinin hangi sınıfa ait olduğu belirlenmektedir (Vapnik, 1999; Vapnik ve Chapelle, 2000). Gauss süreç regresyonu (GSR), klasik istatistiksel yaklaşımdan aşına olunan kavramların farklı modülasyon yöntemleri ile kullanımını sağlayan ve veri sayısının göreceli olarak az olduğu işlemlerde oldukça başarılı sonuç sağlayan bir yöntemdir (Gutierrez Becker vd., 2018). Karar Ağaçları (KA) temel olarak seçim yapma sürecine bağlı olarak geliştirilen makine öğrenme yöntemleridir. Verinin rastgelelik derecesini düşürmeyi yani verideki örüntüyü tespit etmek amacıyla seçim yaparak bilgi kazancını maksimuma çıkarmayı hedeflerler. Her karar verme sürecinde hata fonksiyonu tekrar hesaplanır ve en düşük hataya sahip kestirim noktası tespit edilir (Xu vd., 2005). Yapay Sinir Ağları (YSA), insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşısı sonucu ortaya çıkan bilgisayar sistemleridir.

F-V profili oluşturmak son yıllarda hem araştırmacılar hem de antrenörler arasında uygulanabilirliği açısından oldukça pratik olduğu için popülerlik kazanmıştır. Ancak dikey sıçrama sırasında uygulanan prosedürleri nedeniyle uygulamanın pratikliğini ve kasta oluşabilecek yaralanmalardan dolayı testin tamamlanması, tamamlansa da gerçek performansı yansıtmayı yansıtmayacağı testi zorlaştırmakta ve güvenilirliğini etkilemektedir (Kotani vd., 2021). Bu sebeple çalışma kapsamında sporcunun tek seferde yapabildiği sıçrama yüksekliği

hesaplanarak makine öğrenme yöntemleri ile farklı ağırlıklardaki sıçrama yüksekliğinin belirlenmesi amaçlanmıştır. Çalışmanın yüksek ağırlıklar ile yapılan tekrar sayısını azaltarak sporcu yaralanmasının önüne geçme ve F-V eğrisinin daha güvenli elde edilebilmesine katkı sağlaması beklenmektedir.

Gereç ve Yöntem

Araştırma Grubu

Araştırmaya Akdeniz Üniversitesi Spor Bilimleri Fakültesi'nde öğrenim gören 52 sporcu katılmıştır. Katılımcıların özellikleri Tablo-1'de gösterilmiştir. 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 (KA EK-942) tüm araştırmacılar Helsinki bildirisini kabul etmişlerdir.

Tablo 1

Katılımcıların Demografik ve Kinematik Özellikleri

Girdi Özellikleri	Ortalama \pm SEM
Yaş	19.65 \pm 0.07 (yıl)
Boy	171.77 \pm 0.51 (cm)
Bacak Boyu	111.54 \pm 0.42 (cm)
İtme Mesafesi	0.54 \pm 0.008 (cm)
Kas Kütlesi	48.24 \pm 0.52 (kg)
Ağırlık	82.46 \pm 1.26 (kg)

Veri Toplama Yöntemi

Çalışmada ilk olarak katılımcıların boy, ağırlık ve antropometrik ölçümleri alınmıştır. Bunun ardından 15 dakikalık genel ısınma hareketleri uygulandı. Son olarak F-V profillerinin belirlenmesi için ölçüm protokolü uygulanmıştır. Bu aşamada, 4 farklı ek yük ile birlikte (vücut ağırlığının %0, %10, %40 ve %60) sıçrama yükseklikleri SJ sırasında belirlendi. SJ öncesi katılımcılara uygun pozisyonda, sıçrama bölgesinin tam ortasında durarak sıçrama gerçekleştirmeleri söylendi. Dikey sıçrama performansı (havada kalış süresi, sıçrama yüksekliği) My Jump 2 uygulaması ile belirlendi.

