



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 13.08.2024
Kabul Tarihi : 22.10.2024

Received Date : 13.08.2024
Accepted Date : 22.10.2024

EMG SİNYALLERİ İLE DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK EL/PARMAK HAREKETİ TANIMA

HAND/FINGER GESTURE RECOGNITION USING DEEP LEARNING METHODS WITH EMG SIGNALS

Mehmet İsmail GÜRİSOY¹ (ORCID: 0000-0002-2285-5160)

¹ Adıyaman Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Adıyaman, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet İsmail GÜRİSOY, mgursoy@adiyaman.edu.tr

ÖZET

Elektromiyografi (EMG) sinyalleri ile el/parmak hareketi tanıma sistemleri, insan – bilgisayara etkileşimi, sanal gerçeklik ve protezler gibi alanlarda önemli bir yere sahiptir. Son yıllarda, EMG sinyalleri ile el/parmak hareketi tanıma için çeşitli derin öğrenme yöntemleri geliştirilmiştir. Bu çalışmada, NinaPRO DB1 veri setinden alınan 10 kanallı EMG cihazı ile 10 farklı kişiden beş parmak hareketini içeren biyoelektrik sinyaller kullanılmıştır. Veriler 500 ms uzunluğunda pencerelere bölünerek %70 oranında kayan pencere yöntemi kullanılmıştır. El/parmak sınıflandırma için Evrişimli Sinir Ağları (CNN) ve Uzun Kısa Dönem Hafıza (LSTM) derin öğrenme yöntemleri kullanılmıştır. Geliştirilen modellerin performansını değerlendirmek için Doğruluk, Kesinlik, Duyarlılık ve F-skor istatistiksel parametreleri kullanılmıştır. Geliştirilen CNN ve LSTM ile modeller 40 defa tekrar edilerek istatistiksel parametreler elde edilmiştir. Sonuç olarak CNN model ile geliştirilen sistemde; doğruluk %100, Kesinlik %100, Duyarlılık %100 ve F-skor %100 en iyi sınıflandırma değerleri ile üstün performansa sahip olduğunu göstermiştir. LSTM modeli ile de doğruluk %99, Kesinlik %98, Duyarlılık %98 ve F-skor %98 sınıflandırma metrikleri elde edilmiştir. Bu çalışmada sunulan derin öğrenme modeli, EMG sinyalleri ile el/parmak hareketi tanıma veya sınıflandırmada güçlü potansiyel ve etkinliğini açıklamaktadır.

Anahtar Kelimeler: EMG, derin öğrenme, el/parmak hareketi tanıma.

ABSTRACT

Electromyography(EMG) signals and hand/finger gesture recognition systems have an important place in fields such as human-computer interaction, virtual reality and prostheses. In recent years, various deep learning methods have been developed for hand/finger gesture recognition with EMG signals. In this study, bioelectric signals containing five finger gesture from 10 different people were used with a 10-channel EMG device obtained from the NinaPRO DB1 dataset. The data was divided into 500 ms long windows and the sliding window method was used at a rate of 70%. Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) deep learning methods were used for hand/finger gesture classification. Accuracy, Precision, Sensitivity and F-score statistical parameters were used to evaluate the performance of the developed models. The developed CNN and LSTM models were repeated 40 times and statistical parameters were obtained. As a result, the system developed with the CNN model showed superior performance with the best classification values of 100% accuracy, 100% precision, 100% sensitivity and 100% F-score. With the LSTM model, 99% accuracy, 98% precision, 98% sensitivity and 98% F-score classification metrics were obtained. The deep learning model presented in this study explains its strong potential and effectiveness in hand/finger gesture recognition or classification with EMG signals.

Keywords: EMG, deep learning, hand/finger gesture recognition

GİRİŞ

El hareketi tanıma sistemleri, esas olarak insan – bilgisayar etkileşim sistemlerine duyulan ihtiyaç nedeniyle son yıllarda büyük ölçüde gelişim göstermektedir (Toro-Ossaba et al., 2022). El/parmak tanıma sistemleri, önceden tanımlanmış bir dizi hareket arasından belirli bir el hareketi sınıfının tanınması ve hareketin gerçekleştirildiği tam anın belirlenmesini içerir (Benalcazar et al., 2018). El/parmak tanıma sistemlerinin biyomekanik, protez el/kol kontrol edilebilmesi, 3boyutlu animasyonlar, video oyunları, işaret dili tanıma ve tıp dahil olmak üzere geniş uygulama alanları bulunmaktadır (Saggio et al., 2020; W. T. Shi et al., 2018). Elektromiyografi (EMG) sinyalleri kullanılarak El/parmak hareketlerine yönelik uygulamalar geliştirilebilir. EMG kayıtları kasların kasılmasıyla üretilen elektrik sinyalleridir. Bu sinyaller, incelenmek istenen kas dokusuna doğrudan bir iğneyle (invazif) veya deri yüzeyine küçük elektrotlar yerleştirilerek (invazif olmayan) kaydedilir (Hahne et al., 2016). Yüzeysel elektromiyografisi (sEMG) gibi invazif olmayan yöntemler genel kullanım için daha pratiktir. sEMG kas aktivasyonunun yoğunluğu ve süresi hakkında bilgi sağlayan biyoelektrik sinyallerdir (Barona López et al., 2024).

