



Investigation of the effects of different arm positions and angles in sEMG-based hand gesture recognition on classification success

Emre Parlak^{1*}, Ulvi Başpınar²

¹Department of Computer Engineering, Faculty of Electrical - Electronics, Yıldız Technical University, 34220, İstanbul, Türkiye

²Department of Electrical – Electronics Engineering, Faculty of Technology, Marmara University, 34722, İstanbul, Türkiye

Highlights:

- Data recorded at varying arm positions and wrist angles
- The effects of using only EMG signals on arm position and wrist angle classification performance were investigated
- The effects of acceleration and gyroscope data on gesture classification were analyzed

Keywords:

- Gesture Recognition
- sEMG
- ANN
- SVM

Article Info:

Research Article

Received: 25.06.2022

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1135737

Acknowledgement:

FEN-K-090518-0244 – “Computer Assisted Hand Rehabilitation System”, Marmara University BAPKO

Correspondence:

Author: Emre Parlak
e-mail: emre.parlak@yildiz.edu.tr
phone: +90 212 383 57 30

Graphical/Tabular Abstract

We often make different hand gestures in daily life. Hand gestures can be predicted by analyzing the sEMG signals generated by muscle contraction. Since hand gestures are performed at different wrist angles and arm positions during the day, these parameters should also be considered in the studies. In this study, different scenarios were analyzed by labeling them as G1, G2, ..., G5 and the results are presented in Table A. In total 9 different positions were analyzed using 3 arm positions and 3 wrist angles. In the first group (G1), only hand movements performed in the same arm position and the same wrist angle were detected. In the second group (G2), hand movements performed in the same arm position at different wrist angles were classified. In the third group (G3), hand movements performed in all arm positions and at all wrist angles were classified. In the fourth group (G4), acceleration and gyroscope data were added to the data in the second group. In the fifth group (G5), acceleration and gyroscope data were added to the third group.

Table A. Classification results with different configurations

	EMG		EMG + acceleration			EMG + acceleration + gyro			
	ANN	SVM	ANN	SVM		ANN	SVM		
	25 neurons	1-vs-1	1-vs-all	25 neurons	1-vs-1	1-vs-all	25 neurons	1-vs-1	1-vs-all
G1	80%	81,00%	80,07%						
G2	84%	82,50%	80,28%						
G3	82%	82,22%	78,47%						
G4	84,31%	82,50%	80,28%	86,67%	86,67%	85,14%	85,14%	86,11%	85,55%
G5	82%	82,22%	78,47%	83%	82,22%	82,50%	82%	81,67%	81,67%

Purpose: The common point of studies in the literature is that most of the EMG recordings were made while the forearm was fixed and in a certain position. The arm position and wrist angles where the gesture is made are also factors that affect the gesture recognition. However, arm position and wrist angle are constantly changing in daily life, and therefore it is important to examine the effects of different arm positions and wrist angles on EMG-based hand gesture classifications. In this study, it was aimed to determine hand gestures, wrist angles and arm positions by using surface electromyogram signals from the right forearms of thirteen persons, and at the same time, the effects of different arm positions and angles on hand gesture classification were studied.

Theory and Methods: Artificial neural networks and support vector machines were used as classification tools and performance comparison was made. 5 time domain and 1 frequency domain features were extracted from the collected data. The three arm positions used in the study were arm parallel to the body, arm parallel to the ground and arm angled upwards at an average of 45 degrees. In the wrist angles, it was named as 0 degrees with the palm facing the ground, 90 degrees with the palm facing the person and 180 degrees with the palm facing out. A total of 9 positions were obtained by combining the specified positions of the arm and the angles of the wrist.

Results: In the classifications made in five different groups, ANN achieved between 80% and 84% success. With the addition of acceleration data to EMG data, this success has reached about 86%. The SVM classifier achieved a success between 78% and 80% in the same groups, and this success reached about 86% with the addition of acceleration data.

Conclusion: In the study, the hand gesture classification results were improved by using emg data, acceleration, and gyroscope data together. If it is desired to determine the arm position and wrist angle which the gesture is made, it has been seen that the acceleration and gyroscope data greatly positively affects the success rate.



sEMG tabanlı el hareket tanımada farklı kol pozisyon ve açılarının sınıflandırma başarısına olan etkilerinin incelenmesi

Emre Parlak^{1*}, Ulvi Başpınar²

¹Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34220, Esenler İstanbul, Türkiye

²Marmara Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 34722, Göztepe, İstanbul, Türkiye

ÖNEÇİKANLAR

- Veri kayıtları kolun ve bileğin değişen açılarında yapılmıştır
- Yalnızca EMG sinyalleri kullanmanın kol pozisyonu ve bilek açısı tahmin performansına etkileri incelenmiştir
- İvme ve jiroskop verilerinin hareket sınıflandırmaya etkileri incelenmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 25.06.2022

Kabul: 23.02.2024

DOI:

10.17341/gazimmfd.1135737

Anahtar Kelimeler:

EMG,
yapay sinir ağları,
destek vektör makinesi,
el hareket tanıma,
insan makine etkileşimi

ÖZ

Günlük yaşamda etkin bir şekilde kullanılması için tasarlanan yüzeysel elektromiyografi (sEMG) sinyal tabanlı kontrol edilen aktif protezler ve insan makine etkileşimli sistemlerin kolun farklı açı ve pozisyonlarında da yüksek doğrulukta çalışması önemlidir. Bu amaçla çalışmada kolun üç farklı pozisyonunda ve üç farklı açıda alınan sEMG kayıtları, ivme ve jiroskop verileri ile desteklenerek dört farklı el hareketinin sınıflandırılması yapılmıştır. Sınıflandırmada kullanılan veri (8 kanal sEMG, ivme ve jiroskop) 13 katılımcının sağ ön kolundan alınmıştır. Çalışmada sEMG sinyallerinden altı adet, ivme ve jiroskop verilerinden de üç adet özellik kullanılarak veri seti oluşturulmuştur. Sonuç olarak, farklı kol pozisyonlarının ve açıların el hareketlerinin sınıflandırılmasını nasıl etkilediği metodik olarak araştırılmıştır. Hareketin yapıldığı farklı kol pozisyonları ve açıları nedeniyle ortaya çıkan olumsuz etkilerin ivme ve jiroskop verileri kullanılarak giderilip giderilemeyeceği noktasında da değerlendirmeler yapılarak sınıflandırıcı performanslarına etkilerine yer verilmiştir. Sınıflandırıcı olarak Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) tercih edilmiştir. Beş farklı kategoride yapılan incelemelerde DVM sınıflandırıcıları ortalama %83 başarı sağlarken YSA sınıflandırıcıları ortalama %82 başarı sağlamaktadır. Farklı pozisyonlarda ivme ve jiroskop verilerinin hareket sınıflama performansına çok az bir katkı sunduğu belirlenmiştir. Yapılan değerlendirme sonucu sEMG tabanlı bir sistemin eğitiminde ön kolun tüm pozisyon ve açılarında eğitim verisinin toplanması sınıflandırma sonuçlarını iyileştirdiği tespit edilmiştir.

Investigation of the effects of different arm positions and angles in sEMG-based hand gesture recognition on classification success

HIGHLIGHTS

- Data recordings were made at varying angles of the arm and wrist
- The effects of using only EMG signals on arm position and wrist angle classification performance were investigated
- The effects of acceleration and gyroscope data on gesture classification were analyzed

Article Info

Research Article

Received: 25.06.2022

Accepted: 23.02.2024

DOI:

10.17341/gazimmfd.1135737

Keywords:

EMG,
artificial neural networks,
support vector machines,
hand gesture recognition,
human machine interface

ABSTRACT

The effective operation of surface electromyography (sEMG) signal-based controlled active prostheses and human-machine interaction systems in daily life is crucial to work with high accuracy in different angles and positions of the arm. In this study, sEMG recordings from three different positions and angles of the arm were combined with accelerometer and gyroscope data to classify four different hand movements. The classification data (8-channel sEMG, accelerometer, and gyroscope) were collected from the right forearm of 13 participants. To create the dataset, six features were extracted from sEMG signals and three from accelerometer and gyroscope data. As a result, the methodological investigation was carried out on how different arm positions and angles affect the classification of hand movements. Evaluations were also made regarding whether the adverse effects arising from different arm positions and angles of the movement could be mitigated using accelerometer and gyroscope data, and their effects on classifier performance were discussed. As classifiers, Artificial Neural Networks (ANN) and Support Vector Machines (SVM) were used. SVM classifiers achieved an average success rate of 83% in the five different categories of analysis, while ANN classifiers achieved an average success rate of 82%. It was found that accelerometer and gyroscope data in various positions contributed very little to the performance of movement classification. As a result of the evaluation, it was discovered that collecting training data in all positions and angles of the forearm improved classification results for a sEMG-based systems.

1. Giriş (Introduction)

Vücutta meydana gelen çeşitli elektrokimyasal olaylar sonucu doku veya organlarda oluşan potansiyel farklara biyoelektrik sinyaller denir. Elektromiyogram (EMG), bilinen ve sıklıkla kullanılan bir biyoelektrik sinyaldir. Yüzeiden ölçülen EMG sinyallerine yüzeysel (surface) elektromiyogram (sEMG) sinyalleri adı verilir. Kas liflerinin kasılıp gevşemesiyle oluşan bu sinyaller ile hastalık teşhisi, vücut kondisyon tahminleri, insansı hareket modelleme ve İnsan Makine Etkileşimli (İME) sistemlerin kontrolü yapılabilmektedir [1-3]. EMG tabanlı İME çalışmalarının odağında özellikle engelli ve yatalak bireyler olmakla beraber çok farklı alanlarda da özgün uygulamalar yapılmaktadır. Ayak bileğinden elde edilen EMG sinyalleri kullanılarak ayak bileğine dair bazı hareketlerin robot bileklere iletimi sağlanabilmektedir [4] Bu çalışma alanlarından bazıları da EMG tabanlı protez kol ve el hareket tanıma sistemleridir. El veya kol, gün içinde çok yaygın kullanıldığından önemli bir organdır. Eğer kol üzerinden bir ölçüm yapılarak hareketi yapan kişinin amacı anlaşılabilirse, protez ve robot kol gibi uygulamalar ve hatta tekerlekli sandalyeler gibi başka çeşitli uygulamalar daha yüksek doğruluk ile kontrol edilebilir [5].