Sadece vücut ağırlığının kullanıldığı durumda, test edilen tüm yükler için aynı deney konfigürasyonlarını uygulamak için 0,5 kg'lık bir çubuk kullanıldı. Katılımcılar, her bir yükte 2 deneme gerçekleştirdi, aralarındaki atlama yüksekliğinde %10 fark olması halinde üçüncü sıçrama yapıldı (Giroux vd., 2015). Ek yük kullanılarak yapılan SJ sırasında ise ellerin barda olması ve tüm hareket boyunca aynı kalması istendi. Katılımcıların SJ başlangıç pozisyonlarını (~ 90 ° diz açısı) yaklaşık 2 saniye boyunca tutmaları ve daha sonra mümkün olan en hızlı


şekilde kuvvet uygulayıp maksimum yüksekliğe sıçraması istendi (Samozino vd., 2014). Sıçrama sırasında yere karşı kuvvet uygulayarak sıçramaları engellendi. Bu şartlara uyulmadığı anda sıçrama tekrar edildi. Her bir yük ile yapılan sıçrama denemeleri arasında toparlanma için 2 dakika, farklı yük denemeleri arasında üç gün dinlenme verildi.

F-V ilişkileri, her bir yüklenme için en iyi denemeleri ve en küçük kareler lineer regresyon eşitliği kullanılarak belirlendi. F-V eğrisi, kuvvet ve hız eksenini ile kesişim noktalarına tekabül eden F_0 ve V_0 'ı elde etmek için ekstrapolasyona tabi tutuldu. F-V eğrisinin eğimi F_0 ve V_0 'dan hesaplandı (Samozino vd., 2014).

Makine Öğrenme Modelleri

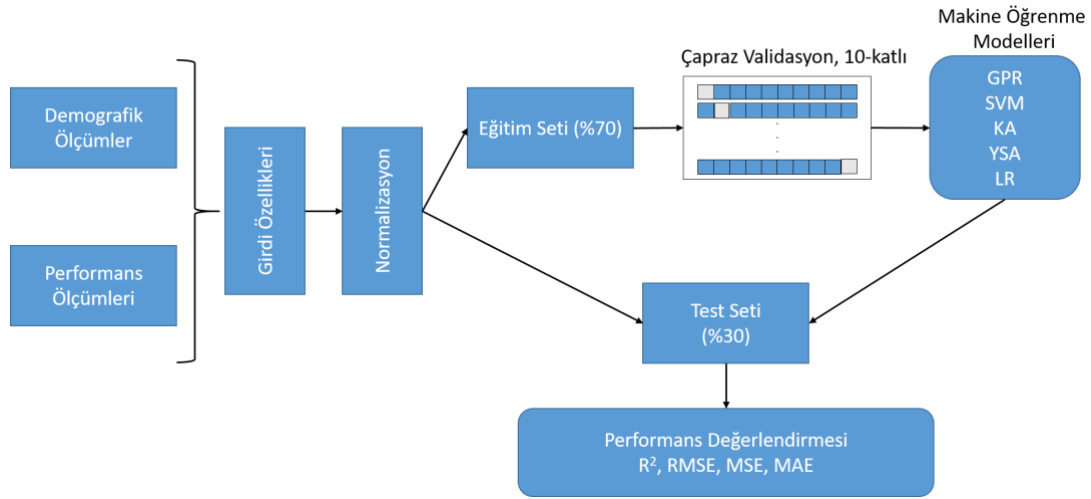
Çalışmada farklı ağırlık yüklerinde sıçrama yüksekliğinin belirlenmesi için beş farklı makine öğrenmesi modeli (Temel Lineer Regresyon, Karar Ağaçları, Destek Vektör Makineleri, Gauss Süreç Regresyonu, Yapay Sinir Ağları) kullanılmıştır. Kullanılan makine öğrenme yöntemlerinin girdi verisine uyguladığı matematiksel yaklaşım açısından farklılıkları ve benzerlikleri bulunmaktadır.

Çalışmada öncelikle ölçülen antropometrik özellikler ve hesaplanan kinematik özellikler belirlenmiştir. Toplamda 209 farklı sıçrama ve her sıçrama için 5 farklı özellikten oluşan bu matris (209x5) makine öğrenme modelleri için girdi özelliklerini yansıtmaktadır. Bunun ardından verilerin birim ağırlıklarının modellerde hatalı ağırlık yönlendirmesine sebep olmaması için tüm girdi verileri normalize edilmiştir. Normalize edilen verilerin dağılımları Şekil 1'de gösterilmiştir.