El/parmak hareketi tanıma, insan – bilgisayar etkileşimi sistemlerinde yaygın olarak kullanılan bir tekniktir. Çok sayıda çalışma parmak hareketleri tanımanın yüksek sınıflandırma doğruluğuna ulaşmak için farklı modeller oluşturmuştur. El/parmak hareketi tanıma modelinin yapısı temel olarak 4 aşamadan meydana gelir: Veri toplama, ön işleme, özellik çıkarma ve sınıflandırma. Veri toplama aşamasında, atalet ölçüm sistemleri, sensör eldivenleri ve EMG kullanılmaktadır (Benalcázar et al., 2020; Pallotti et al., 2021). Ön işleme aşaması sinyali düzenleme ve filtreleme gibi tekniklerden oluşmaktadır. Özellik çıkarma aşamasında yaygın olarak Ortalama mutlak değer (MAV) Ortalama karekök (RMS), Standart sapma (SD) gibi yöntemler (X. Chen et al., 2021) ve ayrıca Evrişimli Sinir Ağları (CNN) gibi otomatik özellik çıkarım yöntemleri kullanılır. Sınıflandırma aşamasında makine öğrenme algoritmalarından k-En yakın komşu (kNN) (Elsayed et al., 2017), Destek vektör Makineleri (SVM) (Günay & Alkan, 2010; Miron et al., 2019), Rastgele Orman (RF) (Bargellesi et al., 2019) ve İleri beslemeli yapay sinir ağları (ANN) (Özerdem & Bamwenda, 2019) yaygın olarak kullanılmaktadır.

El/parmak hareketi tanıma problemleri genellikle iki şekilde analiz edilmektedir. Genel modeller ve kullanıcıya özel (bireysel) modeller. Genel bir model birden fazla gönüllüden alınan veriler ile eğitilir ve herhangi bir kişiden alınan örnekleri tanıyacak şekilde model geliştirilir. Bireysel modeller ise belirli bir kişiden alınan veriler ile eğitilir ve yalnızca o kişiden alınan örnekler işleyebilir. Bireysel modeller için %90-95 doğruluk elde ediliyorken, genel modeller için %80-85 arası doğruluk elde edilmektedir (Barona López et al., 2024).


Son yıllarda ileri yapay zeka teknolojisinin gelişmesiyle birlikte, derin öğrenme teknikleri ile el hareketi tanıma ilgili alanlarda araştırmaların odak noktası haline gelmiştir. Geleneksel makine öğrenme algoritmalarıyla karşılaştırıldığında, derin öğrenme yöntemlerinin büyük veri kümeleri üzerinde daha güçlü öğrenme yeteneği vardır. Bu da bir çok sınıflandırma algoritmalarına karşı üstünlüğünü kanıtlamıştır (H. Shi et al., 2024). Lin et al. (Lin et al., 2022) 12 parmak hareketini 10 farklı kişi ile sınıflandırma yapmıştır. CNN yöntemi ile %74,34 başarı oranını elde etmiştir. Özdemir ve ark. (Özdemir et al., 2020) El hareketlerinin sınıflandırması için ResNet mimarisini temel alan 50 katmanlı bir CNN mimarisi kullanmışlardır. Kısa Zamanlı Fourier Dönüşümü (STFT) ile yapılan EMG sinyallerinin renkli spektrogramları derin öğrenme modelinde eğitmişlerdir. Karnam ve ark. (Karnam et al., 2022) NINNA-PRO DB1 veri setini kullanarak CNN ve Bidirectional-LSTM yöntemlerini kullanarak hibrit EMGHandNet modelini geliştirmiştir. Farklı giriş veri uzunluğu kullanarak sınıflandırma işlemi yapmıştır. 20 ms, 250 ms ve 500 ms giriş veri uzunluklarında en yüksek sınıflandırma başarımları olan %91,76 doğruluğu elde etmiştir. Shanmuganathan ve ark. (Shanmuganathan et al., 2020) EMG sinyallerini kullanarak el hareketi tanıma için R-CNN ve Dalgacık özelliği çıkarma yöntemi önermişlerdir. Geliştirdikleri model ile %96,48 doğruluk elde etmişlerdir. Çalışmalarında kullanılan veri kümesi, dört farklı el hareketini gerçekleştiren on denekten oluşmaktadır. Tuncer ve ark. (Tuncer & Alkan, 2022) Üst ekstremite protezlerinin işlevselliğini ve kontrol kolaylığını iyileştirmek amacıyla EMG sinyallerini dört farklı derin öğrenme yöntemleri ile analiz etmişlerdir.

Önerilen çalışmanın önemli katkıları şunlardır:

1. Günlük hayatta en pratik kullanılan beş parmak hareketinin sınıflandırılmasında CNN ve LSTM yöntemleri kullanılmıştır.
2. EMG sinyallerinin özellik çıkarımı yerine ham EMG sinyalleri değerlendirilmiştir.
3. Sınıflandırma başarısının değerlendirilmesi için farklı yöntemler kullanılarak karşılaştırılmıştır.
4. Elde edilen sonuçlar ile önerilen derin öğrenme yöntemlerinin EMG sinyallerinin sınıflandırma performansının başarısını göstermektedir.

