



# Nörodejeneratif Hastalıkların Tespiti İçin Derin Öğrenme Tabanlı Bir Yaklaşım

## A Deep Learning-Based Approach to Detect Neurodegenerative Diseases

Çağatay Berke Erdaş<sup>1\*</sup>, Emre Sümer<sup>1</sup>  
Bilgisayar Mühendisliği, Mühendislik Fakültesi  
Başkent Üniversitesi  
Ankara, Türkiye  
{berdas, esumer}@baskent.edu.tr

**Özetçe**— Dünya Sağlık Örgütü (WHO) tarafından yürütülen araştırmalar, dünya çapında bir milyardan fazla kişinin nörolojik bozukluklardan muzdarip olduğunu ve etkili tanı prosedürlerinin eksikliğinin tedaviyi etkilediğini göstermektedir. Teşhislerini kolaylaştırmak için belirli motor semptomlarını karakterize etmek, hastalığın ilerlemesinin izlenmesinde ve etkili tedavi planlamasında yararlı olabilir. Parkinson hastalığı (PH), Amyotrofik Lateral Skleroz (ALS) ve Huntington hastalığı (HH) gibi prevalansı yüksek nörodejeneratif hastalıkların (NDD) sınıflandırılması klinik öneme sahiptir. Bahsi geçen bu nörodejeneratif hastalıkların tespit edilmesi için literatürce kullanılan yöntemlerden birisi yürüme analizi tabanlı sınıflandırmadır. Bu çalışmada, 12 farklı öznelik tek boyutlu Erişimsel Sinir Ağı (Convolutional Neural Network- CNN) derin öğrenme algoritması tabanlı bir modeli beslemiş ve PH, HH, ALS hastalıklarının tespiti üzerine çalışılmıştır. 12 öznelik ile beslenen tek boyutlu CNN derin öğrenme modeli, HH'ye karşı kontrol, PH'ye karşı kontrol ve ALS'ye karşı kontrol problemleri için %78,92, %84,39 ve %92,09 sınıflandırma doğruluğu elde etmiştir. Yine ilgili sınıflandırıcı Tüm nörodejeneratif hastalık örnekleri (NDD) sınıfı olarak tek bir etiket altında toplandığı ve mevcut kontrole karşı bu hastalıkların ayrılması için geliştirilen yaklaşım ile %84,75 doğruluk üretmiştir.

**Anahtar Kelimeler** — *Nörodejeneratif Hastalıklar; Parkinson Hastalığı; Huntington Hastalığı; Amyotrofik Lateral Skleroz, Sınıflandırma.*

**Abstract**— Studies conducted by the World Health Organization (WHO) show that more than a billion people worldwide suffer from neurological disorders and the lack of effective diagnostic procedures affects treatment. Characterizing specific motor symptoms to facilitate their diagnosis can be useful in monitoring disease progression and effective treatment planning. Classification of highly prevalent neurodegenerative diseases (NDD) such as Parkinson's disease (PH), Amyotrophic Lateral Sclerosis (ALS), and Huntington's disease (HH) is of clinical importance. One of the methods used in the literature to

detect these neurodegenerative diseases is gait analysis-based classification. In this study, 12 different features fed a unidimensional Convolutional Neural Network (CNN) deep learning algorithm-based model, and aims to detect PD,HD, and ALS diseases was studied.

The unidimensional CNN deep learning model fed with 12 features achieved 78,92%, 84,39% and 92,09% classification accuracy for control against HH, control against PH, and control detection problems against ALS. Again, the relevant classifier produced 84.75% accuracy with the approach developed to separate all neurodegenerative disease specimens (NDD) under a single label as a class, and to distinguish these diseases against the current control.

**Keywords** — *Neurodegenerative Diseases; Parkinson's Disease; Huntington Disease; Amyotrophic Lateral Sclerosis; Classification.*

