

Makine öğrenmesi ile kinematik veriden serebral palsili hastaların yürüyüş karakteristiğinin analizi

Mustafa Erkam ÖZATEŞ^a, Sebastian Immanuel WOLF^b, Yunus Ziya ARSLAN^c

ÖZET

Amaç: Serebral palsy (SP), nöromotor fonksiyon bozuklarına dayanan bir rahatsızlıktır ve özellikle yürüme kinematiğini etkileyebilir. SP'li hastaların hareket yeteneklerini iyileştirmek için kişiye özgü değerlendirmelere ihtiyaç vardır. Bu değerlendirmeler için laboratuvarlarda kullanılan yer tepki kuvveti (YTK) ölçümleri, SP hastalarının tedavisinde önemli bir rol oynar. Ancak YTK'nin doğal yürüyüş sırasında ölçülmesi zor ve donanım gerektirdiği için maliyetlidir. Bu çalışmada SP'li hastaların YTK'lerini kuvvet platformlarına ihtiyaç duymadan tahmin etmek için makine öğrenimi kullanılarak SP hastalarının yürüyüş analizi için yeni bir yaklaşım sunulmaktadır. **Yöntem:** Araştırma, 40 sağlıklı birey ve 40 SP hastasının yürüme verisi kullanılmıştır. İlk olarak, bir boyutlu konvolüsyonel sinir ağına (CNN) girdi olarak kullanılan kinematik veriler aracılığıyla sağlıklı ve SP'li bireylerin sınıflandırılabilirliği için bir model geliştirilmiştir. Ardından, SP'li hastaların kinematik verileri ikinci bir CNN modeline beslenerek YTK tahmin edilmiştir. **Bulgular:** SP hastalarının ve sağlıklı bireylerin yüksek doğruluk oranlarıyla (%98) sınıflandırılabilirliği sağlanmıştır. Ayrıca, SP'li hastalarda YTK, %13.3'lük (± 5.1) normalize edilmiş ortalama karesel hata ve 0.88'lik $\pm (0.07)$ Pearson korelasyon katsayısı oranları ile kestirilebilmiştir. Bu sonuçlar, laboratuvar ortamında YTK ölçümü yapılamayan hastalar için önemlidir. **Sonuç:** Bu çalışmada, SP hastalarının tedavisinde kullanışlı ve hızlı bir hareket analizi yöntemi sunulmuş ve SP hastalarının tedavi süreçlerini geliştirmeye yardımcı olacak bir yöntem uygulanmıştır. Bununla birlikte çalışmadan elde edilen sonuçların klinik karar verme süreçleri açısından hataya yer bırakmayacak bir dikkatle ele alınması gerekmektedir.

Anahtar Kelimeler: Yürüme analizi, makine öğrenmesi, serebral palsy

Analyzing the walking characteristics of cerebral palsy patients from kinematic data using machine learning

ABSTRACT

Objective: Cerebral palsy (CP) is a condition based on neuromotor impairments that can particularly affect walking kinematics. Individualized assessments are necessary to improve the movement abilities of CP patients. Measurements of ground reaction forces (GRF) used in laboratories for these assessments play a significant role in the treatment of CP patients. However, measuring GRF during natural walking is challenging and costly due to equipment requirements. This study introduces a new approach for analysing the walking of CP patients by using machine learning to estimate their GRFs without the need for force platforms. **Method:** The research utilized walking data from 40 healthy individuals and 40 CP patients. Initially, a model was developed using kinematic data as input into a one-dimensional convolutional neural network (CNN) to classify healthy individuals and those with CP. Subsequently, the kinematic data of CP patients were fed into a second CNN model to predict GRFs. **Results:** The classification of CP patients and healthy individuals was achieved with high accuracy (98%). Additionally, GRFs in CP patients could be estimated with a normalized mean squared error of 13.3% (± 5.1) and a Pearson correlation coefficient of 0.88 (± 0.07). These results are crucial for patients where GRF measurement in a laboratory setting is not feasible. **Conclusion:** This study presents a useful and rapid movement analysis method for the treatment of CP patients, aiming to improve their treatment processes. However, it's important to handle the results obtained from the study with careful consideration to avoid errors in clinical decision-making processes.

Keywords: Gait analysis, machine learning, cerebral palsy

Geliş Tarihi: 09.10.2023

Kabul Tarihi: 15.11.2023

^aTürk-Alman Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, İstanbul, Türkiye, e-posta: ozates@tau.edu.tr ORCID: 0000-0002-7657-2764

^bOrthopädische Universitätsklinik Heidelberg Schlierbacher Landstr, Heidelberg, Almanya e-posta: sebastian.wolf@med.uni-heidelberg.de ORCID: 0000-0003-3921-6629

^cTürk-Alman Üniversitesi, Fen Bilimleri Enstitüsü, Robotlar ve Akıllı Sistemler Anabilim Dalı, İstanbul, Türkiye e-posta: yunus.arslan@tau.edu.tr ORCID: 0000-0002-1861-9368

Sorumlu Yazar/Correspondence: Mustafa Erkam Özateş e-posta: ozates@tau.edu.tr

Atıf/Citation: Özateş ME, Wolf SI, Arslan YZ. Makine öğrenmesi ile kinematik veriden serebral palsili hastaların yürüyüş karakteristiğinin analizi. Sağlık ve Yaşam Bilimleri Dergisi 2023;5(3):146-152.