Şekil-1 Makine öğrenme modelleri girdilerinin normalize edilmiş gösterimi.

Makine öğrenme modellerinde temel prensip öğrenme seti ve test seti şeklinde verilerin ayrılması, öğrenme verileri ile kurulan modelin hiç görmediği test verilerinde başarısının denemesidir. Bu sebeple verilerin %70'i eğitim için (n=147), %30'u validasyon için (n=62) rastgele olacak şekilde ayrılmıştır. Bunun ardından oluşturulacak modelin eğitim verisine fazla uymasının (overfitting) önüne geçilmesi için eğitim setinde 10 katlı çapraz doğrulama kullanılmıştır. Çapraz doğrulamada belirlenen kat sayısına göre eğitim seti bölünmektedir. 10 katlı çapraz doğrulamada 10 eş sayıda parçaya ayrılan verinin 9 eş parçası eğitim modelinin temel ağırlıklarını belirlemek, kalan eş parçası ise bu ağırlıkların düzeltilmesinde kullanılmaktadır. Bu sayede modelin tek bir veri parçası üzerinden fazla öğrenmeye yol açması engellenmektedir. Yapılan tüm bu işlemler Şekil-2' de gösterilmiştir. Tüm analizler MATLAB programında gerçekleştirilmiştir.



Şekil-2 Çalışma kapsamında yapılan analizlerin şematik gösterimi

İstatiksel Analiz

Çalışmada makine öğrenme modeline sunulan girdi verileri aritmetik ortalama ve standart sapma ile değerlendirilmiştir. Tüm ağların başarıları gerçek veri ve tahmin edilen veri arasındaki sırasıyla Denklem 1- 4'te verilen korelasyon (R^2) ve kök ortalama kare hatası (RMSE), ortalama mutlak hata (MAE), ortalama kare hata (MSE) eşitlikleri ile kıyaslanmıştır.

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

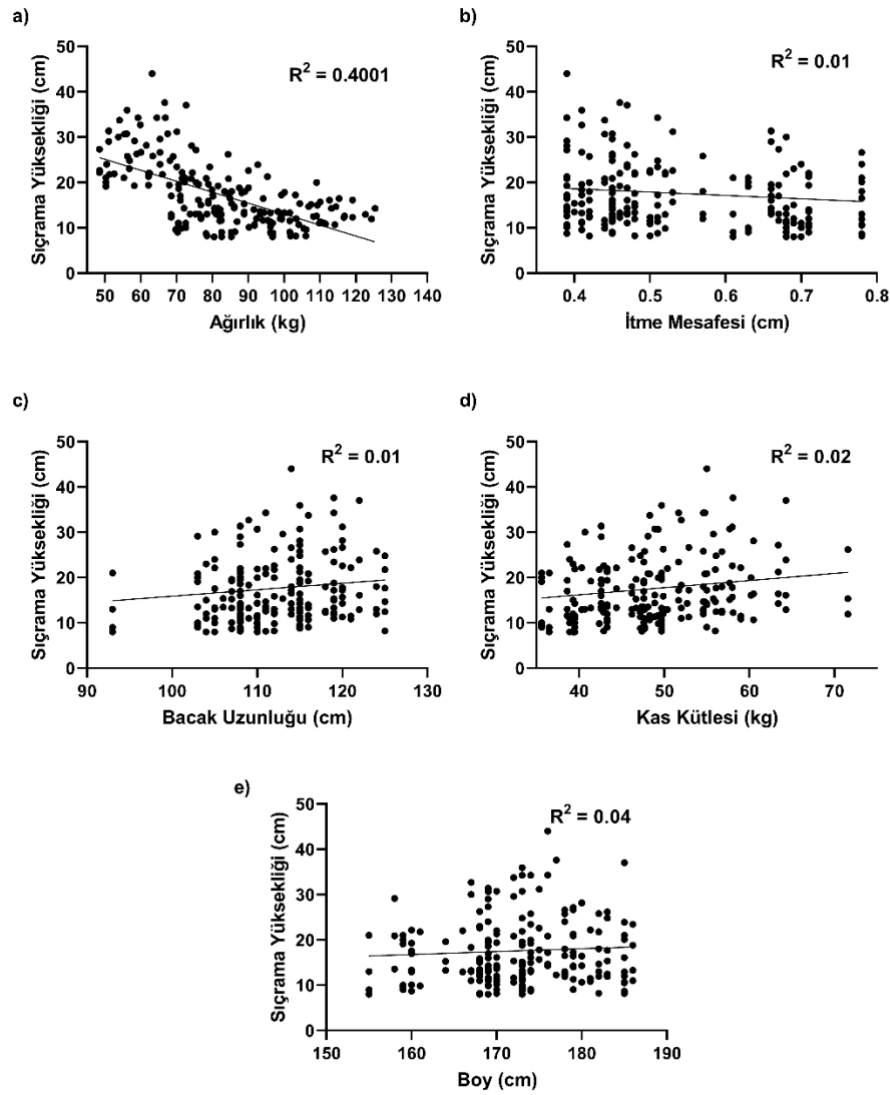
$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad \text{Denklem - 2}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad \text{Denklem - 3}$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad \text{Denklem - 4}$$