### I. GİRİŞ

Parkinson (PH), Huntington (HH) ve Amyotrofik lateral skleroz (ALS) hastalıkları, yürüyüş ve yürüyüşün başlamasında ciddi rahatsızlıkların sıklıkla bildirildiği üç nörodejeneratif hastalıktır. Bu nedenle, teşhis açısından bakıldığında, araştırmalar bu koşulların karakterizasyonu için yürüyüş çalışmasına doğru büyüyen bir eğilim göstermektedir. Bu nörolojik bozuklukları teşhis etmek için klinik analizler (ALS, HH ve PH) kan testleri, EMG analizi, genetik test ve spinal tapayı (lomber ponksiyon) içerir ve bunlar diğer hastalık ihtimallerini dışlamak için yapılır [1]. Bu tür teşhis önemli olsa da, bu prosedürlere dayalı erken teşhis görevi, karmaşık ve zaman alıcı bir sorun olmaya devam etmektedir. Bunun nedeni, ilk aşamada semptomların üç nörodejeneratif durumdan herhangi biri için yanlış anlaşılabilmesidir. Bu nedenle, etkili tedavi planlamasını kolaylaştırmak adına, büyük bir popülasyona fayda sağlamak için bu koşulların ön taramasına ihtiyaç vardır. Tüm bu koşullarda sık karşılaşılan semptom, anormal istemsiz titreme hareketleridir. Bu anormal istemsiz hareketler ALS ve HH için Kore, PH içinse Diskinezi ile kendini gösterebilir. Bu anormal hareketler yürüyüşü değiştirir ve bacakların yanal


koordinasyonu sırasında ve diğer ilişkili hareketlerde zorluklara neden olur [2]. Bu anormalliğin getirdiği değişikliklerin yanı sıra, adım adım dalgalanmalar da hasta ve kontrol grupları için denekler arasında farklılık gösterir. Bu nedenle, yürüyüşteki temel farklılıkları (kalıtsal + anormallikler tarafından oluşanlar) uygun şekilde karakterize eden bir yaklaşım çok önemlidir. Bu çalışmada, normal ve anormal yürüyüşteki gömülü uzun vadeli korelasyon bilgilerinden, nörolojik bozuklukların etkin bir şekilde ayrıştırılması için tek boyutlu Evrişimsel Sinir Ağı derin öğrenme modeli önerilmiştir. Dahası, önerilen model ile (i) tüm nörolojik hastalıkların tek bir etiket altında toplandığı ve sadece kontrol ve hasta olarak 2 ayrı grubun olduğu, (ii) sadece ALS hastalarının ve kontrol grubunun bulunduğu, (iii) sadece HH hastalarının ve kontrol grubunun bulunduğu, (iv) sadece PH hastalarının ve kontrol grubunun bulunduğu senaryolar üzerinde hastalık tespiti problemlerine çözüm aranmaktadır.

NDD'lere bağlı hareket bozuklukları, bir kişinin düzgün yürüyebilme yeteneğini azaltır ve rahatsızlık döngüsüne yol açar. Bu tür hastalıklardan etkilenen yürüyüş parametrelerinin analizi, hareketin nöral bileşenini açıklamada ve otomatik bir sınıflandırma metodolojisi geliştirmede uygulamalara sahiptir. Literatürde yürüyüş verisine dayalı ve adım değişkenliğini karakterize ederek PH, HH ve ALS'yi kontrol grubundan ayırmak için geliştirilen çalışmalar mevcuttur [3,4]. Hausdorff ve diğerleri tarafından önerilen bir araştırmada [3], eğilimi azaltılmış dalgalanma analizini kullanarak yürüyüş döngüsündeki değişiklikler tahmin edilmiştir. Dalgacık temelli bir şema kullanarak bozukluğu olan denekler arasındaki göreceli düşme riskini hesaplamak için zamanla değişen yürüyüş modelini karakterize etmek yeni bir tahmin tekniği olarak Khandoker ve arkadaşları tarafından önerilmiştir [5]. Liao vd. [6], yürüme simetrisinin karakterizasyonu ve nörolojik bozuklukların saptanması için çoklu çözünürlük analizinin kullanılabilirliğini genişletti. Benzer şekilde, Myklebust ve ark. [7], HH deneklerin yürüyüşü ve kontrol deneklerinin yürüyüşü arasındaki ayırt edilebilir özellikleri belirlemek için tutarlılık ölçütlerinin önemini sunmuştur.

## II. YÖNTEMLER

### A. Genel yapı

Yürüyüş analizi, ayağın altına yerleştirilmiş bir dizi Zemin Tepki Kuvveti (Ground Reaction Force - GRF) sensörü kullanılarak gerçekleştirilir. GRF, zeminin kendisine temas eden vücut bölgesine uyguladığı kuvvettir. Kişisel yürüyüş alışkanlıklarına göre bir yürüyüş aktivitesi sırasında ayaklardaki bu tepki kuvveti zaman içinde değiştiğinden, bireysel yürüyüş analizi için uygun bir kaynak olduğu düşünülmektedir. Şekil I'de görüleceği üzere GRF sensörleri ile elde edilen yürüyüş öznitelikleri test ve eğitim için ikiye ayrılır. Eğitim için ayrılan alt veri kümesinde bulunan örnekler ile önerilen model eğitilirken kalan örnekler kullanılarak önerilen modelin nörodejenetarif hastalıkların tespiti problemi özelinde yakaladığı sınıflandırma performansı test edilir.