GİRİŞ

Serebral palsi (SP), yani beyin felci, insan nöromotor fonksiyonlarını etkileyen bir grup rahatsızlığa verilen isimdir. SP, iskelet kaslarının davranışını, tonusunu ve vücudun duruşunu etkilemektedir ve bu sebeple insanda ciddi hareket bozukluklarına yol açmaktadır. Ortaya çıkan patoloji kişiye özeldir ve uygulanacak tedavinin belirlenmesi için kişiye özgü değerlendirmenin yapılması zorunludur¹

Yürüme analizi laboratuvarı bulunan kliniklerde kaydedilebilen kinematik ve kinetik hareket verisi yardımıyla SP'nin değerlendirilmesi, izlenmesi ve tedavisi objektif bir yaklaşımla gerçekleştirilebilmektedir. Kaydedilen yürüme verisi içerisinde bulunan yer tepki kuvveti (YTK) ve bu veri kullanılarak hesaplanan alt ekstremitte eklem momentleri, SP'li bireyin yürüme karakteristiğinin tespit edilmesinde çok önemli kinetik parametrelerdir.¹⁻⁵ Yer tepki kuvveti (YTK) ve eklem momentleri dengeli ve kararlı bir yürüme davranışının tespiti ve eklem hareketi sırasında kasların aktif ve pasif olma durumları hakkında da önemli bilgiler vermektedir. Örneğin, bükük diz yürüyüşü (*Ing:*

crouch gait) durumunda kuadriceps kasının hangi oranda diz ekstansiyon momentine katkıda bulunduğu belirlenmesi, diz ekstansiyon momentinin büyüklüğünün ve örüntüsünün (*Ing: pattern*) analizi cerrahi karar verme sürecinde çok önemlidir.^{6,7}

Eklem momentlerinin hesaplanabilmesi için yürüme analizi sırasında kaydedilen eklem açılarının (kinematik veri) ve YTK'nin (kinetik veri), insan vücudunun dinamik modeli ile entegre edilmesi ve ters dinamik analiz yönteminin uygulanması gerekmektedir.^{8,9} YTK, yürüme analizi laboratuvarlarında, zemine gömülü ve oldukça yüksek maliyetli kuvvet platformları (Bkz. Resim 1) kullanılarak ölçülebilmektedir. Ancak, YTK'nin doğal yürüme sırasında kaydedilmesi, özellikle yürüme bozukluğu şiddetli olan ya da yürüme için yardımcı cihazlar kullanan SP'li hastalar için, oldukça zordur.^{10,11} YTK, yürüme analizinin deneysel olarak doğrudan ölçülebilen tek kinetik parametresidir. Ayrıca, YTK ölçümü zorunluluğu, yürüme verisi kaydının yalnızca laboratuvar ortamında yapılması mecburiyetini oluşturur.



Resim 1. Yer tepki kuvveti (YTK) ölçümünde zemine gömülü şekilde kullanılan kuvvet platformu¹²

Yukarıda bahsedilenler ışığında YTK'nin laboratuvar dışı ortamlarda ve pratik bir şekilde belirlenebilmesi büyük önem arz etmektedir. Bu çerçevede YTK'nin yapay zekâ yöntemleri aracılığıyla kinematik veriden kestirilmesi üzerine başarılı çalışmalar yapılmıştır; ancak bu çalışmaların tamamı sağlıklı bireyler için gerçekleştirilmiştir.¹³⁻¹⁶

YTK'nin kuvvet platformları kullanılmadan makine öğrenmesi (MÖ) yoluyla kestirimi *i*) klinisyenlerin yürüme analizi laboratuvarında hareket bozukluğu olan hastalardan ölçüm alınması sırasında yaşanan zorlukları aşmasına, *ii*) yürüme analizinin laboratuvar dışında yapabilmesine ve *iii*) çok yüksek fiyatlara satılan (yaklaşık 50.000 \$) ve çok az klinikte bulunan kuvvet platformu sistemlerine olan bağlılığın ortadan kalkmasına olanak tanır. MÖ, herhangi bir sistemde

verilerin veya veri ile yapılacak analizler için gerekli modellerin eksik olduğu problemleri çözmek için güçlü bir araçtır.

Sağlıklı bireylerin yürüyüşü sırasında oluşan YTK'yi tahmin etmeye yönelik ilk girişimler 2013'te başlamış ve bu çalışmalarda genellikle konvansiyonel MÖ algoritmaları kullanılmıştır.¹³ Daha sonra istatistiksel yaklaşımlar ve hareket yakalama verileri kullanarak derin öğrenme algoritmaları ve zaman-mekânsal bilgiler de dâhil olan diğer YTK tahmin çalışmaları, yalnızca sağlıklı bireyler için yapılmıştır.¹⁴⁻¹⁶ Ancak henüz SP'li hastalarda YTK'ni tahmin etme konusunda yapılmış bir çalışma yoktur. Bugüne kadar SP'li hastalarda MÖ algoritmaları yalnızca yürüyüş evrelerinin sınıflandırılması (*Ing: gait event classification*) ya da erken dönemde bebeklerin iki

boyutlu video kayıtlarından SP'li olma ihtimallerinin belirlenmesi için uygulanmıştır.²¹⁻²⁵