Bulgular

Çalışma kapsamında ilk adım olarak sıçrama yüksekliğinde önemli olarak kabul edilen parametreler ile sıçrama yüksekliği arasındaki ilişki korelasyon analizi ile incelenmiştir. Sıçrama yüksekliği, ağırlık ile zayıf kabul edilse de diğer parametrelere kıyasla daha iyi korelasyon göstermektedir. Bunun dışındaki parametreler ile gösterdiği korelasyon ise yok kabul edilebilecek kadar düşüktür. Tüm parametrelerin sıçrama yüksekliği ile korelasyonları ve veri dağılımları Şekil-3' de gösterilmiştir. Bu sonuçlar sıçrama yüksekliğinin tek bir parametre ile tahmin edilmesinin oldukça zor olduğunu, kompleks bir model ile tüm parametrelerin birlikte değerlendirilmesinin gerekliliğini göstermektedir.



Şekil-3 Girdi verileri ile sıçrama yüksekliği arasındaki korelasyon ilişkisi

Makine öğrenme modellerinde daha önce belirtildiği üzere verinin %70'i eğitim, %30'u ise test için ayrılmıştır. Eğitim ve test denemelerinde modellerin hata oranları MSE, RMSE ve MAE parametreleri ile modelin başarısı ise R2 ile değerlendirilmiştir. Ayrıca hata oranı parametreleri eğitim ve test denemeleri için karşılaştırılmıştır. Bu sayede modelin sadece verinin belirli kısmına özelleşmediği, tüm veriye uygun bir model olduğu incelenmiştir. Elde edilen sonuçlar tüm makine öğrenme modellerinde eğitim ve test denemeleri arasında anlamlı bir farklılık olmadığını, hata oranlarının eğitim ve test sırasında birbirine oldukça yakın olduğunu göstermektedir. Bu sonuçlar modellerde yalnızca eğitim setine özgü fazla öğrenme (overfitting) olmadığını önemli bir göstergesidir. Tablo 2' de beş farklı model için eğitim ve test sırasında MSE, RMSE ve MAE parametrelerinin değerlerini göstermektedir.