METERYAL VE YÖNTEMLER

Bu çalışmada, NinaPRO DB1 veri setinde günlük hayatta çok kullanılan beş parmak hareketi seçilerek el/parmak hareketleri sınıflandırma mimarisi geliştirildi. 500 ms uzunluğundaki veriler, kayan pencere yöntemi ile %70 oranında (150 ms uzunluğunda) örtüştürerek özellikler elde edildi. Derin öğrenme algoritmalarından CNN ve LSTM modelleri kullanılarak sınıflandırma işlemi yapıldı. Geliştirilen modelin eğitim mimarisi Şekil 1’de gösterilmektedir.



Şekil 1. Geliştirilen Model Mimarisi

Veri Seti (Dataset)

Bu çalışmada kullanılan el hareketlerinin sEMG sinyalleri, ücretsiz olarak temin edilebilen halka açık NinaPRO DB1 veri setinden alınmıştır. Veriler 10 tane Otto Bock MyBock 13E200 sEMG elektrotları kullanarak kaydedilmiştir. sEMG sinyalleri, Radyohumeral eklem yüksekliğinde ön kol çevresinde eşit aralıklarla yerleştirilmiş 8 elektrot ve felsor ve ekstansör kaslarına yerleştirilen 2 elektrot ile kaydedilmiştir. NinaPRO DB1 veri seti 27 denek tarafından gerçekleştirilen 52 farklı el hareketinden oluşmaktadır. Her hareket 10 defa tekrar içermektedir (Atzori et al., 2014).

NinaPRO DB1 veri setinden, günlük hayatta en pratik kullanılan beş parmak hareketini seçtik (Şekil 2). Bu hareketleri yapan 10 kişinin sEMG sinyallerini analiz ettik. Seçilen grup, boyları 169 cm – 187 cm, ağırlıkları 58 kg – 75 kg ve yaşları 23 – 32 arasında değişen 3 kadın ve 7 erkek gönüllüden oluşmaktadır. Gönüllülerin yapılması istenen parmak hareketleri Şekil 2’de gösterilmektedir.

10 gönüllüden alınan veriler, %70 eğitim, %20 doğrulama ve %10 test oranında ayrıldı. Her bir gönüllünün verileri ayrı ayrı analiz edildi.




Şekil 2. Çalışmada Kullanılan El Hareketleri

Evrişimli Sinir Ağları (Convolutional Neural Network – CNN)

Evrişimli Sinir Ağları (CNN), verilerde özellik çıkarma için etkili bir araçtır. CNN örüntü sınıflandırması, görüntü işleme, ses işleme ve model tanıma gibi birçok alanda yaygın olarak kullanılmaktadır (H. Wang et al., 2017). CNN öğrenme yoluyla kendini optimize eden nöronlardan oluşmaları bakımından geleneksel ANN benzerler. ANN temelinde olduğu gibi her nöron bir girdi değeri olarak işlemler gerçekleştirmektedir. CNN en büyük farklılıklarından biri, içindeki katmanların üç boyutta (height, width and depth) organize edilmiş nöronlardan oluşmasıdır (Gursoy, 2024; O’Shea & Nash, 2015). Bir CNN modeli genel olarak evrişim katmanı (Convolution Layer), havuzlama katmanı (Pooling Layer) ve tam bağlantılı katman (Fully Connected Layer) olmak üzere üç ana katmandan meydana

gelmektedir. (i) Evrişim Katmanı: CNN modelinin çekirdeğini oluşturmaktadır. Ana hesaplama işlemleri bu bölümde gerçekleşmektedir. Evrişim katmanının temel görevi giriş verilerinden öznelikleri belirlemektir. Evrişim katmanında nöronlar arasında bir bağlantı yoktur. Farklı katmanlardaki nöronlar, ağırlık paylaşımı tekniği ile lokal olarak birbirlerine bağlanır. (ii) Havuzlama Katmanı: Model oluşturulurken genellikle evrişim katmanından sonra havuzlama katmanı kullanılır. Bu katmanın ana amacı hesaplama maliyetini azaltmak ve evrişim katmanının özellik vektörünün boyutunu azaltmaktır. (iii) Tam Bağlantılı katman: Bu katman nöronlar ile birlikte ağırlıklardan oluşur. Nöronları farklı iki katmana bağlamak için kullanılır. Genellikle oluşturulan modelin son katmanları Tam Bağlantılı katmanlardan oluşur (Y. Chen et al., 2023; Gürsoy & Alkan, 2022).

Bu çalışmada NinaPRO DB1 veri seti ile CNN mimarisi geliştirilmiştir. Bu mimaride giriş verileri 500 ms (50 veri) boyutunda belirlenmiştir. 4 tane evrişim katmanı ve 3 tam bağlantılı katmandan oluşan bir mimari geliştirilmiştir. Çıkış katmanında 5 parmak hareketini sınıflandıran katman oluşturulmuştur. CNN mimarisi Şekil 3'de gösterilmektedir.