Literatürdeki bu boşluğu doldurmak amacıyla bu çalışma ile ilk defa bir bireyin sağlıklı mı yoksa SP hastası mı olduğunun belirlenmesi ve SP hastası ise, yürüyüş sırasındaki YTK'nin kestirilmesi gerçekleştirilmiştir. Bu amaca ulaşmak için, zaman serisi bilgilerini işleyen bir derin öğrenme modeli olan bir boyutlu konvolüsyonel sinir ağları, alt eksremiteden elde edilen üç boyutlu eklem açıları ile beslenmiş ve *i*) ilk model ile hastalığın tespit edilmesi sağlanmış, *ii*) ikinci model ile de yürüme sırasında oluşan YTK'leri kestirilmiştir.

YÖNTEM

Bu retrospektif çalışmada, Heidelberg Üniversitesi Hastanesi arşivindeki 40 sağlıklı ve 40 SP'li hastaya ait kinematik ve kinetik yürüme verileri dikkate alınmıştır. Benzer nitelikte verilere ulaşılabilecek açık erişimli kaynaklar da bulunmaktadır.¹⁷⁻²⁰ Çalışmanın ilk aşamasında, kinematik yürüme verileri bir boyutlu konvolüsyonel sinir ağı (*İng: convolutional neural network-CNN*) modeline beslenmiş ve yapılan eğitim sonucunda sağlıklı ve SP'li bireylerin sınıflandırılması gerçekleştirilmiştir. İkinci aşamada ise başarılı sınıflandırılan SP'li bireylere ait kinematik veriler ikinci bir konvolüsyonel sinir ağı modeline beslenmiş ve yürüme sırasında ortaya çıkan YTK'lerinin kestirilmesi amaçlanmıştır.