Tablo 2

Makine Öğrenme Modellerinin Eğitim ve Test Setlerindeki Hata Oranları

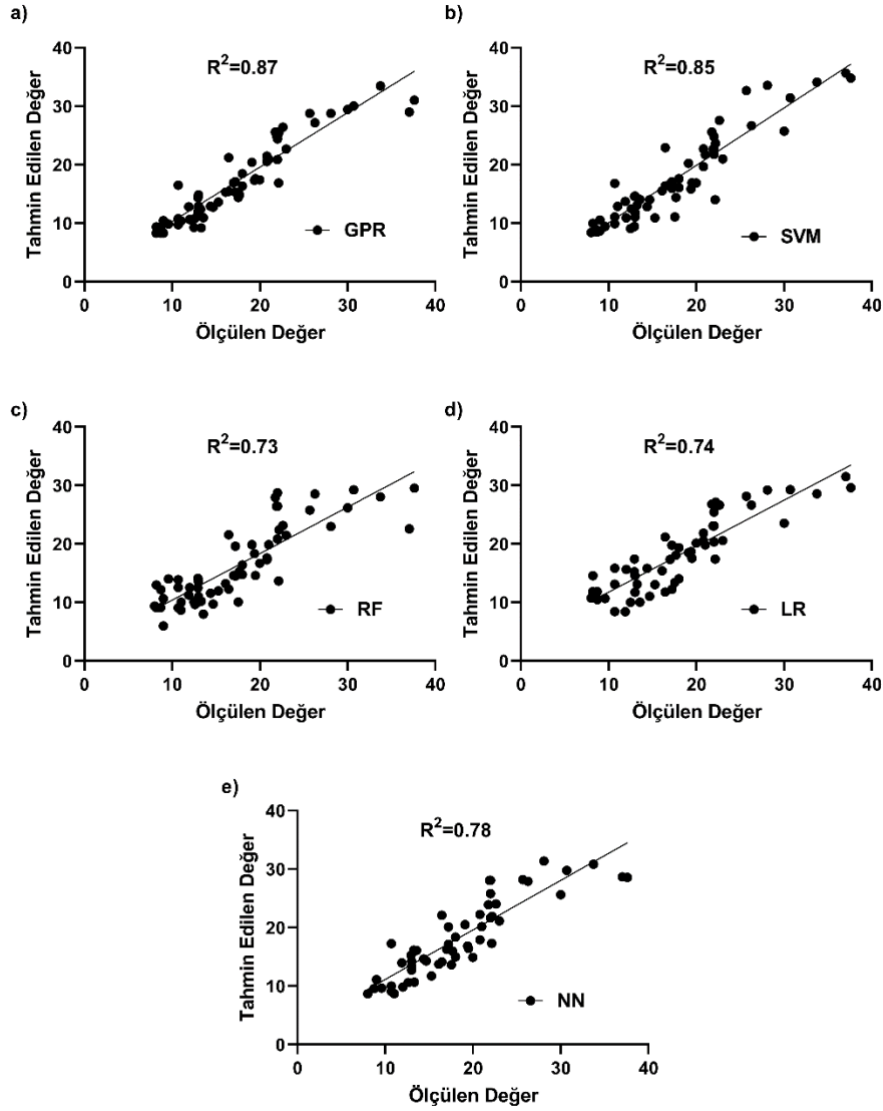
	MSE		RMSE		MAE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
GPR	0.003	0.003	0.062	0.059	0.047	0.044
SVM	0.004	0.004	0.070	0.065	0.053	0.047
LR	0.007	0.007	0.084	0.085	0.070	0.070
RF	0.005	0.007	0.077	0.088	0.058	0.070
YSA	0.007	0.006	0.085	0.077	0.061	0.060

Modeller kendi aralarında kıyaslandığında ise en yüksek başarı GPR modelinde elde edilmiştir. GPR yöntemi ile oluşturulan model hem eğitim hem de test verilerinde yüksek başarı oranı ile sıçrama yüksekliğini tahmin edebilmiştir ($R^2=0.87$). SVM modeli GPR modeline oldukça yakın başarı oranı ile sıçrama yüksekliğini tahmin etmiştir ($R^2=0.85$). Diğer modeller ise korelasyon analizlerine kıyasla yüksek başarı elde etseler de GPR ve SVM modellerine göre başarı oranları daha düşük kalmıştır. Test verilerinde en düşük başarı oranı RF makine modelinde görülmüştür ($R^2=0.73$). Tüm modellerin hem eğitim hem de test veri seti için başarı oranları Tablo-3’de belirtilmiştir. Test veri setindeki ölçülen ve model tarafından tahmin edilen tüm verilerin dağılımı ve korelasyon başarısı Şekil-4’ de gösterilmiştir.