Şekil 3. CNN Mimarisi

Uzun Kısa-Dönem Hafıza (Long Short-Term Memory – LSTM)

Uzun Kısa Süreli Hafıza (LSTM) Hochreiter ve Schmidhuber tarafından 1990 yıllarının sonunda geliştirilen sıralı verilerin modellenmesi için uygulanan Tekrarlayan Sinir Ağları (Recurrent Neural Network -RNN) yaklaşımının özel bir türüdür (Hochreiter & Schmidhuber, 1997). Genellikle uzun vadeli bağımlılık gerektiren öğrenme için kullanılır. LSTM modeli hemen önceki veriler ile değil aynı zamanda geçmiş verileri de dikkate alarak gelecekteki verileri tahmin etmeye olanak tanır. Literatürde, son zamanlarda karmaşık veri kümelerinde LSTM birimlerinin daha iyi performans sergilediği görülmektedir (Abdelaziz et al., 2024; Toro-Ossaba et al., 2022; L. Wang et al., 2023; Zhang et al., 2024). Sürekli insan hareketlerinden elde edilen verilerin işlenmesinde zamansal sıra önemlidir (Garcia-Vellisca et al., 2021). Bu zamansal sırayı göz önünde bulundurarak veri sınıflandırma ve tahmin için LSTM çeşitli çalışmalarda iyi sonuçlar göstermiştir (Li et al., 2020).

LSTM mimarisi ile geliştirilen model Şekil 4'de gösterilmektedir. Bu mimaride giriş katmanı 50 örnek (500 ms) uzunluğunda verileri 10 tekrar ile (50 x 10) şeklinde belirlendi. Modelde ilk olarak 400 nörondan oluşan tam bağlantılı katman belirlendi. Sonradan iki tane 1000 LSTM bloğundan oluşan LSTM – 1 ve 2 katmanları oluşturuldu. Çıkış katmanı ise softmax fonksiyonunu kullanarak 5 parmak hareketini sınıflandıran birimden meydana geldi.



Şekil 4. LSTM Mimarisi

Performans Kriterleri

Sınıflandırma problemlerinde geliştirilen modelin başarısı, doğru olarak belirlenen sınıf verileri ile yanlış olarak belirlenen sınıf verilerinin sayıları karşılaştırılarak belirlenmektedir. Karışıklık matrisi (Confusion Matrix) (Tablo-1) kullanılarak geliştirilen modelin doğruluk, hassasiyet, duyarlılık ve F1 skor değerleri ile hesaplanabilir.

Tablo 1. Karışıklık Matrisi

	Doğru	Yanlış
Doğru	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
Yanlış	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk, doğru sınıflandırılan örnek sayısının toplam örnek sayısına oranı şeklinde hesaplanmaktadır (Denklem-1). (Icel et al., 2019) Kesinlik, doğru pozitif değerlerin, sınıflandırılan pozitif değerlere oranıdır (Denklem-2). Duyarlılık, geliştirilen model sonucunda elde edilen doğru sınıflandırılmış örnek sayısının, pozitif örnek sayısına oranıdır (Denklem -3). F-Skor, duyarlılık ve kesinlik değerlerinin harmonik ortalamasıdır (Denklem -4). Bazen modellerin başarımı değerlendirilirken tek başına Kesinlik veya Duyarlılık değerlendirilmesi eksik olabilmektedir. Bunun için F-skor parametresi literatürde sıklıkla kullanılmaktadır (Gursoy, 2024).

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

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

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

$$F - \text{skor} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4)$$


BULGULAR VE SONUÇLAR

Bu bölümde önerilen sınıflandırma modellerinin değerlendirilmesinde elde edilen sonuçlar sunulmaktadır. Analizler derin öğrenme algoritmalarından CNN ve LSTM modelleri ile analiz edilmiştir. Bu çalışmada geliştirilen modeller Python programlama dili kullanılarak gerçekleştirilmiştir. Derin öğrenme araçları olarak TensorFlow ve Keras kütüphaneleri kullanılmıştır. Önerilen modeller Windows 11 işletim sistemi ile IntelCore i7 2,2 GHz mikroişlemci ve 32 GB RAM özellikli bilgisayarda geliştirilmiştir.

Sinyal Ön İşleme

NinaPRO DB1 veri setinde veriler kaydedilirken elektrotların amplifikasyon kazancı yaklaşık 14.000 olarak ayarlandı. sEMG sinyalleri bant geçiren filtre ve Kök Ortalama Kare (RMS) ile düzeltilmiş versiyonunu sağlayan 10 tane MyoBock elektrot kullanılarak kaydedildi (Atzori et al., 2014). Veri kümesindeki kişilerin her bir hareketine ilişkin veriler %70 eğitim, %20 doğrulama ve %10 test olarak bölündü (Dobbin & Simon, 2011). Veri kümesinde her bir hareketin 10 tekrarı vardı, dolayısıyla 1.,3.,5.,6.,8.,9. ve 10. tekrarları eğitim için, 2. ve 4. tekrarları doğrulama için ve 7. Tekrarı ise test için kullanıldı.