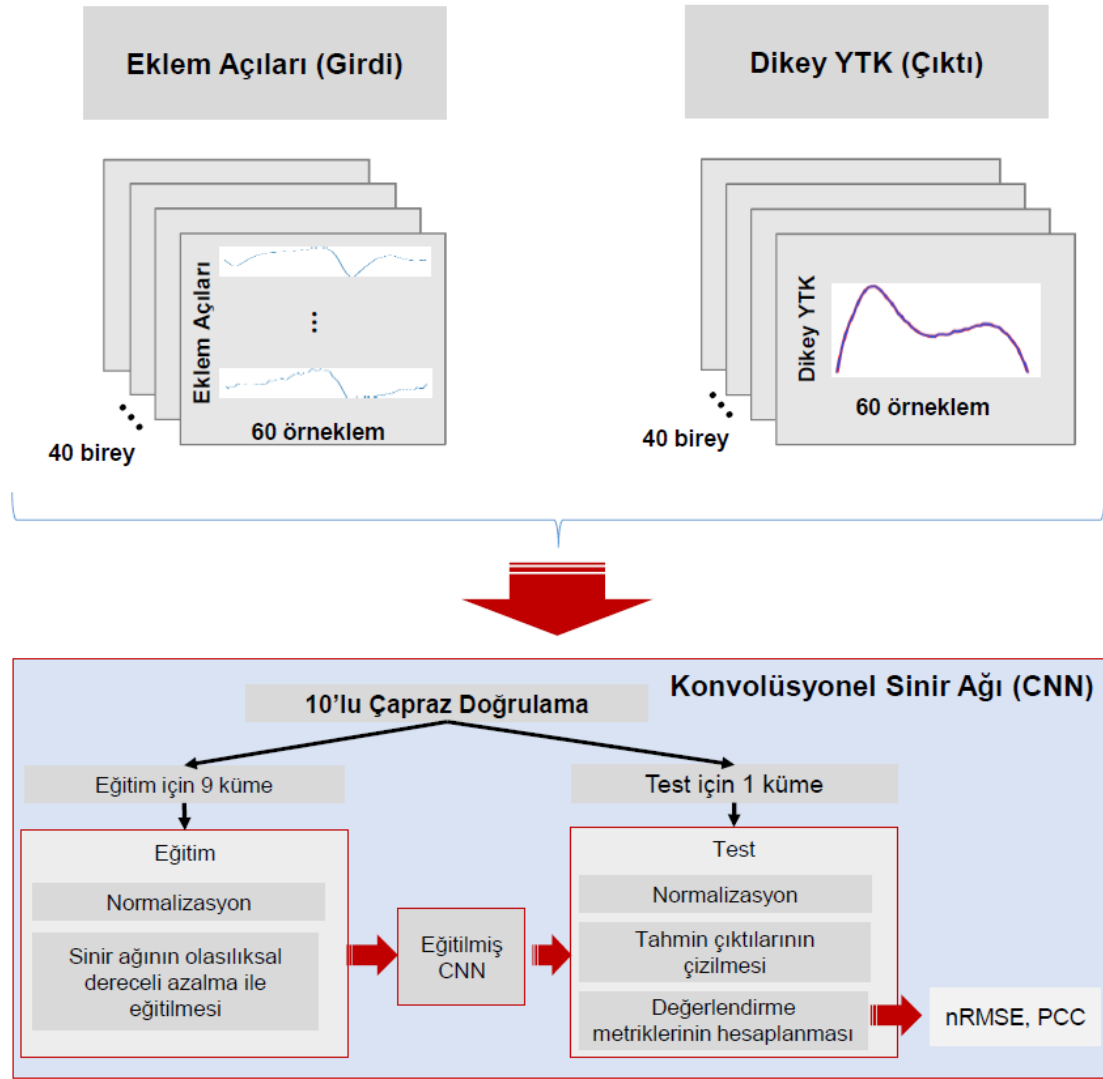
Kullanılan Veri Seti

Veri seti, tedavi amaçlı veri toplanan hastalardan Heidelberg Üniversite Hastanesi yerel etik komitesi tarafından onaylanarak ((S-227/2021) edinilmiştir. Kinematik veri seti, gönüllülerin kendi seçtikleri hızda yürümesi sırasında kızılötesi kameralarla donatılmış hareket algılama sistemi kullanılarak, 19 işaretçili Plugin Yürüyüş Modeline göre toplanmıştır. Tüm veri setinde alt ekstremite eklem açıları (gövde, pelvis, kalça, diz ve ayak bileğinden sagittal, koronal ve transvers düzlemlerde toplanan eklem açıları-toplam 15 eklem açısı) ve kuvvet platformu aracılığıyla ölçülmüş YTK verisi bulunmaktadır. Her katılımcı için 7 ila 10 adım ortalaması alınmış ve her adım bir yürüyüş döngüsünün tamamlanmasına göre normalize edilmiştir. Eklem açıları ve YTK farklı sürelerdeki adımlar için aynı aralığa (100 örneklemler) ölçeklendirilmiş ve sadece adımın yere temas ettiği Sağlıklı ve SP'li bireylerin belirlenmesi için kullanılan algoritmada ise, yukarıda anlatılan MÖ modelinin sadece son katmanı tek bir nöron içeren ve aktivasyon fonksiyonu sigmoid olan bir katman ile değiştirilmiştir. Modeller, Olasılıksal Dereceli Azalma (*İng: stochastic gradient descent*) algoritması ile eğitilmiş ve Keras 2.9.0 arayüzü ile Tensorflow 2.9.1 kütüphanesi kullanılarak ücretsiz Google Colab sunucuları üzerinde

uygulanmıştır.²⁸ YTK tahmin modeli kayıp fonksiyonu (*İng: lost function*) için Pearson korelasyon katsayısı (PCC) ve normalize edilmiş ortalama karesel hata (nRMSE) kullanılmıştır. Sınıflandırma modelinde ise kayıp fonksiyonu olarak tekil çapraz düzensizlik (*İng: binary cross entropy*) değeri kullanılmıştır. Yer tepki kuvveti tahmin modeli için 500 iterasyon ile sınırlandırılmış bir eğitim 10 toptan (*İng: batch*) büyüklüğü ile gerçekleştirilmiştir. Sınıflandırma modeli için ise 50 iterasyon ile sınırlandırılmış bir eğitim 10 toptan büyüklüğü ile gerçekleştirilmiştir. zaman aralığı (basma fazı) sırasındaki veriler (yaklaşık ilk 60 örnekleme) kullanılmıştır. Girdi verisi olarak eklem açıları satırlar olacak şekilde (*eklem açısı sayısı × 60 örnekleme* boyutunda) bir matris olarak tanımlanmıştır. Her bir birey için bir matris oluşturulmuştur. Çıktı verisi ise sınıflandırma algoritması için ait olduğu grubu sembolize eden tekil bir değer (1-0) olarak tanımlanmış yer tepki kuvveti tahmini algoritması için ise her bir birey için 60 örneklemlerli bir vektör olarak tanımlanmıştır.

Makine Öğrenmesi Modeli

Girdi matrisinde bulunan zaman serisi satırlarını işlemek ve özniteliklerini çıkarmak için, CNN modelinde bir boyutlu konvolüsyon uygulanmıştır. Bir boyutlu konvolüsyon katmanları, zaman serisi verilerinden (bizim çalışmamızda eklem açıları), filtrelerin boyutlarıyla belirlenmiş zaman aralıklarıyla öznitelik çıkarırlar. Bu öznitelikler başka bir zaman serisi verisini (bizim çalışmamızda yer tepki kuvveti) tahmin etmek için anlamlı bilgileri içerir.^{26,27} Tasarladığımız bir boyutlu CNN modeli, [128, 128, 512, 1024, 2048] filtre sayılarına sahip beş konvolüsyon katmanından oluşmuş ve [30, 15, 10, 5, 3] filtre boyutlarına sahiptir. Her katmanda filtre sayısının artması ve aynı zamanda filtre boyutunun azalması giderek küçülen zaman aralıkları için sayıca fazlalaşan öznitelik çıkarılmasını sağlar. Konvolüsyon katmanlarının çıktısı tek boyuta indirgindikten sonra (*İng: flattening*) aşağıdaki nöron sayılarına sahip doğrudan bağlantılı (*İng: densely connected*) katmanlar kullanılmıştır: [10000, 8000, 6000, 4000, 3000, 2000, 1000, 500, 250, 100]. Doğrudan bağlantılı katmanlarda nöron sayısının ileriye doğru azalması, öğrenme sürecinde bilginin istenilen çıktı boyutuna dönüştürülmesine yardımcı olur. Seçilen nöron sayısı, çıkarılan öznitelikler kullanılarak öğrenme sürecinin icra edilmesinde yeterli olmuştur. Tüm katmanlarda ReLU aktivasyon fonksiyonu kullanılmış ve çıktılara %1 oranında ihmal etme (*İng: drop-out*) katmanı eklenmiştir. Son olarak, lineer aktivasyon fonksiyonuna sahip doğrudan bağlantılı bir çıktı katmanı kullanılmış ve bu katmanda basma fazı örnekleme sayısına eşit miktarda (60) nöron kullanılmıştır. Resim 2 geliştirilen makine öğrenmesi algoritmasının akış diyagramını göstermektedir.