Şekil I. Genel yapı

### B. Evrişimsel Sinir Ağı

Bir Evrişimsel Sinir Ağı (CNN), bir veya daha fazla Evrişimsel katmandan ve ardından standart bir çok katmanlı sinir ağına olduğu gibi bir veya daha fazla tamamen bağlı katmandan oluşur. Bir CNN'nin mimarisi, bir giriş verisinin yapısından yararlanarak üzerinde bulunan örüntüyü ortaya çıkarmak üzere tasarlanmıştır. Bu, yerel bağlantılarla ve bağlı ağırlıklar ile elde edilir. CNN'lerin diğer bir yararı, eğitilmelerinin daha kolay olması ve aynı sayıda gizli birimle tam olarak bağlı ağlara göre çok daha az parametreye sahip olmalarıdır. Bir tek boyutlu CNN, özniteliklerin segmentte nerede konumlandığının çok önemli olmadığı durumlarda, genellikle veri kümesinin sabit uzunluklu bir segmentinden özellik üretmek için çok etkilidir [8].


## III. SONUÇLAR

### A. Veri Kümesi

GRF sensörleri ile oluşturulan yürüyüş veritabanı Physionet'in resmi web sayfasında [9] ücretsiz olarak mevcuttur. Veriler, kontrol (n = 16; 2 erkek ve 14 kadın) ve NDD (Parkinson hastalığı -n = 15; 10 erkek ve 5 kadın, Huntington hastalığı -n = 19; 6 erkek ve 13 kadın; Amyotrofik lateral skleroz -n = 13; 10 erkek ve 3 kadın) için gerçek zamanlı olarak alınan yürüyüş parametresi aralıklarını içerir. Bahsi geçen veritabanı, her iki bacaktan yürüme parametrelerinin (duruş, salınım, çift destek ve adım) zaman aralığını bildirir. Veri kümesinin oluşturulma sürecinde [10], her denekten, düz zeminde 5 dakika boyunca 77 m uzunluğundaki düz koridor boyunca normal hızıyla yürümesi istenmiştir. Her denegin ayakkabılarının içindeki kuvvete duyarlı sensörlerden gelen kuvvet sinyalleri 300 Hz örnekleme frekansı ile kaydedilmiştir. Bu kuvvet sinyalleri, duruş, salınım, adım adım ve çift destek faz aralığını belirlemek için kullanılmıştır. Veri kümesinde bulunan öznitelikler Tablo I'de verilmiştir. Bahsi geçen öznitelikler Şekil II'de görsele dökülmüştür.

TABLO I. GRF VERİ KÜMESİNDE BULUNAN 12 ÖZNETELİK

Adım Süresi (Sol - Sağ için)
Savurma Süresi (Sol - Sağ için)
Savurmanın Adıma göre oranı (Sol ve Sağ için)
Duruş Süresi (Sol - Sağ için)
Duruşun Adıma göre oranı (Sol ve Sağ için)
Çift Destek Süresi
Çift Desteğin Adıma göre oranı



Şekil II. GRF veri kümesinde bulunan öznitelikler

### B. Performans Değerlendirmesi

Deneylerin gerçekleştirimi sırasında, K kat çapraz doğrulama yöntemi kullanılmıştır. K kat çaprazlama yönteminde veri seti k eşit parçaya bölünerek sıra ile her parça test için kullanılırken kalan parçaların tamamı eğitim için kullanılmaktadır. Bu sayede her bir örneğin hem test hem de eğitim için kullanılması garanti edilmiş olur. Bu çalışmada k değeri 10 olarak seçilmiştir. İlgili deneylerin sınıflandırma performansını değerlendirebilmek adına doğruluk, keskinlik, duyarlılık, ve F1 skor metrikleri kullanılmıştır.