EMG sinyallerinin sınıflandırma algoritmasından önce, verilerin boyutlarının düzenlenmesi gerekir. Kayan pencere tekniği, bir veri kümesi üzerinde yineleme yapılmasına yönelik bir yöntemdir. Verileri sabit boyuttaki örtüşen pencerelere bölmeyi ve her pencereyi bağımsız olarak işlemeyi içerir. Bu çalışmada sEMG sinyalleri 50 veri (500 ms) uzunluğunda pencerelere ayrıldı. Örtüşme değeri %70 (15 örnek – 150 ms) olarak seçildi (Şekil 5).



Şekil 5. sEMG Sinyallerinin Kayan Pencere


Sınıflandırma

NinaPRO DB1 veri seti kullanılarak 10 kişiden 5 parmak hareketi yapılması sonucunda elde edilen sEMG sinyalleri kullanılarak derin öğrenme algoritmalarından CNN ve LSTM yöntemleri ile sınıflandırma modeli geliştirilmiştir. Kişiler, her parmak hareketini 10 tekrar yaparak elde edilen sonuçlar kaydedilmiştir. Beş farklı sınıfa ait parmak hareketleri modellerde sınıflandırma sonucunda doğruluk, kesinlik, duyarlılık ve F-skor değerleri ile her iki modelin performansı belirlenmiştir. Geliştirilen CNN ve LSTM modellerinde karakteristik parametreleri Tablo 2 de gösterilmektedir.

Tablo 2. CNN - LSTM Modellerinin Karakteristik Parametreleri

Parametreler	Değer	
	CNN	LSTM
Input size	50 x 1	50 x 10
Epoc	200	100
Batch Size	72	32
Optimizer Function	Adam	Adam
Activation Function	Softmax	Softmax
Class	5	5

10 farklı kişinin 5 parmak hareketi ve 10 tekrardan oluşan veri seti geliştirilen CNN ve LSTM algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma aşamasında, her bir algoritma 40 defa tekrar edilmiştir. CNN algoritması ile geliştirilen modelde giriş olarak 500 ms uzunluğunda 50 veriden oluşan vektör kullanılmıştır. Algoritma 200 epoc ile eğitilmiştir. CNN algoritmasının eğitim doğruluk (Accuracy) ve kayıp (Loss) fonksiyon grafiği Şekil 6(a)' da gösterilmektedir. LSTM algoritması ile geliştirilen modelde 100 epoc kullanılarak model eğitilmiştir. Modele ait eğitim ve kayıp fonksiyonu Şekil 6(b) de gösterilmektedir. Şekil 6(a) ve (b) görüldüğü gibi model eğitim performansında uygun epoc değeri ile yaklaşık %100 başarı oranına ulaşmıştır.



Şekil 6. Eğitim Doğruluk (Accuracy) ve Kayıp (Loss) Fonksiyonları (a) CNN Model, (b) LSTM Model


CNN ve LSTM modelleri eğitim ve test işlemlerinden sonra elde edilen Doğruluk, Kesinlik, Duyarlılık ve F-skor istatistik parametreleri Tablo 3 de gösterilmektedir. Geliştirilen modellerde 10 kişiye ait istatistik parametreler kişilerin sEMG sinyal özelliklerinden dolayı bazı kişilerde CNN daha üstün sonuç verirken bazı kişilerde LSTM yöntemi daha üstün sonuç verdiği görülmektedir. Örneğin S7 kişinin CNN algoritması ile Ortalama %99 doğru

sınıflandırma elde ediliyorken aynı kişinin LSTM ile ortalama %95 doğru sınıflandırdığı görülmektedir. S10 kişisi için de LSTM yöntemi ortalama %96 doğru sınıflandırırken CNN yöntemi ortalama %94 doğru sınıflandırdığı görülmektedir. Genel olarak ortalama başarı oranları arasında büyük fark olmadığı görülmektedir. Derin öğrenme mimarisinin el/parmak hareketi sınıflandırma problemlerinde yüksek başarı elde ettiği görülmektedir.

CNN ve LSTM modelleri ile geliştirilen algoritmalarda 10 gönüllünün yaptığı 5 parmak hareketi sınıflandırmasında yüksek doğruluk elde edildiği görülmektedir. Her iki algoritma ile yapılan 40 tekrarlı uygulama sonucunda modellerin doğruluk değerleri Şekil 7’de grafikte gösterilmektedir.