Resim 2. Makine Öğrenmesi Akış Diyagramı

Değerlendirme Kriterleri Ve Kullanılan Metrikler

Modellerin kestirim performansı 10'lu çapraz doğrulama (*İng: cross validation*) tekniği ile test edilmiştir. Test ölçütleri YTK kestirim modeli için nRMSE (Bkz. denklem 1) ve PCC (Bkz. denklem 2) olup, sınıflandırma modeli için ise doğru sınıflandırma (*İng: accuracy*) (Bkz. denklem 3) değeridir. Bu metrikler biyomekanik veri kestirimi ve sınıflandırma çalışmalarında genel kabul görmüş metriklerdir.²⁹⁻³² nRMSE kestirilen ve deneysel olarak elde edilen YTK sonuçları arasındaki genlik farklılıklarını yüzdesel olarak niteleyen bir metrik iken, PCC tahmin edilen ve deneysel olarak elde edilen YTK örüntülerinin birbirlerine uyumlarını göstermektedir. Örneğin iki eğri arasındaki PCC değerinin 1 olması, bu iki eğrinin tam olarak çakışık olduğu anlamına gelmektedir. Literatürde, YTK'nin kestirimi üzerine yapılan çalışmalarda, nRMSE için %15'den küçük, PCC için de 0.85'dan büyük değerler başarılı olarak kabul edilmektedir.^{14-16,33}

$$nRMSE = \sqrt{\frac{\sum_n (YTK_T - YTK_D)^2}{n}} / \mu RoM_D \quad (1)$$

$$PCC = \frac{cov(D,T)}{\sigma_D \cdot \sigma_T} \quad (2)$$

$$Doğruluk = \frac{DoğruP + DoğruN}{DoğruP + DoğruN + YanlışP + YanlışN} \quad (3)$$

Denklem 1’de, tahmin edilen yer tepki kuvveti YTK_T ile deneysel olarak ölçülmüş yer tepki kuvveti YTK_D arasındaki ortalama karesel hatanın, tahmin edilen yer tepki kuvvetinin hareket aralığına μRoM_E göre normalize edilmesi hesaplanmıştır.

Denklem 2’de, tahmin edilen ile ölçülen yer tepki kuvvetlerinin kovaryanslarının $cov(D,T)$, ikisinin ayrı ayrı varyanslarının çarpımına $\sigma_D * \sigma_T$ bölümü hesaplanmıştır.

Denklem 3’de ise doğru pozitif (*DoğruP*) ve doğru negatif (*DoğruN*) sınıflandırma tahminlerinin, doğru ve yanlış bütün pozitif ve negatif sınıflandırmalara oranı hesaplanmıştır.

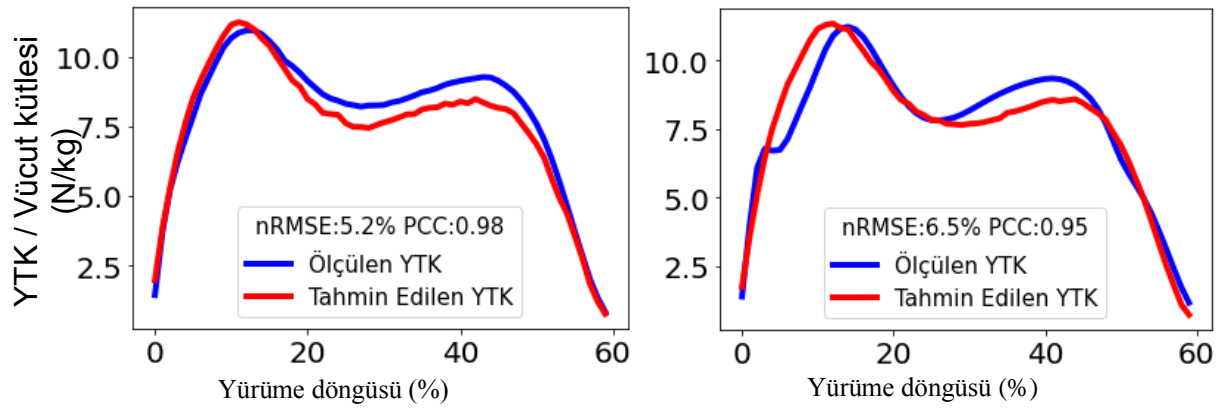
BULGULAR

10’lu çapraz doğrulama sonucunda elde edilen sağlıklı ve SP’li bireylerin sınıflandırma başarısı 0.98 ± 0.06