Literatürde incelenen çalışmalarda özellikle YSA ve DVM sınıflandırıcı kullanan çalışmaların üzerine durulmuştur. Bu çalışmalardan YSA sınıflandırıcısı kullanarak yapılan çalışmalara örnekler vermek gerekirse; örneğin Başpınar, Varol [6], EMG sinyallerini ölçmek ve el hareketlerini sınıflandırmak için ev yapımı dört kanallı bir sEMG amplifikatör devresi tasarlamışlar; kaydettikleri sEMG sinyalleri dalgacık tabanlı filtreleme kullanılarak filtrelenmiş ve sınıflandırma için 8 zaman alanı ve 2 frekans alanı özelliği çıkarmışlardır. Yedi farklı el hareketinin sınıflandırılması yapay sinir ağı ve bulanık sınıflandırıcılar kullanılarak gerçekleştirmiş ve performansları karşılaştırmışlardır. Rehabilitasyon çalışmalarını ön plana alarak hazırlanan bir başka çalışmada Caesarendra vd. [7], sekiz el hareketinden elde edilen EMG sinyallerinin çok sınıflı sınıflandırılması için bir sınıflandırma yöntemi sunmaktadır. Çalışmada Endonezya'daki engelli insanlar için biyoteknolojik bir el geliştirmeyi amaçlamaktadırlar. Yöntemleri özellik çıkarma, Temel Bileşen Analizi (PCA) kullanılarak boyutluluk özelliğini azaltma ve YSA kullanarak sınıflandırmayı içerir. Sonuçlar %85,7'lik bir eğitim doğruluğu ve %81,2'lik bir test doğruluğu göstermektedir. Çalışma 15 katılımcıyla gerçekleştirilmiştir. Protez kollar düşünülerek hazırlanmış bir başka çalışmada Saeed vd. [8], protez ellerin kontrolünde kullanılan EMG sinyaller için sınıflandırıcıların karşılaştırılması bir analizini sunmaktadır. Çalışma, EMG verilerine dayalı el hareketlerini sınıflandırmada doğrusal diskriminant analizi (LDA) ve YSA performansını karşılaştırmaktadır. NinaPro veri tabanı ve sağlıklı ve ampute deneklerden toplanan veriler dahil olmak üzere iki veri kümesi kullanılmıştır. Sonuçlar, YSA'nın her iki veri kümesi için de sınıflandırma doğruluğu açısından LDA'dan daha iyi performans gösterdiğini ortaya koymaktadır.

Bazı çalışmalar tıpkı bu çalışmada olduğu gibi veri setlerini MYO bileklik kullanarak hazırlamışlardır. Örneğin Sayın vd. [9], beş denekten sEMG verisi toplamak için MYO kol bandı kullanmış ve sınıflandırıcı olarak YSA uygulamışlardır. Beş el hareketini sınıflandırmışlardır: el açık, el kapalı, silindirik kavrama, yanak çimdikleme (anahtar kavrama) ve işaret parmağı açma. Sınıflandırma için sEMG sinyallerinden ortalama mutlak değer, eğim işareti değişimi, dalga şekli uzunluğu, Willison genliği ve ortalama frekans gibi farklı özellikler çıkarılmıştır. Çalışmada beş denegın tamamında ortalama %88,4 sınıflandırma oranı elde edilmiştir. Benzer şekilde Chung E, Benalcázar M [10], ön kolda ölçülen EMG sinyallerini kullanarak gerçek zamanlı el hareketi tanıma için bir model önermektedir. Model özellik çıkarımı için bir otomatik kodlayıcı ve

sınıflandırma için bir ileri beslemeli sinir ağı kullanılmaktadır. Model ortalama 3 ms yanıt süresiyle ortalama %85,08 tanıma doğruluğuna ulaşmaktadır. Bireysel eğitime ihtiyaç duymadan herhangi bir kullanıcının hareketlerini tanıyabilen genel bir modeldir. Model 60 kullanıcı üzerinde test edilmiş ve literatürdeki diğer modellere kıyasla rekabetçi doğruluk göstermiştir. EMG sinyallerini toplamak için Myo Armband kullanılmış ve veri tabanı 5 farklı kullanıcı tarafından gerçekleştirilen 120 hareketten oluşmuştur.

Literatürde sığ YSA çalışmalarının yanı sıra derin yapılar kullanan çalışmalar da bulunmaktadır. Bunlara örnek olarak Asif vd. [11], sEMG sinyallerinden 6 kanallı verileri 18 katılımcıdan elde etmiş ve derin ağ kullanmışlardır. Farklı hiper-parametrelerin el hareketlerinin sınıflandırma doğruluğu üzerindeki etkisini analiz etmek için bir evrişimli sinir ağı (CNN) kullanmışlardır. Sonuçlar, 80-100 epok ile 0.0001 veya 0.001 öğrenme oranının en iyi performansı verdiğini göstermiştir. Ayrıca, belirli el hareketleri çalışma boyunca sürekli olarak daha iyi performans göstermiştir. Derin ağlara ek olarak bazı çalışmalar iki farklı mimari kullanmışlardır. Bunlara örnek olarak Alba-Flores vd. [12], iki farklı YSA mimarisini geliştirmiş ve karşılaştırmışlardır. İlk mimaride dokuz el hareketini sınıflandırmak için tek bir YSA kullanılmış ve ortalama %83,43 doğruluk elde edilmiştir. İkinci mimaride her biri belirli bir el hareketini tespit etmek için eğitilmiş dokuz bağımsız YSA'dan oluşmaktadır ve ortalama %91,85 doğruluk elde etmiştir.

Bizim çalışmamızda kullandığımız benzer şekilde farklı sınıflandırıcılar kullanıp performans karşılaştırması yapan çalışmalar da vardır. Örneğin Cerci, Temeltaş [13], başparmak, işaret, orta, yüzük, başparmak-ışaret, başparmak-orta, başparmak-yüzük ve el kapatma hareketleri dahil olmak üzere dört kişiden alınan sekiz farklı hareket sinyali kullanmışlardır. Sinyaller pencereleme kullanılarak daha küçük parçalara bölünmüş ve özellik vektörleri oluşturmuşlardır. Bu özellik vektörleri daha sonra k-en yakın komşu (kNN) ve YSA algoritmaları kullanılarak sınıflandırılmıştır. Sonuçlar, kNN'nin 150 ms'de %89 doğruluk elde ettiğini, YSA'nın ise %93 doğruluk elde ettiğini göstermektedir. Elbette yapılan çalışmalar bunlarla kısıtlı değildir. Örneğin bir çalışmada bulanık mantık sınıflandırıcı kullanılarak 30 katılımcıdan elde edilen verilerden yedi el hareketi tespiti yapılmıştır [14]

Literatür taramasında DVM sınıflandırıcılar kullanan çalışmalar da incelenmiştir. Yoshikawa vd. [15], EMG sinyalleri ve DVM kullanarak el hareketlerini tahmin etmek için bir yöntem önermektedirler. Önerilen yöntem iki aşamadan oluşmaktadır: DVM'ler kullanarak el hareketi sınıflandırması ve doğrusal modellere dayalı eklem açıların tahmini. Yöntemin etkinliği yedi el hareketi üzerinde yapılan deneylerle gösterilmiştir. Tek kişinin ön kolundan 4 kanallı alınan verilerden 7 özellik çıkarmışlardır. Çalışmalarda çok sınıflı DVM sınıflandırıcılar kullanılmaktadır. Rekhi vd. [16], dalgacık paket dönüşümü kullanılarak sEMG sinyalinin analiz edilmesini ve tekil değer ayrıştırması kullanılarak özelliklerin çıkarılmasını önermektedirler. Bu özellikler daha sonra altı farklı el hareketini sınıflandırmak için çok sınıflı bir DVM için girdi olarak kullanılır. Sonuçlar yöntemin el hareketlerini sınıflandırmada %96'nın üzerinde bir doğruluğa ulaştığını göstermektedir. Çalışma, tekil değer ayrıştırma ve çok sınıflı DVM kullanımının farklı el hareketleri için EMG sinyallerini doğru bir şekilde sınıflandırmada etkili olduğunu göstermektedir.

Çalışmalar birden fazla özellik kullanabildikleri gibi tek özellik de kullanabilmektedirler. Örneğin Alkan, Günay [17], kol protezi kontrolü için EMG sinyallerinin sınıflandırılmasını ele almaktadırlar. Çalışmada dört farklı kol hareketi için biceps ve triceps kaslarından kaydedilen EMG sinyalleri kullanılmıştır. Sinyalleri sınıflandırmak

için diskriminant analizi ve DVM sınıflandırıcısı kullanmışlardır. Sınıflandırma öncesinde ortalama mutlak değer (MAV) kullanılarak özellik vektörleri oluşturulmuştur. Elde edilen sınıflandırma doğruluk oranları çok yüksek olup %96 ile %99 arasında değişmektedir. Çalışmada tek kişiden iki kanallı ölçümler yapılmıştır. Tek özellik kullanımı açısından buna benzeyen bir başka çalışmada ise Altan vd. [18] protez bir uzvu kontrol etmek için EMG sinyallerinin kullanımını tartışmaktadır. Çalışmada tek kişiden 8 kanal üzerinden veriler elde edilmiş ve tek özellik kullanılarak DVM sınıflandırıcı ile %94 başarı elde edilmiştir. Tek özellik kullanan bir başka çalışma, bahsedilen bu iki çalışmadan farklı olarak gömülü sistem kullanmaktadır. Tavakoli vd. [19], sadece iki EMG kanalı kullanarak dört el hareketini (açma, kapama, içeri sallama, dışarı sallama) tanımayı amaçlamaktadır. Sistem tasarımı kuru elektrotların kullanımını ve kanalların ön kol üzerinde belirli bir şekilde konumlandırılmasını içerir. Sinyal bir mikro denetleyici tarafından alınmadan önce filtrelenir ve yükseltilir. Sistem yüksek bir tanıma yüzdesi, hızlı işlem süresi ve diğer uzuv hareketlerine karşı sağlamlık elde etmeyi amaçlamaktadır. Sistemin yedi denek üzerinde yapılan test sonuçları tek özellik kullanılarak %90 olarak belirtilmiştir. Benzer şekilde gömülü sistem kullanan bir başka çalışma, bahsedilen bir önceki çalışmadan farklı olarak birden fazla özellik kullanmaktadır. Benatti vd. [20], giyilebilir cihazlar kullanarak gerçek zamanlı EMG tabanlı el hareketi tanıma için gömülü bir çözüm sunmaktadır. Sistem üst düzey EMG sensörleriyle aynı doğruluğa ancak daha düşük bir maliyetle ulaşmaktadır. Yazarlar farklı faktörlerin tanıma doğruluğu ve hesaplama talebi üzerindeki etkisini değerlendirmek için 4 kullanıcıdan 7 hareketten oluşan bir veri kümesi oluşturmuşlardır. Sistem %90 sınıflandırma oranına ve 29,7 mW güç tüketimine ulaşarak 44 saat kesintisiz çalışmaya olanak sağlamıştır.