Tablo 3. CNN ve LSTM Modellerinin İstatistiksel Sonuçları

Yöntem	Kişi	Doğruluk (Accuracy)			Kesinlik (Precision)			Duyarlılık (Recall)			F- Skor (F – Score)		
		Min	Max	Ort.	Min	Max	Ort.	Min	Max	Ort.	Min	Max	Ort.
CNN	S1	0,88	0,95	0,92	0,86	0,96	0,92	0,87	0,94	0,91	0,86	0,94	0,91
	S2	0,85	0,95	0,92	0,86	0,95	0,91	0,84	0,94	0,91	0,84	0,94	0,91
	S3	0,90	0,99	0,94	0,90	0,98	0,94	0,89	0,98	0,93	0,89	0,98	0,93
	S4	0,74	0,89	0,83	0,76	0,90	0,85	0,73	0,88	0,82	0,73	0,88	0,82
	S5	0,86	0,97	0,92	0,86	0,96	0,91	0,85	0,96	0,91	0,85	0,96	0,91
	S6	0,92	0,98	0,94	0,92	0,97	0,94	0,91	0,97	0,93	0,91	0,97	0,93
	S7	0,95	1,00	0,99	0,94	1,00	0,98	0,94	1,00	0,98	0,94	1,00	0,98
	S8	0,80	0,89	0,83	0,80	0,90	0,87	0,79	0,88	0,82	0,75	0,87	0,80
	S9	0,86	0,96	0,90	0,86	0,95	0,90	0,85	0,95	0,89	0,84	0,95	0,89
	S10	0,90	0,97	0,94	0,92	0,97	0,95	0,89	0,96	0,93	0,89	0,96	0,93
LSTM	S1	0,88	0,96	0,94	0,90	0,96	0,94	0,87	0,95	0,93	0,87	0,95	0,93
	S2	0,93	0,98	0,95	0,92	0,98	0,95	0,92	0,97	0,94	0,92	0,97	0,94
	S3	0,81	0,96	0,91	0,84	0,95	0,91	0,80	0,95	0,90	0,80	0,95	0,89
	S4	0,80	0,91	0,86	0,81	0,91	0,87	0,79	0,90	0,85	0,79	0,90	0,86
	S5	0,79	0,97	0,91	0,80	0,96	0,91	0,78	0,96	0,90	0,78	0,96	0,90
	S6	0,91	0,97	0,94	0,90	0,96	0,94	0,90	0,96	0,93	0,89	0,96	0,93
	S7	0,91	0,97	0,95	0,97	0,98	0,98	0,97	0,98	0,98	0,97	0,98	0,98
	S8	0,76	0,85	0,81	0,76	0,88	0,83	0,74	0,83	0,79	0,72	0,81	0,77
	S9	0,76	0,88	0,83	0,77	0,88	0,83	0,75	0,87	0,82	0,73	0,87	0,82
	S10	0,93	0,99	0,96	0,94	0,98	0,96	0,92	0,98	0,95	0,92	0,98	0,95



Şekil 7. Geliştirilen Modellerin Doğruluk Oranları (a) CNN Model (b) LSTM Model

Geliştirilen modellerin karışıklık matrisi Şekil 8(a) ve (b)’de gösterilmektedir. CNN ve LSTM modeller ile geliştirilen algoritmalarda sınıflandırma başarısı en yüksek modellerin karışıklık matrisi gösterilmiştir. Bu matriste CNN yöntemi ile test işleminde %100 başarı elde edilirken, LSTM yöntemi ile %99 başarı elde edildiği görülmektedir.



Şekil 8. Sınıflandırma Karışıklık Matrisleri (a) CNN Model (b) LSTM Model

TARTIŞMA

İnsan – bilgisayar etkileşimi çalışmalarında el/parmak hareketi tanıma/sınıflandırma çalışmaları literatürde yoğun bir şekilde yapılmaktadır. Video oyunu, işaret dili tanıma gibi uygulamalarda önemli katkı sağlayacaktır. Bu çalışmada, halka açık NinaPRO DB1 veriseti kullanılarak beş farklı parmak hareketlerinin sınıflandırılması amaçlanmıştır. Derin öğrenme algoritmalarından CNN ve LSTM sinir ağı modelleri geliştirilerek performansları değerlendirilmiş ve karşılaştırılmıştır. Her bir kişi için ayrı ayrı sınıflandırma işlemi yapılmıştır. Geliştirilen modeller 40 defa tekrar ederek doğruluk sonuçları bulunmuştur. CNN modeli ile ortalama doğruluk %83 - %99 arasında elde edilmiştir. LSTM yönteminde ise %81 - %96 arasında ortalama doğruluk değerleri elde edilmiştir. Geliştirilen mimarilerde her iki derin öğrenme algoritmasında da yüksek sonuçlar elde edilmiştir. Ayrıca model geliştirilirken maksimum başarı oranlarında %99-100 değerine ulaşabildiği görülmüştür. Modelin 40 defa tekrarı sonucu ortalama doğruluk oranları elde edilmiştir. Genel olarak ortalama doğruluk oranının yükseltilebilmesi için modelin tekrar sayısı artırılabilir.

Genel olarak elde edilen sonuçlar ile insan – bilgisayar etkileşimi sisteminin geliştirilmesine katkı sağlayacağını göstermektedir. Bu çalışmada kullanılan 5 parmak hareketi tanıma sistemi yeteneği daha fazla el/parmak hareketi tanıyabilecek modellere öncülük edeceği düşünülmektedir. Önerilen çalışma 5 parmak hareketini kapsadığı için veri miktarı kısıtlıdır. EMG sinyallerinin incelenmesinde genelleme yapabilmek için daha büyük verilere ihtiyaç duyulmaktadır.

Bu çalışmada, EMG tabanlı ampute çözümlerin sağlamlığını ve güvenilirliğini belirlemek için, sınıflandırıcıların farklı el/parmak hareketlerinin genelleştirilmesine ilişkin daha ileri analizler geliştirilmesine omurga görevi görebilir. Ayrıca çözümlerin güvenilirliği açısından gerçek zamanlı sınıflandırmanın sağlanması amacıyla ayrıntılı bir çalışma yapılabilir.