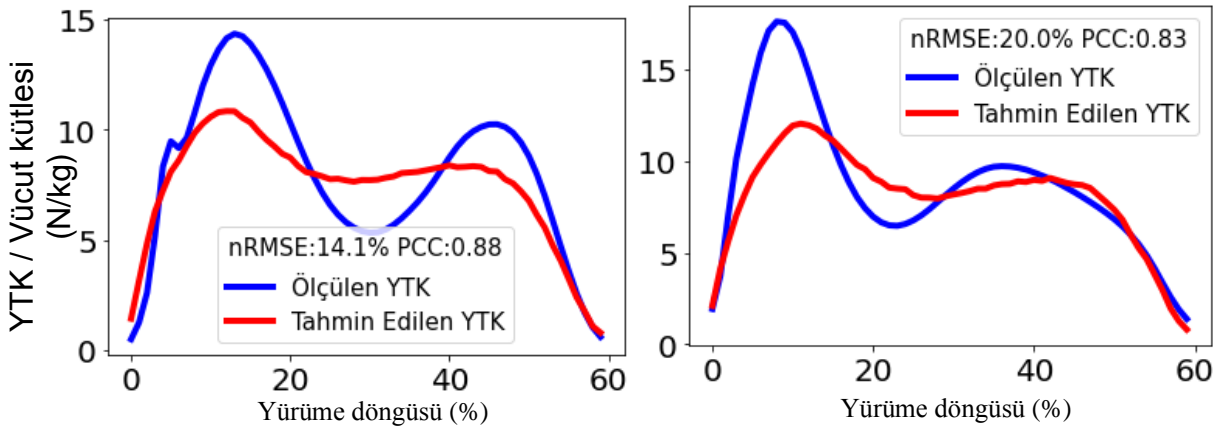
doğruluk oranındadır. Bu değer 10 farklı test grubunun doğruluk oranlarının ortalaması ve standart sapmasının hesaplanması ile bulunmuştur.

YTK tahmini için 10’lu çapraz doğrulama sonuçlarında ortalama olarak nRMSE için 13.3 ± 5.1 ve PCC için 0.88 ± 0.07 bulunmuştur. Resim 3’de tahmin edilen ve deneysel olarak elde edilen YTK örnekleri verilmiştir. Sonuçların temsil niteliğinin yüksek olması için iki tane ortalama üstü başarıya sahip (Resim 3-A) ve iki tane ortalama altında başarıya sahip (Resim 3-B) YTK grafiği verilmiştir.

YTK sonuçları, her bir katılımcının kendi kütlesine göre normalize edilmiş ve böylece katılımcıların kütlelerinden bağımsız, objektif ve literatürle karşılaştırılabilir bir değerlendirme yapılabilmektedir. Literatürde sağlıklı bireyler için yapılan çalışmalarda YTK %10.7-%14.5 nRMSE ve 0.93-0.99 PCC başarı değerleriyle kestirilmiştir.^{13,15}



A) Ortalama üstü başarıyla tahmin edilmiş iki yer tepki kuvveti (YTK) örneği



B) Ortalama altında başarıyla tahmin edilmiş iki yer tepki kuvveti (YTK) örneği

Resim 3. A) ortalamanın üzerinde başarıyla tahmin edilmiş (kırmızı) ve deneysel olarak ölçülmüş yer tepki kuvvetleri (mavi), B) ortalamanın altında başarıyla tahmin edilmiş (kırmızı) ve deneysel olarak ölçülmüş yer tepki kuvvetleri (mavi)

TARTIŞMA

YTK'nin pratik ve hızlı bir şekilde belirlenebilmesi, özellikle SP gibi nörodejeneratif rahatsızlıkları bulunan hastalar için büyük önem arz etmektedir. Bu çalışmada YTK'nin makine öğrenmesi aracılığıyla kinematik veriden kestirilmesi gerçekleştirilmiştir. Sonuç olarak sağlıklı ve SP'li bireyler 0.98 gibi yüksek bir sınıflandırma doğruluğu ve düşük bir standart sapma (± 0.06) değeri ile başarılı bir şekilde sınıflandırılabilmiştir. Ayrıca SP'li bireylerde, literatürde belirtilen başarı oranları (nRMSE için %15, PCC için 0.85) üzerine çıkılarak nRMSE için 13.3 ± 5.1 ve PCC için 0.88 ± 0.07 'lik kestirim başarısı elde edilmiş ve çalışmada önerilen yöntemin ilerleyen yıllarda klinikte de uygulanabilmesi adına önemli bir adım atılmıştır.