İki farklı modeli bir arada kullanıp model düzeyinde füzyon yapan çalışmalar da bulunmaktadır. Subasi [21], parçacık sürü optimizasyonu (PSO) ve DVM hibrit modelini kullanarak EMG sinyallerini sınıflandırmak için yeni bir yaklaşım sunmaktadır. Önerilen yöntem EMG sinyallerini ayrık dalgacık dönüşümü (DWT) kullanarak frekans alt bantlarına ayırır ve bu alt bantlardan istatistiksel özellikler çıkarır. PSO-SVM modeli, genel doğruluk oranı %97,41 ile geleneksel makine öğrenimi yöntemlerine kıyasla daha yüksek sınıflandırma doğruluğu elde etmiştir. Veriler 27 katılımcıdan iğne tipi invazif elektrot ile tek kanallı elde edilmiş ve 4 özellik kullanılmıştır. Bir başka hibrit model kullanan çalışmada ise Rossi vd. [22], sınıflandırma doğruluğunu artırmak için DVM ve Gizli Markov Modellerini (HMM) birleştiren hibrit bir yaklaşım önermektedir. Bu

birleşik yaklaşımın tek başına DVM kullanımına kıyasla tanıma doğruluğunu %12 oranında artırdığını gösteriyorlar. Özellik düzeyinde füzyon yapan bir başka çalışmada ise Ali, Yanen [23], el hareketi tanımayı iyileştirmek için EMG sensörleri ve atalet ölçüm birimleri (IMU) sensörlerinden gelen verileri birleştirmek için bir yöntem önermektedirler. Hareketleri sınıflandırmak için farklı sınıflandırma teknikleri kullanılmış ve sonuçlar doğruluk, kesinlik, duyarlılık gibi ölçütlere göre karşılaştırılmıştır. Makalede son olarak, tanınan hareketlerin sanal bir robotu kontrol etmek için kullanılmasından bahsedilmektedir. 37 kişiden 2 kanal üzerinden elde edilen verilerden 4 özellik çıkarmışlar ve DVM sınıflandırıcı ile ortalama %95 başarı elde etmişlerdir.

Tablo 1’de yapılan literatür taramasının özeti verilmiştir. Sınıflama metodu, yapılan hareketlerin sayısı, toplanan verilerden çıkarılan özelliklerin adedi, verilerin toplandığı kanal sayısı, verilerin kaç kişiden toplandığı ve sınıflandırma başarı oranı verilmiştir. Özellik sayısının otomatik (Oto.) olduğu kısımlarda özellik sayısı, kullanılan başka bir algoritma ile otomatik belirlenmiştir.

Tablo 1’de ESA evrimsel sinir ağlarını göstermektedir. [8] numaralı çalışmada veriler 6 kanal yüzey tipi elektrotlardan ve 6 kanal iğne tipi elektrotlardan toplanmıştır. [21] numaralı çalışmada veriler iğne tipi elektrotla toplanmıştır.

Daha önceki çalışmalarda veri kayıtları kol sabit pozisyonda ve belirlenmiş hareketler yapılırken kaydedilmişlerdir. Fakat günlük yaşamda kol pozisyonu ve açısı sürekli değişmektedir ve bu nedenle kolun farklı pozisyon ve açılarının EMG tabanlı el hareket sınıflamalarına etkilerinin incelenmesi önem arz etmektedir.

Bu çalışmada sağlıklı 13 bireyden 8 kanal üzerinden toplanan 4 el hareketi için kolun farklı pozisyon ve açılarından ölçülen sEMG verileri kullanılmıştır. Çalışmada ayrıca diğer çalışmalardan farklı olarak EMG sinyalleri ile kol pozisyonu ve açısının tahmin başarısı incelenmiştir. Sınıflamada EMG verisinden ve cihaz üzerinde bulunan ivme ve jiroskop verilerinden elde edilen özellik verileri kullanılmıştır. Elde edilen verilerle YSA ve DVM sınıflandırıcıları eğitilmiştir. Sınıflandırıcı performansları sonuçlar bölümünde detaylı verilmiştir.

Özetle bu çalışmada kendinden önceki çalışmalardan farklı olarak;

- Veri kayıtları kolun ve bileğin değişen açılarında yapılmıştır,

Tablo 1. Literatür taraması özeti (summary of the literature review)

Çalışma	Metot	Hareket Sayısı	Özellik Sayısı	Kanal Sayısı	Kişi Sayısı	Ortalama Başarı (%)
Başpınar, Varol [6](2012)	YSA	7	10	4	4	91,95
Alba-Flores vd. [12](2016)	YSA	9	2	8	12	83,43
Caesarendra vd. [7](2016)	YSA	8	16	10	15	81,2
Cerci, Temeltaş [13](2018)	YSA	8	9	2	4	93
sayın vd. [9](2018)	YSA	5	5	8	5	88,4
Chung E, Benalcázar M [10] (2019)	YSA	5	Oto.	8	120	85,08
Asif vd. [11] (2020)	ESA	10	Oto.	6	18	89,7
Saeed vd. [8] (2021)	YSA	11	4	6+6	16	97,69
Yoshikawa vd. [15] (2006)	DVM	7	7	4	1	92,17
Rekhi vd. [16] (2009)	DVM	6	5	2	10	96
Alkan, Günay [17] (2012)	DVM	4	1	2	1	99
Subasi [21] (2013)	DVM	2	4	1*	27	96,75
Benatti vd. [20] (2015)	DVM	7	8	8	4	92
Rossi vd. [22] (2015)	DVM	6	1	4	9	84
Tavakoli vd. [19] (2018)	DVM	5	1	2	7	90
Altan vd. [18] (2019)	DVM	7	1	8	1	94
Ali, Yanen [23] (2020)	DVM	24	4	2	37	95

- Farklı yaş gruplarından, farklı kilolardan, her iki cinsiyetten ve farklı baskın ele sahip bireylerden veri alınmıştır,
- Yalnızca EMG sinyalleri kullanılarak kol pozisyonu ve bilek açısı tahmin performansı incelenmiştir,
- İvme ve jiroskop verilerinin kolun farklı pozisyonlarında hareket sınıflandırmaya etkileri incelenmiştir,
- İki farklı yaygın sınıflandırıcı kullanılmış ve performans karşılaştırması yapılmıştır.

2. Materyal ve Metotlar (Materials and Methods)

Bu bölümde veri toplama yöntemlerinden ve veri toplama cihazından bahsedilmiştir. Ayrıca kaydedilen veriler üzerinde hareket bölgelerinin tespitinin nasıl yapıldığı ve hangi özelliklerin çıkarıldığı üzerine durulmuştur. Son olarak kullanılan sınıflandırıcılara değinilmiş ve performans ölçütlerine yer verilmiştir. İzlenen yol blok diyagramı şeklinde Şekil 1’de verilmiştir.