KAYNAKLAR

Abdelaziz, M. H., Mohamed, W. A., & Selmy, A. S. (2024). Hand Gesture Recognition Based on Electromyography Signals and Deep Learning Techniques. *Journal of Advances in Information Technology*, 15(2), 255–263. <https://doi.org/10.12720/jait.15.2.255-263>

Atzori, M., Gijbets, A., Castellini, C., Caputo, B., Hager, A. G. M., Elsig, S., Giatsidis, G., Bassetto, F., & Müller, H. (2014). Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, 1, 1–13. <https://doi.org/10.1038/sdata.2014.53>

- Bargellesi, N., Carletti, M., Cenedese, A., Susto, G. A., & Terzi, M. (2019). A Random Forest-based Approach for Hand Gesture Recognition with Wireless Wearable Motion Capture Sensors. *IFAC-PapersOnLine*, 52(11), 128–133. <https://doi.org/10.1016/j.ifacol.2019.09.129>
- Barona López, L. I., Ferri, F. M., Zea, J., Valdivieso Caraguay, Á. L., & Benalcázar, M. E. (2024). CNN-LSTM and post-processing for EMG-based hand gesture recognition. *Intelligent Systems with Applications*, 22(February), 200352. <https://doi.org/10.1016/j.iswa.2024.200352>
- Benalcázar, M. E., Caraguay, Á. L. V., & López, L. I. B. (2020). A user-specific hand gesture recognition model based on feed-forward neural networks, emgs, and correction of sensor orientation. *Applied Sciences (Switzerland)*, 10(23), 1–21. <https://doi.org/10.3390/app10238604>
- Benalcazar, M. E., Motoche, C., Zea, J. A., Jaramillo, A. G., Anchundia, C. E., Zambrano, P., Segura, M., Benalcazar Palacios, F., & Perez, M. (2018). Real-time hand gesture recognition using the Myo armband and muscle activity detection. 2017 IEEE 2nd Ecuador Technical Chapters Meeting, ETCM 2017, 2017-Janua, 1–6. <https://doi.org/10.1109/ETCM.2017.8247458>
- Chen, X., Li, Y., Hu, R., Zhang, X., & Chen, X. (2021). Hand Gesture Recognition based on Surface Electromyography using Convolutional Neural Network with Transfer Learning Method. *IEEE Journal of Biomedical and Health Informatics*, 25(4), 1292–1304. <https://doi.org/10.1109/JBHI.2020.3009383>
- Chen, Y., Wang, H., Zhang, D., Zhang, L., & Tao, L. (2023). Multi-feature fusion learning for Alzheimer's disease prediction using EEG signals in resting state. *Frontiers in Neuroscience*, 17. <https://doi.org/10.3389/fnins.2023.1272834>
- Dobbin, K. K., & Simon, R. M. (2011). Optimally splitting cases for training and testing high dimensional classifiers. *BMC Medical Genomics*, 4. <https://doi.org/10.1186/1755-8794-4-31>
- Elsayed, R. A., Sayed, M. S., & Abdalla, M. I. (2017). Hand gesture recognition based on dimensionality reduction of histogram of oriented gradients. 2017 Proceedings of the Japan-Africa Conference on Electronics, Communications and Computers, JAC-ECC 2017, 2018-Janua, 119–122. <https://doi.org/10.1109/JEC-ECC.2017.8305792>
- Garcia-Vellisca, M. A., Matran-Fernandez, A., Poli, R., & Citi, L. (2021). Hand-movement Prediction from EMG with LSTM-Recurrent Neural Networks. *Pan American Health Care Exchanges, PAHCE*, 2021-May. <https://doi.org/10.1109/GMEPE/PAHCE50215.2021.9434840>
- Günay, M., & Alkan, A. (2010). Spektral Yöntemler ve DVM Sınıflandırıcı ile EMG İşaretlerinin Tasnifi Classification of EMG Signals by Spectral Methods and SVM Classifier. *KSU Journal of Engineering Sciences*, 13(2), 63–69.
- Gursoy, M. I. (2024). Biometric Authentication Based on EMG Hand Gestures Signals Using CNN. *Elektronika Ir Elektrotehnika*, 30(2), 54–62. <https://doi.org/10.5755/j02.eie.33777>
- Gürsoy, M. İ., & Alkan, A. (2022). Investigation Of Diabetes Data with Permutation Feature Importance Based Deep Learning Methods. *Karadeniz Fen Bilimleri Dergisi*, 12(2), 916–930. <https://doi.org/10.31466/kfbd.1174591>
- Hahne, J. M., Farina, D., Jiang, N., & Liebetanz, D. (2016). A novel percutaneous electrode implant for improving robustness in advanced myoelectric control. *Frontiers in Neuroscience*, 10(MAR), 1–10. <https://doi.org/10.3389/fnins.2016.00114>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1–32.
- Icel, Y., Mamis, M. S., Bugutekin, A., & Gursoy, M. I. (2019). Photovoltaic Panel Efficiency Estimation with Artificial Neural Networks: Samples of Adiyaman, Malatya, and Sanliurfa. *International Journal of Photoenergy*, 2019, 1–12. <https://doi.org/10.1155/2019/6289021>
- Karnam, N. K., Dubey, S. R., Turlapaty, A. C., & Gokaraju, B. (2022). EMGHandNet: A hybrid CNN and Bi-LSTM architecture for hand activity classification using surface EMG signals. *Biocybernetics and Biomedical Engineering*, 42(1), 325–340. <https://doi.org/10.1016/j.bbe.2022.02.005>
- Li, Z., Zuo, J., Han, Z., Han, X., Sun, C., & Wang, Z. (2020). Intelligent classification of multi-gesture EMG signals based on LSTM. *International Conference on Artificial Intelligence and Electromechanical Automation, AIEA 2020*, 2020, 62–65. <https://doi.org/10.1109/AIEA51086.2020.00020>