Çalışma sonuçları, yakın gelecekte laboratuvar ortamında, özellikle hasta bireylerde uygulanması çok zor olan yer tepki kuvveti ölçümüne ihtiyaç duymadan yürüyüş analizi yapılabileceğini göstermektedir. Ülkemizde ve dünyada çok sayıda bulunan SP hastasının düzenli yürüyüş analizinin kolaylıkla yapılabilmesi, hastaların teşhisleri ve uygulanacak tedavi yaklaşımlarının objektif olarak değerlendirilebilmesi için çok önemlidir. Çalışmada önerilen makine öğrenmesi tabanlı hareket analiz yöntemi, hastanelerdeki laboratuvarlara kolaylıkla kazandırılabilir. Böylece klinisyenler başarıyla ölçüm alamadıkları hastaların yer tepki kuvvetlerini doğrulukla belirleyebilirler ve bu veri ile klinik kararlarını güçlendirebilirler. Bununla birlikte eksik donanımları sebebiyle yer tepki kuvvetini hiç ölçemeyen kliniklerin de bu algoritmayı kullanmaları, tedavi etkileri hastaların yer tepki kuvvetlerine ulaşabilmelerine imkan tanır. Önerdiğimiz yaklaşım ile klinikte yürüme analizi sırasında kişisel olarak da gözlemediğimiz birçok sorunun (SP'li çocukların yürüme analizi için yaklaşık 3-4 saat boyunca iç çamaşırları ile laboratuvarında bulunmaları ve bu sebeple üşümeleri, rahatsızlık hissetmeleri, midelerinin bulanması, yorulması ve psikolojilerinin olumsuz etkilenmesi) azaltılması mümkün olacaktır.

SP'li hastalar için yer tepki kuvvetlerinin makine öğrenmesi kullanılarak kestiriminin muadili bir sistem akademik literatürde veya pratik uygulamalarda mevcut değildir. Bu yüzden geliştirilen sistemin kullanım alanının ticari rekabet potansiyeli oldukça yüksektir. Kişiye özel koruyucu ve cerrahi tedavilerin uygulanmasının zorunlu olduğu serebral palsi hastalarında pratik ve hızlı bir şekilde uygulanabilecek bir hareket analizi sistemi, uygulanacak tedavilerin başarısını ve kısa-uzun dönemdeki sonuçlarını objektif bir şekilde değerlendirmek açısından da çok önemli olacaktır.

Bu çalışmanın bazı kısıtları da vardır ve dikkate alınmalıdır. İlk olarak, çalışmada kullanılan kinematik

veriler üst ekstremitelere ait kinematik veriyi içermiyordu; ancak üst ekstremitelerden alınabilecek daha fazla kinematik veri, yer tepki kuvvetinin daha yüksek bir başarıyla kestirilmesini sağlayabilir. İkincisi, çalışmamızda toplam 80 gönüllüye ait veri kullanılmıştır. Makine öğrenmesi yaklaşımlarının kestirim başarısının artırılması için çok daha fazla gönüllüden elde edilen verilerin kullanılması gerekebilir.

Çalışmanın sonuçları, yer tepki kuvvetinin kinematiğe dayalı makine öğrenimi ile kestiriminin, yakın gelecekte SP'li hastaların yürüyüş analizinde kullanılan geleneksel yaklaşıma önemli ve pratik bir alternatif olabileceğini göstermiştir. Bununla birlikte, yalnızca sorumlu hekim onayı ile yapılan hesaplamaların klinik uygulamalarda kullanılması mümkündür; aksi bir kullanım klinik hata riskleri barındırır.

Yazar Katkıları

Çalışma fikri/tasarımı: MEÖ, YZA, SIW

Veri toplama: SIW

Veri analizi ve yorumlama: MEÖ, YZA

Literatür tarama: MEÖ

Eleştirel inceleme: YZA, SIW

Son onay ve sorumluluk: YZA, SIW

Çıkar çatışması: Yazarlar çıkar çatışması beyan etmemiştir.

Finansal Destek: Yazarlar finansal destek beyan etmemiştir.

KAYNAKLAR

1. Gage JR. The clinical use of kinetics for evaluation of pathological gait in cerebral palsy. *JBJS*. 1994;76(4):622-31.
2. Ounpuu S, Davis RB, Deluca PA. Joint kinetics methods, interpretation and treatment decision-making in children with cerebral palsy and myelomeningocele. *Gait & Posture*. 1996;4(1):62-78.
3. Lai KA, Kuo KN, Andriacchi TP. Relationship between dynamic deformities and joint moments in children with cerebral palsy. *Journal of Pediatric Orthopedics*. 1988;8(6):690-5.
4. Novacheck TF, Gage JR. Orthopedic management of spasticity in cerebral palsy. *Child's Nervous System*. 2007;23(9):1015-31.
5. Lin CJ, Guo LY, Su FC, Chou YL, Cherng RJ. Common abnormal kinetic patterns of the knee in gait in spastic diplegia of cerebral palsy. *Gait & Posture*. 2000;11(3):224-32.
6. Lenhart RL, Brandon SC, Smith CR, Novacheck TF, Schwartz MH, Thelen DG. Influence of patellar position on the knee extensor mechanism in normal and crouched walking. *Journal of Biomechanics*. 2017;51:1-7.