Tablo 3

Makine Öğrenme Modellerinin Eğitim ve Test Setlerinde Başarı Oranları

	R^2	
	Eğitim	Test
GPR	0.87	0.87
SVM	0.83	0.85
LR	0.75	0.74
RF	0.79	0.73
YSA	0.75	0.78



Şekil-4 Her bir makine öğrenme modelinin test setindeki tahminleri ve ölçülen gerçek değerler ile karşılaştırılması

Tartışma ve Sonuç

Çalışmada öncelikli olarak makine öğrenme modellerine girdi olarak sunulacak parametreler ile çıktı arasındaki ilişki incelenmiştir. Buradaki amaç eğer tek bir parametrenin sıçrama yüksekliği ilişkisi iyi bir korelasyon gösteriyorsa kompleks işlemler olan makine öğrenme modelleri yerine daha basit çözümlerle sıçrama yüksekliğinin tahmin edilebileceğini test etmektir. Ancak sıçrama yüksekliğinin en yüksek korelasyonu gösterdiği ağırlık parametresi bile oldukça zayıf bir korelasyon değerine sahiptir. Bu durum sıçrama yüksekliğinin farklı parametrelerin birleşimi ile oluştuğunu ve bu ilişkinin doğrusal olmadığı için daha kompleks çözüm önerilinin gerekli olduğunu göstermiştir.

Farklı makine öğrenme modelleri kullanıldığında yüksek başarı ile sıçrama yüksekliğinin tahmin edilebildiği görülmüştür. KA, LR ve YSA yöntemleri GPR ve SVM yöntemlerine göre daha düşük başarı oranlarına sahiptir. KA ve LR' nin daha düşük başarıya sahip olması girdi verileri ile çıktı verisi arasındaki ilişkinin kompleks ilişki ve dağılımın non-parametrik olmasıyla ilişkili olabilir. YSA yöntemi birçok tahmin modelinde oldukça yüksek başarı oranına sahiptir (Musa vd., 2019). Çalışmada GPR ve SVM' ye göre daha düşük başarı göstermesinin sebebi girdi veri setinin göreceli olarak az sayıda olmasından kaynaklı olabilir. Özellikle GPR modelinin girdi sayısının daha az olduğu veri setlerinde daha iyi başarıya sahip olduğu farklı çalışmalarda gösterilmiştir (Gutierrez Becker vd., 2018; Williams ve Rasmussen, 2006).

Sonuç olarak çalışma kapsamında farklı ağırlıklardaki sıçrama yüksekliğinin tek tekrar yaparak tahmin edilebilmesi için makine öğrenme modelleri geliştirilmiş ve birbirlerine olan üstünlükleri, zayıflıkları gösterilmiştir. Elde edilen sonuçlar makine öğrenme modellerinin yüksek başarı oranı ile farklı ağırlıklardaki sıçrama yüksekliğini tahmin edebildiğini göstermektedir. Çalışmanın literatüre dikey sıçrama testinde kullanılan yüksek ağırlık kaynaklı sporcu yaralanmalarının önüne geçilmesi ve F-V eğrisinin daha güvenli elde edilebilmesi için gerekli olan farklı ağırlık değerlerinde sıçrama yüksekliğini belirlenerek daha iyi F-V eğrisinin elde edilmesi konularında katkı sağlaması beklenmektedir.

Kaynakça

- Alcazar, J., Csapo, R., Ara, I., & Alegre, L. M. (2019). On the shape of the force-velocity relationship in skeletal muscles: The linear, the hyperbolic, and the double-hyperbolic. *Frontiers in physiology*, 769.
- Alcazar, J., Pareja-Blanco, F., Rodriguez-Lopez, C., Navarro-Cruz, R., Cornejo-Daza, P. J., Ara, I., & Alegre, L. M. (2021). Comparison of linear, hyperbolic and double-hyperbolic models to assess the force-velocity relationship in multi-joint exercises. *European Journal of Sport Science*, 21(3), 359-369.
- Byrne, C., & Eston, R. (2002). The effect of exercise-induced muscle damage on isometric and dynamic knee extensor strength and vertical jump performance. *Journal of Sports Sciences*, 20(5), 417-425.
- Colyer, S. L., Stokes, K. A., Bilzon, J. L., Holdcroft, D., & Salo, A. I. (2018). Training-related changes in force-power profiles: implications for the skeleton start. *International Journal of Sports Physiology and Performance*, 13(4), 412-419.
- Eston, R., Byrne, C., & Twist, C. (2003). Muscle function after exercise-induced muscle damage: Considerations for athletic performance in children and adults. *Journal of Exercise Science and Fitness*, 1(2), 85-96.
- Falvo, M. J., & Bloomer, R. J. (2006). Review of exercise-induced muscle injury: relevance for athletic populations. *Research in Sports Medicine*, 14(1), 65-82.
- Giroux, C., Rabita, G., Chollet, D., & Guilhem, G. (2015). What is the best method for assessing lower limb force-velocity relationship? *International Journal of Sports Medicine*, 36(02), 143-149.
- Gutierrez Becker, B., Klein, T., Wachinger, C., Alzheimer's Disease Neuroimaging, I., the Australian Imaging, B., & 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>