- Lin, Y., Palaniappan, R., De Wilde, P., & Li, L. (2022). Reliability Analysis for Finger Movement Recognition With Raw Electromyographic Signal by Evidential Convolutional Networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 96–107. <https://doi.org/10.1109/TNSRE.2022.3141593>
- Miron, C., Pasarica, A., Costin, H., Manta, V., Timofte, R., & Ciucu, R. (2019). Hand gesture recognition based on SVM classification. *7th E-Health and Bioengineering Conference, EHB 2019*, 2–7. <https://doi.org/10.1109/EHB47216.2019.8969921>
- O’Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. <http://arxiv.org/abs/1511.08458>
- Ozdemir, M. A., Kisa, D. H., Guren, O., Onan, A., & Akan, A. (2020). EMG based Hand Gesture Recognition using Deep Learning. *2020 Medical Technologies Congress, TIPTEKNO 2020*, 1919, 1–4. <https://doi.org/10.1109/TIPTEKNO50054.2020.9299264>
- Özerdem, M. S., & Bamwenda, J. (2019). Recognition of static hand gesture with using ANN and SVM. *DÜMF Mühendislik Dergisi*, 10(2), 561–568. <https://doi.org/10.24012/dumf.569357>
- Pallotti, A., Orenco, G., & Saggio, G. (2021). Measurements comparison of finger joint angles in hand postures between an sEMG armband and a sensory glove. *Biocybernetics and Biomedical Engineering*, 41(2), 605–616. <https://doi.org/10.1016/j.bbe.2021.03.003>
- Saggio, G., Cavallo, P., Ricci, M., Errico, V., Zea, J., & Benalcázar, M. E. (2020). Sign language recognition using wearable electronics: Implementing K-nearest neighbors with dynamic time warping and convolutional neural network algorithms. *Sensors (Switzerland)*, 20(14), 1–14. <https://doi.org/10.3390/s20143879>
- Shanmuganathan, V., Yesudhas, H. R., Khan, M. S., Khari, M., & Gandomi, A. H. (2020). R-CNN and wavelet feature extraction for hand gesture recognition with EMG signals. *Neural Computing and Applications*, 32(21), 16723–16736. <https://doi.org/10.1007/s00521-020-05349-w>
- Shi, H., Jiang, X., Dai, C., & Chen, W. (2024). EMG-based Multi-User Hand Gesture Classification via Unsupervised Transfer Learning Using Unknown Calibration Gestures. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 32, 1119–1131. <https://doi.org/10.1109/TNSRE.2024.3372002>
- Shi, W. T., Lyu, Z. J., Tang, S. T., Chia, T. L., & Yang, C. Y. (2018). A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study. *Biocybernetics and Biomedical Engineering*, 38(1), 126–135. <https://doi.org/10.1016/j.bbe.2017.11.001>
- Toro-Ossaba, A., Jaramillo-Tigeros, J., Tejada, J. C., Peña, A., López-González, A., & Castanho, R. A. (2022). LSTM Recurrent Neural Network for Hand Gesture Recognition Using EMG Signals. *Applied Sciences (Switzerland)*, 12(19). <https://doi.org/10.3390/app12199700>
- Tuncer, S. A., & Alkan, A. (2022). Classification of EMG signals taken from arm with hybrid CNN-SVM architecture. *Concurrency and Computation: Practice and Experience*, 34(5), 16723–16736. <https://doi.org/10.1002/cpe.6746>
- Wang, H., Yi, H., Peng, J., Wang, G., Liu, Y., Jiang, H., & Liu, W. (2017). Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network. *Energy Conversion and Management*, 153, 409–422. <https://doi.org/10.1016/j.enconman.2017.10.008>
- Wang, L., Fu, J., Chen, H., & Zheng, B. (2023). Hand gesture recognition using smooth wavelet packet transformation and hybrid CNN based on surface EMG and accelerometer signal. *Biomedical Signal Processing and Control*, 86(PB), 105141. <https://doi.org/10.1016/j.bspc.2023.105141>
- Zhang, K., Badesa, F. J., Liu, Y., & Ferre Pérez, M. (2024). Dual Stream Long Short-Term Memory Feature Fusion Classifier for Surface Electromyography Gesture Recognition. *Sensors*, 24(11), 1–18. <https://doi.org/10.3390/s24113631>