Doğruluk (Accuracy - A), sınıflandırma modellerini değerlendirmek için kullanılan bir ölçü birimidir. Doğruluk, sınıflandırma modelinin doğru yaptığı tahminlerin tüm tahminlerine oranıdır. Doğruluk eşitlik (1)'de olduğu gibi formülüze edilebilir [11].

$$A = \frac{(DP+DN)}{(DP+DN+YP+YN)} \quad (1)$$

Keskinlik (Precision - P), gerçek pozitiflerin sayısının gerçek pozitiflerin ve yanlış pozitiflerin sayısına oranı olarak tanımlanır. Keskinlik formülü eşitlik (2)'de verilmiştir.

$$P = \frac{(DP)}{(DP+YP)} \quad (2)$$

Duyarlılık (Recall - R), gerçek pozitiflerin sayısının gerçek pozitiflerin ve yanlış negatiflerin sayısına oranı olarak tanımlanır. Duyarlılık eşitlik (3)'te olduğu gibi tanımlanabilir.

$$R = \frac{(DP)}{(DP+YN)} \quad (3)$$

DO, DN, DP, YN, YP ifadeleri sırasıyla doğruluk oranına, doğru sınıflandırılan negatif değerlere, doğru sınıflandırılan pozitif değerlere, yanlış sınıflandırılan negatif değerlere ve yanlış sınıflandırılan pozitif değerlere karşılık gelmektedir.

F1 skoru (F1), bir sınıflandırıcının keskinliğini ve duyarlılığını harmonik ortalamalarını olarak tek bir metrikte birleştirir. F1 skoru eşitlik (4)'te gösterilmiştir.

$$F1 = 2 * \frac{(P*R)}{(P+R)} \quad (4)$$

### C. Deneysel Kurulum

Bu çalışmada, ALS, PH, HH gibi Nörodejeneratif hastalıkların tespiti kontrol grubundan ayrıştırılabilmesi için tek boyut üzerinde çalışan bir Evrimsel Sinir Ağı (CNN) derin öğrenme modeli önerilmiştir. Bahsi geçen CNN mimarisi, kullanılan katmanlar ve sıralamaları, katmanların kullandığı biçimler Tablo II'de detaylı olarak incelenebilir. Buna göre 12\*1 boyutundaki veriler aktivasyon olarak 'Relu' kullanan 512 filtreye sahip bir 'Conv1D' katmanı tarafından işlenmiş çıkan özellik haritaları 'Flatten' ve 'Dropout' katmanlarından geçerek 'Dense' katmanlarına aktarılmıştır. Sırasıyla 2048, 1024 ve 2 nörona sahip 3 ayrı 'Dense' katmanlarından geçen veriler sınıflandırılmış olur. Ayrıca 'Mini-batch' boyutu olarak 64, öğrenme oranı (learning rate) 0.01 ve iyileştirici (optimizer) olarak 'adam' seçilmiştir, ilgili mimari 30 epoch olacak şekilde çalıştırılmıştır.

Tablo II. Kullanılan tek boyutlu CNN mimarisi

Katman	Biçim
(Conv1D)	(-, 12, 512)
(Activation-Relu)	(-, 12, 512)
(Flatten)	(-, 6144)
(Dropout)	(-, 6144)
(Dense)	(-, 2048)
(Dense)	(-, 1024)
(Dense)	(-, 2)
(Activation-Softmax)	(-, 2)

### D. Deneysel Sonuçlar.

Yürüyüş öznitelikleri, tek boyutlu CNN derin öğrenme algoritması ile sınıflandırılmıştır. İlgili yöntemin hastalık tespiti bazı sınıflandırma başarıları Tablo III'de gösterilmiştir. Buna göre önerilen yöntemin veri kümesinde bulunan tüm nörolojik hastalıkların tek bir etiket altında toplandığı ve sadece kontrol ve hasta olarak 2 ayrı grubu sınıflandırılma performansı doğruluk metriği özelinde %84.75, keskinlik ve duyarlılık özelinde sırasıyla %80.46 ve %81.92, ve F1 skor özelinde %81.15 olarak ölçülmüştür. Sadece ALS hastalarının ve kontrol grubunun sınıflandırılma performansı doğruluk metriği özelinde %92.09, keskinlik ve duyarlılık özelinde sırasıyla %91.65 ve %91.63, ve F1 skor özelinde %91.64 olarak ölçülmüştür. Sadece Huntington hastalarının ve kontrol grubunun sınıflandırılma performansı doğruluk metriği özelinde %78.92, keskinlik ve duyarlılık özelinde sırasıyla %79.77 ve %79.62, ve F1 skor özelinde %78.95 olarak ölçülmüştür. Sadece Parkinson hastalarının ve kontrol grubunun sınıflandırılma performansı doğruluk metriği

özelinde %84.39, keskinlik ve duyarlılık özelinde sırasıyla %84.67 ve %84.09, ve F1 skor özelinde %84.23 olarak ölçülmüştür.