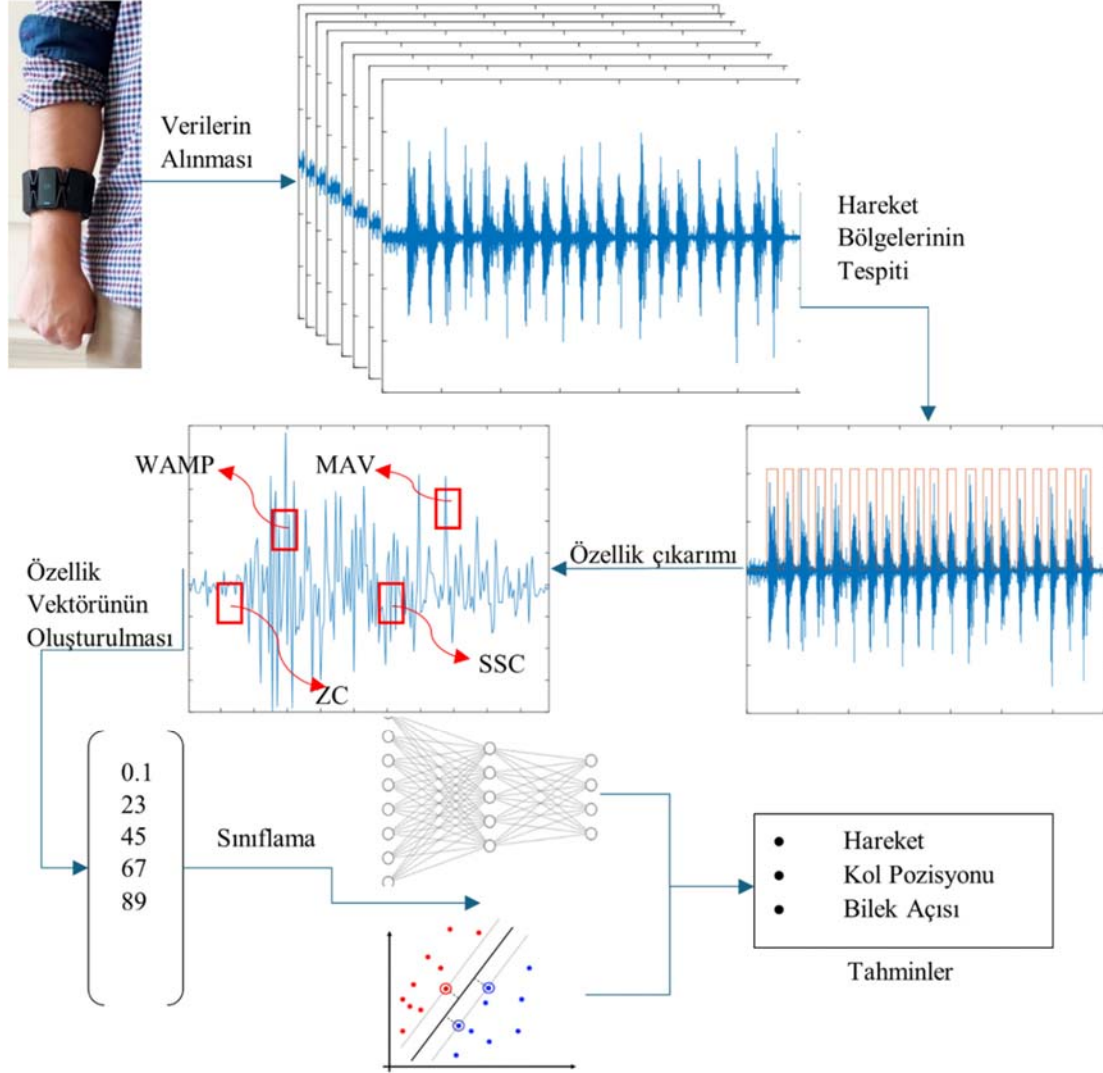
Öncelikle katılımcıların ön kollarından farklı bilek açıları ve kol pozisyonlarında yaptıkları hareketlere ait veriler kayıt edilir. Elde edilen veriler 8 kanal EMG verileri, ivme ve jiroskop verilerinden oluşmaktadır. Ardından EMG sinyalleri üzerinden hareketli sinyal

bölgesi tespiti yapılır. Hareket bölgesi tespit edildikten sonra ilgili özellikler çıkarılır ve özellik vektörleri oluşturulur. İlgili vektörler sınıflandırıcılar ile işleme tabi tutularak sınıflandırma sonucu elde edilir.

2.1. Veri Toplama (Data Collection)

Bu çalışmada kullanılan veriler yaşları 20 ile 25 arasında değişen sağlıklı 3 kadın ve 10 erkek bireyden Thalmic Labs tarafından geliştirilen MYO kol bandı ile toplanmıştır. MYO kol bandı, ön kola takılan kablosuz giyilebilir bir teknolojidir. Cihaz 8 kanal üzerinden ölçülen sEMG sinyallerini 200 Hz örnekleme frekansı ile örnekleyerek Bluetooth haberleşme teknolojisi ile PC’ye aktarır. 3 eksen ivmeölçer ve 3 eksen jiroskop verilerini de aynı yolla iletir. Ölçülen veriler bilgisayara 8 bitlik işaretli sayılar şeklinde iletir.

Veriler, kişiler 4 farklı hareketi toplamda 9 farklı pozisyonda yaparken kayıt edilmiştir. Şekil 2’de çalışmadaki bilek açıları ve kol pozisyonları görülmektedir. Şekil 2a kolun vücuda paralel ve bileğin 0 derece açı yaptığı pozisyon iken, Şekil 2b bileğin 90 derece açı yaptığı pozisyondur. Şekil 2c’de ise bilek 180 derece açı yapmıştır. Aynı şekilde d, e ve f’de kol vücuda dikken bileğin sırasıyla 0, 90 ve



Şekil 1. Önerilen yöntemin blok diyagramı (Block diagram of the proposed method)



Şekil 2. Hareketlerin yapıldığı bilek açıları ve kol pozisyonları (wrist angles and arm positions)

180 derece açı yaptığı konumlar gösterilmiştir. Son olarak g, h ve i’de kol yukarı uzanırken bileğin yine sırasıyla 0, 90 ve 180 derece açı yaptığı pozisyonlar verilmiştir.

Çalışmada bahsetme kolaylığı oluşturmak için kolun vücuda paralel olduğu pozisyona P1, dik olduğu pozisyona P2 ve kolun yukarıda olduğu pozisyona P3 kısaltmaları verilmiştir. Aynı şekilde bilek açılarının sırasıyla 0, 90 ve 180 derece olmalarına göre sırasıyla P11, P12 ve P13 şeklinde numaralandırılmıştır. Bu durumda P21 Şekil 2d’yi ifade ederken; P32 ise Şekil 2h’yi ifade etmektedir.

Eğitim verileri kendi içlerinde rastgele karıştırılmıştır. Toplam verinin %90’ı eğitim için %10’u test için kullanılmıştır. 10 katlı çapraz doğrulama kullanılmış ve tüm sonuçlar bu katların ortalaması alınarak kaydedilmiştir.

Çalışmada veri toplama sırasında 4 el hareketi yapılmıştır. Bu hareketler sırasıyla el açma hareketi, el kapama veya yumruk hareketi, bilek fleksiyon hareketi ve bilek ekstensiyon hareketidir ve sırasıyla Şekil 3’te gösterilmiştir.

2.2. Özellik Çıkarma (Feature Extraction)

Toplanan verinin uzunluğu kişinin hareketi yaparken geçirdiği zamana göre değişmektedir. Kişilerden toplanan veriler her hareket için 20 tekrar şeklindedir. Özellik çıkarma işleminde aynı şartlarda çalışabilmek için her hareket bölgesinden aynı miktarda örnek


alınmıştır. Bunun için hareket bölgesinin tespiti gerekmektedir. Hareket bölgesi tespiti tek eşik değeri metodu ile yapılmıştır[24]. Her bir hareketin ortalama 1 saniyede tamamlandığı bir seans dinlenme süreleri ile ortalama 30-35 saniye sürmekte, her hareket bölgesinde ortalama 200 örneğin olduğu veride ortalama 7000 örnek ölçülmektedir. Hareket tespitinden sonra ilk 150 örnek alınarak ilgili verinin özellikleri çıkarılmıştır. Şekil 4’te örnek EMG sinyal kaydı ve eşik değeri metodu ile belirlenmiş tekrarlı hareket bölgeleri gösterilmiştir.

Hareket bölgelerine ayrılan kayıtlar üzerinden özellikler elde edilmektedir. Bu çalışmada 5 zaman alanına ait ve 1 frekans alanına ait olmak üzere toplam 6 özellik kullanılmıştır. Bu özellikler Willison genliği, ortalama mutlak değer, eğitim işareti değişimi, dalga şeklinin uzunluğu, sıfır geçiş sayısı ve ortalama frekans şeklindedir. Bu özellikler birçok uygulamada kullanılan popüler özelliklerdir[25]. İvme ve jiroskop verileri için 3 özellik kullanılmıştır. Bunlar Willison genliği, standart sapma ve ortalama mutlak değerdir[26].

2.2.1. Willison genliği (Willison amplitude)

Wilson Genliği (Wilson Amplitude, WAMP), birbiri ardına gelen örneklerin farkının büyüklüğünün belirlenen eşik değerini geçiş sayısıdır ve denklemi Eş. 1’de verilmiştir[25].

$$WAMP = \sum_k^{N-1} f(|x_k - x_{k+1}|) \quad (1)$$



Şekil 3. Çalışmada yapılan el hareketleri (a) El açma, (b) El kapama, (c) Bilek fleksiyon, (d) Bilek ekstensiyon (hand gestures used in this study, a)hand open, b)hand closed, c)wrist flexion, d)wrist extension)

2.2.2. Ortalama mutlak değer (Mean absolute value)

Ortalama mutlak değer (\bar{X}), mutlak değerleri alınmış sinyalin değerlerinin ortalaması olarak tanımlanır. Sinyalin genliğiyle doğrudan ilişkili olduğundan EMG ile el hareketleri tanımlamada yaygın olarak kullanılan bir özelliktir. Denklemi Eş. 2'de verilmiştir[25].

$$\bar{X}_t = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (2)$$

2.2.3. Eğim işareti değişimi (Slope sign change)

Eğim işareti değişimi (δ), sinyal üzerindeki ardışık üç değer eğimlerinin işaret değiştirme sayısıdır. Sinyal üzerinde işlem yapıp gürültüyü egale etmek için bir eşik değeri belirlenir ve bu eşik değerinin aşıldığı pencerelerdeki eğim değişikliği sayılarak bir özellik elde edilir [25].

$$\delta = \sum_{k=2}^{N-1} [f[(x_k - x_{k-1})x(x_k - x_{k-1})]]$$

$$f(x) = \begin{cases} 1, & \text{if } x \geq \text{eşik} \\ 0, & \text{aksi halde} \end{cases} \quad (3)$$

2.2.4. Dalga şeklinin uzunluğu (Waveform length)

Dalga boyunun uzunluğu (ℓ), sinyalin dalga şekli üzerindeki ardışık genliklerin farklarının toplamıdır. Bu toplam sonuç olarak, dalganın iki ucundan tutup uzatıldığında vereceği toplam uzunluğa denk gelecektir. Denklemi Eş. 4 ile verilmiştir [25].


$$\ell = \sum_{k=1}^{N-1} |x_{k+1} - x_k| \quad (4)$$

2.2.5. Sıfır geçiş sayısı (Zero crossing)

Sıfır geçiş sayısı (θ), sinyalin genliğinin sıfır ekseninden kaç kez geçtiğine dair sayıdır. Gürültüyü filtrelemek için bir eşik değeri belirlenerek sıfır ekseninden değil -eşik/eşik eksenlerinden geçiş sayıları hesaplanabilir. Denklemi Eş. 5'te sunulmuştur [25].

$$\theta = \sum_{k=1}^{N-1} \text{işaret}(x_k - x_{k-1}) \cap |x_k - x_{k-1}| \geq \text{eşik}$$

$$\text{işaret} = \begin{cases} 1, & x \geq \text{eşik} \\ 0, & \text{aksi halde} \end{cases} \quad (5)$$



Şekil 4. Hareket bölgesi tespiti ve bölgeden ilk 150 örneğin gösterimi (Detected gesture section and first 150 samples)

2.2.6. Ortalama frekans (Mean frequency)

Ortalama frekans (μf), güç spektrumunun (P) frekans ile çarpılması ve bu çarpımların toplamının, toplam güç yoğunluğuna bölünmesi ile elde edilir. Eş. 6 bu ifadeyi belirtmektedir [25].

$$\mu f = \frac{\sum_{k=1}^M f_k P_k}{\sum_{k=1}^M P_k} \quad (6)$$

2.2.7. Standart sapma (Standard deviation)

Standart sapma (σ), veri setinin aritmetik ortalama etrafında hangi ölçüde değiştiğini gösteren bir ifadedir. Denklemi Eş. 7 ile ifade edilmiştir.

$$\sigma = \frac{\sum (x_i - \bar{x})^2}{N-1} \quad (7)$$

Standart sapma ivme ve jiroskop verileri için kullanılmıştır. İvme ve jiroskop verilerinde ayrıca Willison genliği ve ortalama mutlak değer özellikleri kullanılmıştır.