7. Karabulut D, Arslan YZ, Götze M, Wolf SI. The impact of patellar tendon advancement on knee joint moment and muscle forces in patients with cerebral palsy. *Life*. 2021;11(9):944.
8. Winter DA. Biomechanics and motor control of human movement. John Wiley & Sons; 2009.
9. Whittle MW. Gait analysis an introduction. Butterworth-Heinemann; 2014.
10. Caldas R, Fadel T, Buarque F, Markert B. Adaptive predictive systems applied to gait analysis: A systematic review. *Gait & Posture*. 2020;77:75-82.
11. White R, Agouris I, Selbie RD, Kirkpatrick M. The variability of force platform data in normal and cerebral palsy gait. *Clinical Biomechanics*. 1999;14(3):185-92.
12. Wikimedia Foundation. Force platform. Wikipedia. Published December 6, 2022. Accessed February 9, 2023. https://en.wikipedia.org/wiki/Force_platform
13. Oh SE, Choi A, Mun JH. Prediction of ground reaction forces during gait based on kinematics and a neural network model. *Journal of Biomechanics*. 2013;46(14):2372-80.
14. ohnson, W. R., Mian, A., Donnelly, C. J., Lloyd, D., & Alderson, J. Predicting athlete ground reaction forces and moments from motion capture. *Medical & Biological Engineering & Computing*. 2018;56(10):1781-92.
15. Mundt M, Koeppel A, David S, Bamer F, Potthast W, Markert B. Prediction of ground reaction force and joint moments based on optical motion capture data during gait. *Medical Engineering & Physics*. 2020;86:29-34.
16. Johnson WR, Alderson J, Lloyd D, Mian A. Predicting athlete ground reaction forces and moments from spatio-temporal driven CNN models. *IEEE Transactions on Biomedical Engineering*. 2018;66(3):689-94.
17. Dixon PC, Stebbins J, Theologis T, Zavatsky AB. The use of turning tasks in clinical gait analysis for children with cerebral palsy. *Clinical Biomechanics*. 2016;32:286-94.
18. Steele KM, Seth A, Hicks JL, Schwartz MS, Delp SL. Muscle contributions to support and progression during single-limb stance in crouch gait. *Journal of Biomechanics*. 2010;43(11):2099-105.
19. Steele KM, Seth A, Hicks JL, Schwartz MH, Delp SL. Muscle contributions to vertical and fore-aft accelerations are altered in subjects with crouch gait. *Gait & Posture*. 2013;38(1):86-91.
20. Lencioni T, Carpinella I, Rabuffetti M, Marzegan A, Ferrarin M. Human kinematic, kinetic and EMG data during different walking and stair ascending and descending tasks. *Scientific Data*. 2019;6(1):309.
21. Arslan YZ, Derya K. Sensitivity of model-predicted muscle forces of patients with cerebral palsy to variations in muscle-tendon parameters. *Journal of Mechanics in Medicine and Biology*. 2021;21(01):2150008.
22. Ihlen, E. A., Støen, R., Boswell, L., de Regnier, R. A., Fjørtoft, T., Gaebler-Spira, D. Machine learning of infant spontaneous movements for the early prediction of cerebral palsy: A multi-site cohort study. *Journal of Clinical Medicine*. 2020;9(1):5.
23. Zhang Y, Ma Y. Application of supervised machine learning algorithms in the classification of sagittal gait patterns of cerebral palsy children with spastic diplegia. *Computers in Biology and Medicine*. 2019;106:33-9.
24. Morbidoni, C., Cucchiarelli, A., Agostini, V., Knaflitz, M., Fioretti, S., & Di Nardo, F. Machine-Learning-Based Prediction of Gait Events From EMG in Cerebral Palsy Children. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2021;29:819-30.
25. Kim YK, Visscher RM, Viehweger E, Singh NB, Taylor WR, Vogl F. A deep-learning approach for automatically detecting gait-events based on foot-marker kinematics in children with cerebral palsy—Which markers work best for which gait patterns? *PLoS One*. 2022;17(10):e0275878.
26. Hua X, Han J, Zhao C, Tang H, He Z, Chen Q, et al. A novel method for ECG signal classification via one-dimensional convolutional neural network. *Multimedia Systems*. 2020:1-13.
27. Malek S, Melgani F, Bazi Y. One-dimensional convolutional neural networks for spectroscopic signal regression. *Journal of Chemometrics*. 2018;32(5):e2977.
28. Chollet F. Others, 2015. Keras. GitHub.
29. Ardestani MM, Zhang X, Wang L, Lian Q, Liu Y, He J. Human lower extremity joint moment prediction: A wavelet neural network approach. *Expert Systems with Applications*. 2014;41(9):4422-33.
30. Mundt M, Koeppel A, David S, Bamer F, Potthast W, Markert B. Prediction of ground reaction force and joint moments based on optical motion capture data during gait. *Medical Engineering & Physics*. 2020;86:29-34.
31. Mundt M, Koeppel A, David S, Witter T, Bamer F, Potthast W, Markert B. Estimation of gait mechanics based on simulated and measured IMU data using an artificial neural network. *Frontiers in Bioengineering and Biotechnology*. 2020;8:41.
32. Ripic Z, Kuenze C, Andersen MS, Theodorakos I, Signorile J, Eltoukhy M. Ground reaction force and joint moment estimation during gait using an Azure Kinect-driven musculoskeletal modeling approach. *Gait & Posture*. 2022;95:49-55.
33. Wu CC, Wen YT, Lee YJ. IMU sensors beneath walking surface for ground reaction force prediction in gait. *IEEE Sensors Journal*. 2020;20(16):9372-6.