- 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,
- Jaric, S. (2015). Force-velocity relationship of muscles performing multi-joint maximum performance tasks. *International Journal of Sports Medicine*, 36(09), 699-704.
- Jiménez-Reyes, P., Samozino, P., Brughelli, M., & Morin, J.-B. (2017). Effectiveness of an individualized training based on force-velocity profiling during jumping. *Frontiers in Physiology*, 677.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kotani, Y., Lake, J., Guppy, S. N., Poon, W., Nosaka, K., Hori, N., & Haff, G. G. (2021). Reliability of the Squat Jump Force-Velocity and Load-Velocity Profiles. *Journal of Strength and Conditioning Research*.
- Markus, I., Constantini, K., Hoffman, J., Bartolomei, S., & Gepner, Y. (2021). Exercise-induced muscle damage: Mechanism, assessment and nutritional factors to accelerate recovery. *European Journal of Applied Physiology*, 121(4), 969-992.
- Morin, J.-B., Jiménez-Reyes, P., Brughelli, M., & Samozino, P. (2018). Jump height is a poor indicator of lower limb maximal power output: theoretical demonstration, experimental evidence and practical solutions. <https://doi.org/10.31236/osf.io/6nxyu>
- Musa, R. M., Majeed, A. A., Taha, Z., Abdullah, M., Maliki, A. H. M., & Kosni, N. A. (2019). The application of Artificial Neural Network and k-Nearest Neighbour classification models in the scouting of high-performance archers from a selected fitness and motor skill performance parameters. *Science & Sports*, 34(4), e241-e249.
- Page, P. (1995). Pathophysiology of acute exercise-induced muscular injury: clinical implications. *Journal of Athletic Training*, 30(1), 29.
- Powers, S. K., & Jackson, M. J. (2008). Exercise-induced oxidative stress: cellular mechanisms and impact on muscle force production. *Physiological Reviews*, 88(4), 1243-1276.
- 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.
- Samozino, P. (2018). A simple method for measuring lower limb force, velocity and power capabilities during jumping. In *Biomechanics of Training and Testing*: 65-96. Springer.
- Samozino, P., Edouard, P., Sangnier, S., Brughelli, M., Gimenez, P., & Morin, J.-B. (2014). Force-velocity profile: imbalance determination and effect on lower limb ballistic performance. *International Journal of Sports Medicine*, 35(06), 505-510.
- Samozino, P., Morin, J.-B., Hintzy, F., & Belli, A. (2008). A simple method for measuring force, velocity and power output during squat jump. *Journal of Biomechanics*, 41(14), 2940-2945.
- Uslu, S., Nüzket, T., & Uysal, H. (2018). Modified motor unit number index (MUNIX) algorithm for assessing excitability of alpha motor neuron in spasticity. *Clinical Neurophysiology Practice*, 3, 127-133.
- Vapnik, V. (1999). *The nature of statistical learning theory*. Springer science & business media.
- Vapnik, V., & Chappelle, O. (2000). Bounds on error expectation for support vector machines. *Neural Computation*, 12(9), 2013-2036. <https://doi.org/Doi.10.1162/089976600300015042>
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning*. 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.
- Zivkovic, M. Z., Djuric, S., Cuk, I., Suzovic, D., & Jaric, S. (2017). A simple method for assessment of muscle force, velocity, and power producing capacities from functional movement tasks. *Journal of Sports Sciences*, 35(13), 1287-1293.