2.3. Yapay Sinir Ağı (Artificial Neural Network)

YSA modelleri hareket tanıma gibi uygulamalarda sıklıkla kullanılmaktadır. Bu ağlar veriler arasındaki karmaşık örüntüleri tespit ederek doğrusal veya doğrusal olmayacak şekilde sınıflandırmalar yapabilmektedir. Çalışmadaki verilerin karmaşıklığına ve veri boyutunun büyüklüğüne göre derin yapılarda olabileceği gibi [27] sığ yapılarda da olabilmektedir [28] Bu çalışmada kullanılan YSA üç katmanlıdır. Beş farklı grupta değişimle birlikte giriş katmanında 48 ile 66 arasında nöron, gizli katmanında 25 nöron ve çıkış katmanında 4 ile 10 arasında değişen nöron bulunmaktadır. Çıkış katmanındaki nöron sayısı birinci grup için 4, ikinci grup ile dördüncü grup için 7 ve üçüncü grup ile beşinci grup için 10 şeklindedir. MATLAB platformunda hazır bulunan derin öğrenme kütüphanesi kullanılmıştır. Ağ tipi ileri beslemeli hatanın geri yayılımı modelidir. İlk grup için 9; ikinci ve dördüncü gruplar için üçer tane, üçüncü ve beşinci gruplar için birer ağ eğitimi yapılmıştır.

2.4. Destek Vektör Makinesi (Support Vector Machine)

Destek Vektör Makineleri sık kullanılan bir denetimli öğrenme metodudur. İki sınıf arasında bir hiper düzlem oluşturur ve bu düzlemin sınıflara mesafesini maksimize etmeyi hedefler. Gürültülü veri setlerinde verimsiz olabilmesine karşın yüksek boyutlu verilerde verimli çalışmaktadır [29]. İki sınıflı problemlerde kullanılabileceği gibi çok sınıflı problemlerde de kullanılabilirler [30]. Çok sınıflı DVM için iki farklı metot kullanılmıştır. Bunlar bire karşı bir ve bire karşı hepsi metotlarıdır. Sınıflamalar iki metot için de tüm özellikler ve seçili özellikler kullanılarak yapılmıştır. Seçili özellik sayısına isteğe bağlı karar verilmiştir ve 4, 5, 6 ve 8 özellik üzerinden sınıflandırmalar yapılmıştır. Özellik seçimi için MATLAB platformunda bulunan sequentialfs fonksiyonu kullanılmıştır. En iyi sonuçları veren özellik grupları bu fonksiyon ile seçilip DVM eğitilmiştir.

2.5 Performans Metrikleri (Performance Metrics)

Çalışmada eğitim sonuçları konfüzyon matrisleri ile verilmiştir. Konfüzyon matrislerinden kesinlik, duyarlılık ve F1 skorları hesaplanmış ve tablolarla birlikte sunulmuştur. Doğruluk (accuracy) temel başarı ölçütü olarak alınmış ve bu değerler başarı grafikleri ile gösterilmiştir.

3. Sonuçlar (Results)

Sınıflandırma işlemleri 5 grup şeklinde yapılmıştır. Birinci grupta (G1) yalnızca aynı kol pozisyonu ve aynı bilek açısında yapılan el hareketlerinin tespiti yapılmıştır. Bu durumda P11, P12...P33 şeklinde her sınıf için ayrı modeller kurulmuştur. MYO kol bandı 8 kanal olduğundan ve her kanal verisinden 6 özellik kullanıldığından YSA girişi ve DVM özellik vektörü 48 elemandan oluşmaktadır. İkinci grupta (G2) aynı kol pozisyonunda farklı bilek açılarında yapılan el hareketleri sınıflandırılmıştır. Bu durumda P11, P12 ve P13 verileri uç uca eklenip karıştırılmış ve P1x verileri elde edilmiştir. Aynı yöntemle P2x ve P3x verileri de elde edilmiştir. Üçüncü grupta (G3) tüm kol pozisyonlarında ve tüm bilek açılarında yapılan el hareketleri sınıflandırılmak istenmiştir. Bu durumda P11'den P33'e kadar olan tüm veriler uç uca eklenmiş ve Pxx verisi elde edilmiştir. Dördüncü grupta (G4), ikinci gruptaki verilere ivme ve jiroskop verileri eklenmiştir. Yapılan çalışmada 3 eksen ivmeölçer kullanılmış ve her eksen verisinden 3 özellik çıkarılarak toplamda ivme verilerinden 9 özellik elde edilmiştir. İvme verisinin özellikleri EMG verilerinden elde edilen 48 özelliğe eklenerek 57 elemanlı YSA girişi ve DVM özellik vektörü oluşturulmuştur. Beşinci grupta (G5) üçüncü grupta yapılanlar üzerine ivme ve jiroskop verileri eklenmiştir. Jiroskop verileri 3 eksen geldiğinden ve her eksenden 3 özellik çıkarıldığından; jiroskop verilerinden gelen 9 özellik ivme ve EMG verilerinden gelen 57 özellikle birleştirildiğinden YSA girişi ve DVM özellik vektörü 66 elemanlı olmaktadır.

İkinci ve dördüncü gruplarda hareket sınıflandırmaya ek olarak bilek açısı tespiti; üçüncü ve beşinci gruplarda da el hareketi sınıflandırmaya ek olarak bilek açısı ve kol pozisyonu tespiti yapılmıştır. Tablo 2'de gruplar ve içerikleri verilmiştir. G1-G5 sırasıyla birinci ve beşinci grubu göstermektedir. Tablo 2'de P11...Pxx ifadeleri ilgili pozisyonları ifade etmektedir.


Sonuçlar konfüzyon matrisleri ve başarı yüzdeleri şeklinde sunulmuştur. Konfüzyon matrislerinde gerçek pozitif değerler işaretlenmiştir. Ek olarak kesinlik, duyarlılık ve F1 skoru hesaplanmış ve ilgili tablolarla birlikte sunulmuştur. Başarı oranlarını gösteren tablolar gerçek pozitif değerler göze alınarak doğruluk (accuracy) değerlerinin hesaplanmasıyla elde edilmiştir. YSA ve DVM sınıflandırıcıların ortalama başarı oranları karşılaştırılabilir şekilde tablolarla sunulmuştur.

Birinci grupta toplam 9 YSA eğitimi yapılmıştır. P11'den P33'e kadar yapılan hareketlere dair sınıflandırma sonuçları konfüzyon matrisi olarak Tablo 3'te sırasıyla verilmiştir. Bu grupta hareket sınıflaması aynı kol pozisyonunda ve aynı bilek açısında yapılan hareketler için

Tablo 2. Sınıflandırma gruplarının içerikleri (contents of classification groups)

		El Hareketi						Bilek Açısı			Kol Pozisyonu
G1	P11	P12	P13	P21	P22	P23	P31	P32	P33		
G2		P1x			P2x			P3x		✓	
G3					Pxx					✓	✓
G4	P1x + ivme + jiroskop			P2x + ivme + jiroskop			P3x + ivme + jiroskop			✓	
G5				Pxx + ivme + jiroskop						✓	✓

yapılmıştır. Tabloya kesinlik, duyarlılık ve F1 skoru gibi performans metrikleri de dahil edilmiştir. Birinci grupta eğitilen ağların başarı yüzdeleri Şekil 5'teki grafikte verilmiştir. Bu grupta yalnızca hareket sınıflandırma yapılmıştır. Tüm ağların başarı ortalamaları %82,92 çıkmaktadır.



Şekil 5. Birinci grupta YSA başarı sonuçları
(ANN success results for the first group)

Birinci grup(G1) için iki tür DVM eğitilmiştir. Bunlardan ilki bire karşı bir, diğeri ise bire karşı hepsi algoritmalarıdır. Bu grupta 48 özellik kullanıldığından DVM özellik vektörü 48 sütundur. İki tür DVM sınıflandırıcısında da tüm özellikler, yalnızca 4 özellik, 5 özellik, 6 ve 8 özellik kullanılarak sınıflamalar yapılmıştır. Tablo 4'te DVM başarıları ve kıyas için YSA başarıları verilmiş, her grupta en yüksek başarı veren uygulama kalın yazı karakteri ile işaretlenmiştir.

İkinci grupta P1x, P2x ve P3x için üç adet YSA eğitilmiştir. Bu grupta hareket sınıflaması aynı kol pozisyonunda ve tüm bilek açılarında yapılan hareketler için yapılmıştır. Sınıflama sonuçlarına ait konfüzyon matrisi Tablo 5'te verilmiştir.