Tablo III. Önerilen yaklaşım ile elde edilen sonuçlar

	Doğruluk (%)	Keskinlik (%)	Duyarlılık (%)	F1 skoru (%)
<b>Tüm hastalıklar Kontrole karşı</b>	84.75	80.46	81.92	81.15
<b>ALS Kontrole karşı</b>	92.09	91.65	91.63	91.64
<b>Huntington Kontrole karşı</b>	78.92	79.77	79.62	78.95
<b>Parkinson Kontrole karşı</b>	84.39	84.67	84.09	84.23

#### IV. TARTIŞMA VE SONUÇLAR

Nörodejeneratif semptomlara sahip insanlara teşhis konması genellikle zaman alıcı, öznel ve deneyim gerektiren bir problemdir. Bu hastalar temel motor becerilerini kaybetmekten muzdarip olduğundan, yürüyüş ölçümleri nörodejeneratif semptomlarının ciddiyetini tahmin etmede önemli bir rol oynar. Sensör teknolojisinde yaşana son gelişmeler ile vücuda takılan sensörlerin kullanımı arttırdığından, GRF sensörleri ve bu sensörler ile elde edilen öznelilikler, teşhis amacıyla kolaylıkla kullanılabilir. Elde edilen sonuçlar, hastalığın teşhisinin gelişmiş altyapılara ve testlere ihtiyaç duymadan yapılabileceğine kanıt niteliğinde olup dahası önerilen yöntemin teşhis konusunda doktorlara yardımcı bir karar destek sistemi olarak kullanılabilceğini göstermektedir.

#### TEŞEKKÜR

Bu çalışma 120E380 proje numarası altında Türkiye Bilimsel Ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenmiştir.

#### KAYNAKLAR

- [1] Selzler, R., Green, J. R. and Goubran, R., "Neurodegenerative Disease Prediction Based on Gait Analysis Signals Acquired with Force-Sensitive Resistors," *2018 IEEE Life Sciences Conference (LSC)*, Montreal, QC, 2018, pp. 122-125, doi: 10.1109/LSC.2018.8572063.
- [2] Baker, R., Esquenazi, A., Benedetti, M. G. and Desloovere, K., "Gait analysis : clinical facts," *European Journal of Physical And Rehabilitation Medicine*, 52(4):560-574, 2016.
- [3] Hausdorff, J.M, et al., "Altered fractal dynamics of gait: reduced stride-interval correlations with aging and Huntington's disease", *Journal of Applied Physiology*, 82 (1):262-269, 1997. Available: 10.1152/jappl.1997.82.1.262.
- [4] Hausdorff, M., Cudkovicz, R., Firtion, J., Goldberger, A., "Gait variability and basal ganglia disorders: Stride-to-stride variations of gait

cycle timing in parkinson's disease and Huntington's disease", *Movement Disorders*, 13(3): 428-437, 1998. Available: 10.1002/mds.870130310.

- [5] Khandoker, A.H., Lai, D.T.H., Begg, R.K., Palaniswami, M., "Wavelet-based feature extraction for support vector machines for screening balance impairments in the elderly", *IEEE Trans Neural Syst Rehabil Eng* 2007;15:587-97.
- [6] Liao, F., Wang, J. and He, P., "Multi-resolution entropy analysis of gait symmetry in neurological degenerative diseases and amyotrophic lateral sclerosis", *Medical Engineering & Physics*, 30(3):299-310, 2008. Available: 10.1016/j.medengphy.2007.04.014.
- [7] Myklebust, E., Lovett, B., Myklebust, N., Reynolds, L., and Prieto, T., "Two-dimensional coherence for measurement of asymmetry in postural steadiness", *Gait & Posture*, 29(1):1-5, 2009. Available: 10.1016/j.gaitpost.2008.05.011.
- [8] Kim, S. and Han, G., "1D CNN Based Human Respiration Pattern Recognition using Ultra Wideband Radar," *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, Okinawa, Japan, 2019, pp. 411-414, doi: 10.1109/ICAIIIC.2019.8669000.
- [9] Wu, Y., Krishnan, S., "Computer-aided analysis of gait rhythm fluctuations in amyotrophic lateral sclerosis", *Med Biol Eng Comput*, 47: 1165 (2009). <https://doi.org/10.1007/s11517-009-0527-z>
- [10] Wu, Y. and Krishnan, S., "Statistical Analysis of Gait Rhythm in Patients With Parkinson's Disease," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 2, pp. 150-158, April 2010, doi: 10.1109/TNSRE.2009.2033062.
- [11] Güney, S. and Erdaş, Ç. B., "A Deep LSTM Approach for Activity Recognition," *2019 42nd International Conference on Telecommunications and Signal Processing (TSP)*, Budapest, Hungary, 2019, pp. 294-297, doi: 10.1109/TSP.2019.8768815.