İkinci grupta eğitilen YSA test sonuçları Şekil 6'da verilmiştir. Bu başarı yüzdeleri yalnızca el hareketleri tanımda elde edilen sonuçlar içindir. Başarı oranları ortalaması %84,31 çıkmıştır. İkinci grupta hareket tespiti için kullanılan DVM başarı oranları Tablo 6'da verilmiştir. Kıyas için YSA başarı oranları da tabloya eklenmiştir. En yüksek başarı oranını sağlayan uygulama işaretlenmiştir. İkinci grupta hareket ile birlikte bilek açısı tespiti yapılmıştır. Bu grupta yapılan sınıflamada ivme verileri kullanılmamıştır. Test sonuçlarına göre çıkan konfüzyon matrisi Tablo 7'de verilmiştir.

Tablo 3. Aynı kol pozisyonu ve bilek açısında yapılan hareketlerin sınıflandırmalarının konfüzyon matrisi sonuçları (Confusion matrix for hand gestures classification that were done in the same arm position and wrist angle)


		Tahmin				Toplam	Kesinlik	Duyarlılık	F1	
		El Açma	El Kapama	Bilek Fleksiyon	Bilek Ekstensiyon					
Gerçek	El Açma	P11	18	0	0	6	24	0,82	0,75	0,78
		P12	16	3	0	1	20	0,76	0,80	0,78
		P13	20	0	0	0	20	0,95	1,00	0,98
		P21	14	0	2	8	24	0,78	0,58	0,67
		P22	11	8	0	1	20	0,65	0,55	0,59
		P23	20	1	2	1	24	0,95	0,83	0,89
		P31	16	5	1	2	24	0,73	0,67	0,70
		P32	18	2	2	2	24	0,69	0,75	0,72
		P33	17	1	0	2	20	0,89	0,85	0,87
	El Kapama	P11	1	22	1	0	24	0,96	0,92	0,94
		P12	1	16	1	2	20	0,73	0,80	0,76
P13		0	19	1	0	20	0,95	0,95	0,95	
P21		2	22	0	0	24	1,00	0,92	0,96	
P22		2	17	1	0	20	0,68	0,85	0,76	
P23		1	22	1	0	24	0,85	0,92	0,88	
P31		3	17	1	3	24	0,77	0,71	0,74	
P32		0	24	0	0	24	0,80	1,00	0,89	
P33		0	16	3	1	20	0,84	0,80	0,82	
Bilek Fleksiyon	P11	0	1	23	0	24	0,96	0,96	0,96	
	P12	0	1	18	1	20	0,86	0,90	0,88	
	P13	0	1	19	0	20	0,95	0,95	0,95	
	P21	0	0	24	0	24	0,92	1,00	0,96	
	P22	3	0	17	0	20	0,94	0,85	0,89	
	P23	0	0	24	0	24	0,89	1,00	0,94	
	P31	2	0	19	3	24	0,83	0,79	0,81	
	P32	7	4	13	0	24	0,76	0,54	0,63	
	P33	0	1	16	3	20	0,62	0,80	0,70	
Bilek Ekstensiyon	P11	3	0	0	21	24	0,78	0,88	0,82	
	P12	4	2	2	12	20	0,75	0,60	0,67	
	P13	1	0	0	19	20	1,00	0,95	0,97	
	P21	2	0	0	22	24	0,73	0,92	0,81	
	P22	1	0	0	19	20	0,95	0,95	0,95	
	P23	0	3	0	21	24	0,95	0,88	0,91	
	P31	1	0	2	21	24	0,72	0,88	0,79	
	P32	1	0	2	21	24	0,91	0,88	0,89	
	P33	2	1	7	10	20	0,63	0,50	0,56	

Tablo 4. Birinci grupta DVM başarı sonuçları (SVM success results for the first group)

		P11(%)	P12(%)	P13(%)	P21(%)	P22(%)	P23(%)	P31(%)	P32(%)	P33(%)
YSA	25 nöron	87,50	77,50	96,25	85,42	80,00	90,63	76,04	79,17	73,75
	48 özellik	87,50	70,00	82,50	89,58	88,75	86,46	82,29	65,63	76,25
	4 özellik	68,02	63,88	52,88	68,44	74,00	61,88	75,63	65,21	59,75
Bire karşı bir DVM	5 özellik	68,13	69,63	59,88	62,50	78,00	77,19	77,40	64,38	66,63
	6 özellik	74,27	69,25	76,50	68,65	78,50	76,25	69,79	64,69	68,38
	8 özellik	81,25	62,13	73,13	67,92	76,63	75,63	69,27	66,35	65,50
Bire karşı hepsi DVM	48 özellik	89,58	66,25	85,00	79,17	93,75	86,46	75,00	72,92	72,50
	4 özellik	81,77	67,00	41,75	81,67	68,63	62,19	62,50	78,13	62,13
	5 özellik	86,25	71,75	49,13	82,08	70,00	77,40	70,21	75,94	62,50
	6 özellik	86,77	76,13	62,63	79,27	69,79	78,23	71,04	76,25	61,63
	8 özellik	86,15	75,38	77,38	81,98	76,75	77,08	76,15	77,92	61,50

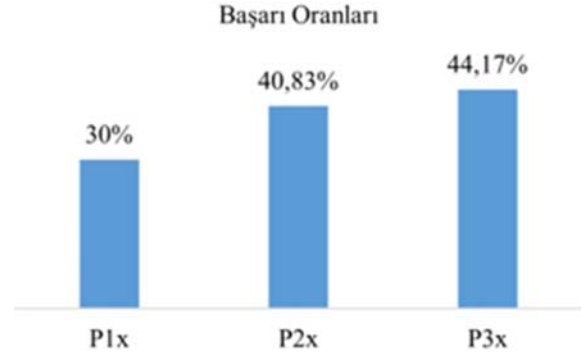
Tablo 5. Kol pozisyonlarındaki tüm bilek açılarında yapılan el hareketleri sınıflandırmasına ait konfüzyon matrisi sonuçları (Confusion matrix for hand gesture classification results in all wrist angle for each arm posture)

	Tahmin	El Açma El Kapama Bilek Fleksiyon Bilek Ekstensiyon				Toplam Kesinlik Duyarlılık F1			
		El Açma	El Kapama	Bilek Fleksiyon	Bilek Ekstensiyon				
El açma	P1x	56	0	0	4	60	0,90	0,93	0,92
	P2x	40	11	1	8	60	0,80	0,67	0,73
	P3x	50	5	2	3	60	0,86	0,83	0,85
El kapama	P1x	1	52	6	1	60	0,98	0,87	0,92
	P2x	4	55	1	0	60	0,82	0,92	0,87
	P3x	3	51	4	2	60	0,80	0,85	0,82
Bilek Fleksiyon	P1x	1	1	58	0	60	0,91	0,97	0,94
	P2x	2	1	56	1	60	0,97	0,93	0,95
	P3x	1	7	46	6	60	0,61	0,77	0,68
Bilek Ekstensiyon	P1x	4	0	0	56	60	0,92	0,93	0,93
	P2x	4	0	0	56	60	0,86	0,93	0,90
	P3x	4	1	24	31	60	0,74	0,52	0,61

**Şekil 6.** İkinci grupta eğitilen YSA başarı oranları (Success rates of ANN trained in the second group)**Tablo 6.** İkinci grup hareket tespitinde kullanılan DVM başarı oranları (SVM success rates for second group)

		P1x (%)	P2x (%)	P3x (%)
YSA	25 nöron	92,50	86,25	74,17
	48 özellik	95,42	82,92	69,17
	4 özellik	73,50	65,46	53,96
Bire karşı bir DVM	5 özellik	80,92	73,54	72,54
	6 özellik	81,38	86,50	75,88
	8 özellik	85,79	85,46	75,33
Bire karşı hepsi DVM	48 özellik	88,75	85,83	66,25
	4 özellik	63,58	68,00	70,13
	5 özellik	69,38	79,79	76,42
	6 özellik	79,17	78,50	73,96
	8 özellik	83,00	83,75	72,63

Şekil 7'de bilek açısı tespiti için eğitilen YSA sonuçlarının başarı oranları verilmiştir. Üç sınıflandırmanın ortalaması %38 çıkmaktadır.

**Şekil 7.** İkinci grupta bilek açısı tespiti için eğitilen YSA test sonuçlarının başarı oranları (Success rates of ANN test results trained for wrist angle detection in the second group)

Üçüncü grupta Pxx için yalnız bir YSA eğitilmiştir. Eğitilen ağın hareket tahmini için test sonucuna ait konfüzyon matrisi Tablo 8'de verilmiştir. Eğitim verisi 6768, test verisi 720 adettir. Başarı oranı %82,36 çıkmaktadır.

Tablo 9'da bilek açısı tahmini dağılımları verilmiştir ve başarı oranı %43,75 çıkmaktadır. 720 adet test verisi her açığa 240 örnek gelecek şekilde dengeli ve rastgele dağıtılmıştır.

Tablo 10'da ise kol pozisyonu tahmini dağılımları verilmiş ve başarı oranı %36,9 olarak hesaplanmıştır.

Üçüncü grupta yapılan hareket tespiti için DVM başarı oranları Şekil 8’de verilmiştir. Karşılaştırma amacıyla YSA sonuçları da grafiğe eklenmiştir. En yüksek başarı bire karşı bir DVM metodunda 8 özellik kullanılarak %82,81 olarak elde edilmiştir. Dördüncü grupta ikinci grupta yapılan işlemlerin aynısını yapılmış, EMG verilerine ek ivme ve jiroskop verileri eklenmiştir. Hareket sınıflandırmak için

eğitilen YSA test sonuçları sunulmuştur. Tablo 11’de P1x, P2x ve P3x için EMG ve ivme verileri, Tablo 12’de ise EMG verilerine ek ivme ve jiroskop verilerine göre sınıflama sonuç dağılımları verilmiştir.

Dördüncü grupta hareket sınıflamak için eğitilen YSA başarı oranları Şekil 9’da verilmiştir. Kıyaslamak için ikinci grupta yalnızca EMG

Tablo 7. İkinci grupta bilek açısı tespiti için eğitilen YSA’nın konfüzyon matrisi sonuçları
(Confusion matrix for the Wrist angle ANN classification results for the second group)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1	
		Px1 (0°)	Px2 (90°)	Px3 (180°)					
Gerçek	Px1(0°)	P1x	23	28	29	80	0,30	0,29	0,29
		P2x	2	43	35	80	0,55	0,54	0,54
		P3x	51	7	22	80	0,26	0,28	0,27
	Px2 (90°)	P1x	37	20	23	80	0,39	0,46	0,42
		P2x	24	35	21	80	0,50	0,44	0,47
		P3x	35	15	30	80	0,41	0,38	0,39
	Px3 (180°)	P1x	17	34	29	80	0,30	0,21	0,25
		P2x	8	11	61	80	0,17	0,14	0,15
		P3x	31	18	31	80	0,26	0,39	0,31

Tablo 8. Üçüncü grupta eğitilen YSA sonuçlarına göre EMG verileri ile hareket tahmini sonuçlarına ait konfüzyon matrisi
(Confusion matrix of gesture recognition results with EMG data according to ANN results trained in the third group)

		Tahmin				Toplam	Kesinlik	Duyarlılık	F1
		El açma	El kapama	Bilek fleksiyon	Bilek ekstensiyon				
Gerçek	El açma	144	25	6	5	180	0,78	0,80	0,79
	El kapama	11	158	11	0	180	0,86	0,88	0,87
	Bilek fleksiyon	0	1	176	3	180	0,77	0,98	0,86
	Bilek ekstensiyon	29	0	36	115	180	0,93	0,64	0,76

Tablo 9. Üçüncü grupta eğitilen YSA sonuçlarına göre EMG verileri ile bilek açısı tahmini konfüzyon matrisi
(According to the ANN results trained in the third group, the confusion matrix for wrist angle recognition with EMG data)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		Px1 (0°)	Px2 (90°)	Px3 (180°)				
Gerçek	Px1 (0°)	63	79	98	240	0,41	0,26	0,32
	Px2 (90°)	81	63	96	240	0,36	0,26	0,30
	Px3 (180°)	11	32	197	240	0,50	0,82	0,62

Tablo 10. Üçüncü grupta eğitilen YSA sonuçlarına göre EMG verileri ile kol pozisyonu tahmini konfüzyon matrisi
(arm position prediction confusion matrix with EMG data according to ANN results trained in the third group)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		P1x (kol vücuda paralel)	P2x (kol yere paralel)	P3x (kol yukarı uzanır)				
Gerçek	P1x (kol vücuda paralel)	47	92	101	240	0,28	0,20	0,23
	P2x (kol yere paralel)	76	75	89	240	0,35	0,31	0,33
	P3x (kol yukarı uzanır)	46	50	144	240	0,43	0,60	0,50



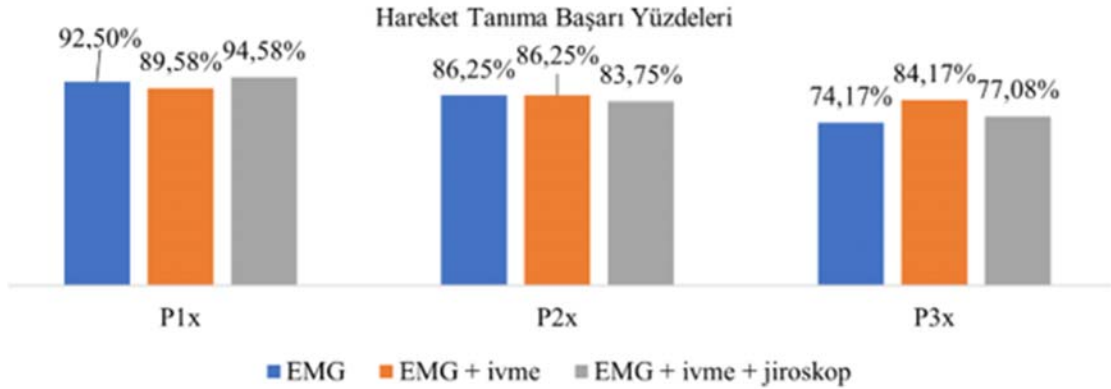
Şekil 8. Üçüncü grup DVM başarı oranları (Classification results for SVM in third group)

Tablo 11. EMG ve ivme verileriyle hareket tahmini sonuçlarına ait konfüzyon matrisi
(Confusion matrix for gesture recognition with EMG and acceleration data)

		Tahmin				Toplam	Kesinlik	Duyarlılık	F1	
		El açma	El kapama	Bilek fleksiyon	Bilek ekstensiyon					
Gerçek	El açma	P1x	59	0	0	1	60	0,75	0,98	0,85
		P2x	43	11	2	4	60	0,83	0,72	0,77
		P3x	49	5	0	6	60	0,89	0,82	0,85
	El kapama	P1x	1	56	3	0	60	0,98	0,93	0,96
		P2x	2	54	4	0	60	0,81	0,90	0,85
		P3x	1	53	6	0	60	0,87	0,88	0,88
	Bilek fleksiyon	P1x	5	1	54	0	60	0,95	0,90	0,92
		P2x	3	1	55	1	60	0,90	0,92	0,91
		P3x	5	3	50	2	60	0,76	0,83	0,79
Bilek ekstensiyon	P1x	14	0	0	46	60	0,98	0,77	0,86	
	P2x	4	1	0	55	60	0,92	0,92	0,92	
	P3x	0	0	10	50	60	0,86	0,83	0,85	

Tablo 12. EMG, ivme ve jiroskop verileri ile hareket tahmini sonuçlarına ait konfüzyon matrisi
(Confusion matrix for gesture recognition with EMG, acceleration and gyroscope data)

		Tahmin				Toplam	Kesinlik	Duyarlılık	F1	
		El açma	El kapama	Bilek fleksiyon	Bilek ekstensiyon					
Gerçek	El açma	P1x	59	0	0	1	60	0,83	0,98	0,90
		P2x	35	21	0	4	60	0,81	0,58	0,68
		P3x	32	14	7	7	60	0,67	0,53	0,59
	El kapama	P1x	1	59	0	0	60	1,00	0,98	0,99
		P2x	4	52	4	0	60	0,70	0,87	0,78
		P3x	1	58	1	0	60	0,81	0,97	0,88
	Bilek fleksiyon	P1x	0	0	60	0	60	1,00	1,00	1,00
		P2x	2	1	56	1	60	0,93	0,93	0,93
		P3x	5	0	46	9	60	0,84	0,77	0,80
Bilek ekstensiyon	P1x	11	0	0	49	60	0,98	0,82	0,89	
	P2x	2	0	0	58	60	0,92	0,97	0,94	
	P3x	10	0	1	49	60	0,75	0,82	0,78	

**Şekil 9.** Dördüncü grupta hareket sınıflama için eğitilen YSA başarı oranları (Success rates for ANN in fourth group)

sinyalleri kullanılarak eğitilen YSA başarı oranları da grafiğe eklenmiştir. Başarı oranları ortalaması EMG ve ivme verisi için %86,37; EMG, ivme ve jiroskop verileri için %85,14 çıkmıştır.

Dördüncü grupta kullanılan DVM başarı oranları YSA oranlarıyla birlikte Tablo 13'te verilmiştir. En yüksek başarılı metod tablo üzerinde işaretlenmiştir. Bu oranlar yalnızca hareket tespiti içindir. Dördüncü grupta aynı zamanda bilek açısı tespiti de yapılmıştır. Tablo 14'te sırasıyla P1x'ten P3x'e EMG verilerine ek ivme verisiyle yapılan bilek açısı tahmini, Tablo 15'te ise EMG ile ivme verilerine

ek jiroskop verilerinin eklenmesiyle eğitilen YSA'nın bilek açısı tahmini konfüzyon matrisi olarak verilmiştir.

Şekil 10'da dördüncü grupta hareket tespiti ile birlikte bilek açısı tespiti de yapmak için eğitilen YSA başarı oranları verilmiştir. Başarı oranları ortalaması EMG verilerine ivme verileri eklendiğinde %71; EMG verilerine ivme ve jiroskop verileri eklendiğinde %72 çıkmaktadır. Yalnız EMG verileri kullanılarak yapılan sınıflandırma sonuçları ile karşılaştırabilmek için ikinci grupta çıkan sonuçlar da grafiğe eklenmiştir.

Tablo 13. Dördüncü grup DVM başarı oranları (Success rates of SVM in fourth group)

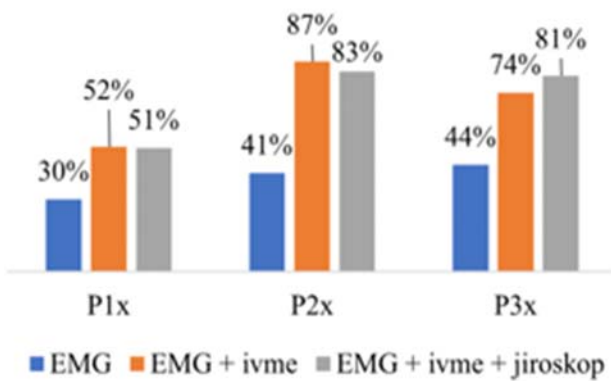
		İvme			İvme + jiroskop		
		P1x (%)	P2x (%)	P3x (%)	P1x (%)	P2x (%)	P3x (%)
YSA	25 nöron	89,58	86,25	84,17	94,58	83,75	77,08
	57 özellik	97,08	84,17	79,58	96,25	86,67	81,67
	4 özellik	79,50	76,58	56,38	72,88	73,71	54,67
Bire karşı bir DVM	5 özellik	80,79	76,71	70,33	70,21	75,29	55,50
	6 özellik	81,21	79,17	73,96	70,42	75,08	63,58
	8 özellik	89,50	90,46	73,21	84,63	87,38	59,92
Bire karşı hepsi DVM	57 özellik	94,58	88,75	75,00	94,58	88,75	73,33
	4 özellik	70,67	73,46	70,75	69,92	64,67	55,50
	5 özellik	79,04	70,17	67,46	64,96	75,50	69,54
	6 özellik	82,33	81,50	65,46	68,71	75,63	69,67
	8 özellik	88,38	79,29	67,50	76,42	80,17	67,21

Tablo 14. Dördüncü grupta EMG ve ivme verileriyle bilek açısı tahmini sonuçları (Results for wrist angle recognition with EMG and acceleration data in the fourth group)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		Px1 (0°)	Px2 (90°)	Px3 (180°)				
Gerçek Px1(0°)	P1x	48	19	13	80	0,61	0,60	0,60
	P2x	76	2	2	80	0,86	0,95	0,90
	P3x	71	7	2	80	0,88	0,89	0,88
Gerçek Px2 (90°)	P1x	15	61	4	80	0,73	0,76	0,75
	P2x	12	67	1	80	0,81	0,84	0,82
	P3x	10	61	9	80	0,60	0,76	0,67
Gerçek Px3 (180°)	P1x	16	3	61	80	0,78	0,76	0,77
	P2x	0	14	66	80	0,96	0,83	0,89
	P3x	0	34	46	80	0,81	0,58	0,67

Tablo 15. Dördüncü grupta EMG + ivme + jiroskop verileriyle bilek açısı tahmini sonuçları (Wrist angle recognition results with EMG + acceleration + gyroscope data in the fourth group)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		Px1 (0°)	Px2 (90°)	Px3 (180°)				
Gerçek Px1(0°)	P1x	52	24	4	80	0,55	0,65	0,59
	P2x	78	2	0	80	0,83	0,98	0,90
	P3x	69	9	2	80	0,97	0,86	0,91
Gerçek Px2 (90°)	P1x	20	54	6	80	0,60	0,68	0,64
	P2x	16	51	13	80	0,81	0,64	0,71
	P3x	2	76	2	80	0,66	0,95	0,78
Gerçek Px3 (180°)	P1x	23	12	45	80	0,82	0,56	0,67
	P2x	0	10	70	80	0,84	0,88	0,86
	P3x	0	30	50	80	0,93	0,63	0,75

Bilek Açısı Tanıma Başarı Oranları**Şekil 10.** Dördüncü grupta bilek açısı tespiti için eğitilen YSA başarı oranları (wrist angle classification success rates for ANN in fourth group)

Beşinci ve son grupta üçüncü grupta yapılan işlemler yapılmıştır. EMG verilerine ek ivme ve jiroskop verilerinin sınıflamaya etkileri incelenmiştir. Tablo 16'da EMG verilerine ivme verileri eklenmiştir. Başarı oranı %82,64 çıkmıştır. Tablo 17'de EMG ve ivme verilerine jiroskop verileri de eklenmiştir ve başarı oranı %82,36 çıkmıştır.

Beşinci grupta hareket tespiti için DVM başarı oranları Şekil 11'de YSA sonuçları ile birlikte verilmiştir.


Beşinci grupta bilek açısı ve kol pozisyonu tespitleri de yapılmıştır. Tablo 18'de ve Tablo 19'da EMG ve ivme verileri kullanarak bilek açısı ve kol pozisyonu tespiti yapılmış, başarı oranları sırasıyla %67,28 ve %97,78 çıkmıştır. Tablo 20 ve Tablo 21'da EMG, ivme ve jiroskop verileri kullanılarak bilek açısı ve kol pozisyonu tespiti yapılmış, başarı oranları sırasıyla %66,1 ve %96,33 çıkmaktadır. Tüm gruplar için eğitilen YSA ve DVM sınıflandırıcılarının sonuçları başarı ortalamalarıyla birlikte Tablo 22'te verilmiştir. Tablo 22'de ivme ve jiroskop verilerinin veri setine eklenmesiyle elde edilen eğitim sonuçları, yalnızca EMG verileri kullanılarak elde edilen eğitim sonuçlarıyla karşılaştırılabilir.

Tablo 16. Beşinci grupta EMG + ivme verileriyle hareket tanıma sonuçları
(Motion recognition results with EMG + acceleration data in the fifth group)

	Gerçek	Tahmin				Toplam	Kesinlik	Duyarlılık	F1
		El açma	El kapama	Bilek fleksiyon	Bilek ekstensiyon				
El açma	135	31	6	8	180	0,86	0,75	0,80	
El kapama	2	161	17	0	180	0,81	0,89	0,85	
Bilek fleksiyon	4	6	168	2	180	0,75	0,93	0,83	
Bilek ekstensiyon	16	0	33	131	180	0,93	0,73	0,82	

Tablo 17. Beşinci grupta EMG + ivme +jiroskop verileriyle hareket tanıma sonuçları
(Motion recognition results with EMG + acceleration + gyroscope data in the fifth group)

	Gerçek	Tahmin				Toplam	Kesinlik	Duyarlılık	F1
		El açma	El kapama	Bilek fleksiyon	Bilek ekstensiyon				
El açma	139	19	7	15	180	0,92	0,77	0,84	
El kapama	3	143	33	1	180	0,86	0,79	0,82	
Bilek fleksiyon	5	4	167	4	180	0,70	0,93	0,80	
Bilek ekstensiyon	4	1	31	144	180	0,88	0,80	0,84	

**Şekil 11.** Beşinci grup DVM başarı oranları (Hand gesture recognition success rates for SVM in fifth group)**Tablo 18.** Beşinci grupta EMG ve ivme verileriyle bilek açısı tahmini sonuçları
(Wrist angle estimation results with EMG and acceleration data in the fifth group)

	Gerçek	Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		Px1	Px2	Px3				
Px1 (0°)	147	63	30	240	0,68	0,61	0,65	
Px2 (90°)	47	162	31	240	0,60	0,68	0,64	
Px3 (180°)	21	44	175	240	0,74	0,73	0,74	

Tablo 19. EMG ve ivme verileriyle kol pozisyonu tahmini sonuçları
(Arm position estimation results with EMG and acceleration data)

	Gerçek	Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		P1x	P2x	P3x				
P1x (kol vücuda paralel)	228	0	12	240	0,99	0,95	0,97	
P2x (kol yere paralel)	0	240	0	240	1,00	1,00	1,00	
P3x (kol yukarı uzanır)	3	1	236	240	0,95	0,98	0,97	

Tablo 20. EMG, ivme ve jiroskop verileriyle bilek açısı tahmini sonuçları
(Wrist angle prediction results with EMG, acceleration and gyroscope data)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		Px1	Px2	Px3				
Gerçek	Px1 (0°)	99	86	55	240	0,79	0,41	0,54
	Px2 (90°)	21	213	6	240	0,58	0,89	0,70
	Px3 (180°)	5	71	164	240	0,73	0,68	0,71

Tablo 21. EMG, ivme ve jiroskop verileriyle kol pozisyonu tahmini sonuçları
(Arm position estimation results with EMG, acceleration and gyroscope data)

		Tahmin			Toplam	Kesinlik	Duyarlılık	F1
		P1x	P2x	P3x				
Gerçek	P1x (kol vücuda paralel)	227	0	13	240	0,95	0,95	0,95
	P2x (kol yere paralel)	0	240	0	240	1,00	1,00	1,00
	P3x (kol yukarı uzanır)	13	0	227	240	0,95	0,95	0,95

Tablo 22. Hareket tespiti için tüm gruplarda ortalama başarı oranları (Overall success rates in all group for gesture recognitions)

	EMG			EMG + ivme			EMG + ivme + jiroskop		
	YSA	DVM		YSA	DVM		YSA	DVM	
	25 nöron (%)	Bire karşı bir (%)	Bire karşı hepsi (%)	25 nöron (%)	Bire karşı bir (%)	Bire karşı hepsi (%)	25 nöron (%)	Bire karşı bir (%)	Bire karşı hepsi (%)
G1	80	81,00	80,07						
G2	84	82,50	80,28						
G3	82	82,22	78,47						
G4	84,31	82,50	80,28	86,67	86,67	85,14	85,14	86,11	85,55
G5	82	82,22	78,47	83	82,22	82,50	82	81,67	81,67

4. Değerlendirme (Conclusions)

Bu çalışmada EMG tabanlı el hareket tanımada bilek açısı ve kol pozisyonunun sınıflandırma performanslarına etkisi, EMG sinyalleri ile kol pozisyonu veya bilek açısının tespit edilip edilemeyeceği, farklı kol pozisyonlarında ve bilek açılarında ivme ve jiroskop verilerinin sınıflandırma performansına etkileri araştırılmıştır. Çalışmada el hareketi, bilek açısı ve kol pozisyonu tespitleri; YSA, bire karşı bir DVM ve bire karşı hepsi DVM kullanılarak yapılmıştır. DVM ile yapılan sınıflandırmalarda kullanılan farklı özellik sayılarının performansa etkileri de incelenmiştir. Farklı özellik sayıları tüm özellikler, beraber kullanıldığında en iyi sonuç veren 4, 5, 6 ve 8 özellik şeklinde kararlaştırılmıştır. Sınıflandırmalar 5 ana grup altında irdelenmiş, sonuçlar tablolar ve şekiller ile verilmiştir. Başarı oranlarının yanı sıra konfüzyon matrisleri ile F1 skorları da sağlanmıştır.

Birinci grupta(G1) sadece EMG sinyalleri kullanılarak farklı pozisyon ve bilek açıları YSA ile yapılan hareket sınıflama performanslarının %73,75 ile %92,5 aralığında değiştiği görülmüştür. İkinci grupta eğitim veri setine farklı bilek ve kol açıları eklenerek yapılan eğitimlerde ortalama el hareket tahminlerinin arttığı gözlenmiştir. Bu sonuca göre günlük yaşamda kullanılacak EMG tabanlı çalışan sistemlerin performansını arttırmak için eğitim verileri farklı pozisyonlar ve açılar göz önünde tutularak kaydedilmelidir. İvme ve jiroskop verilerinin dördüncü(G4) ve beşinci(G5) grupta hareket tespitine etkileri incelendiğinde ivme ve jiroskop verilerinin el hareket tanıma sonuçlarında az da olsa bir artış gösterdiği görülmüştür.

EMG verisi ile bilek açısı ve kol pozisyonu tahmin edilebilir mi sorusuna yanıt olarak yapılan G2, G3, G4 ve G5 etiketli gruplarda yalnız EMG verisinin kullanımının bilek açısı ve kol pozisyon tahmininde başarılı olamadığı tespit edilmiştir. Bilek açısı tanımda

EMG verilerine ivme ve jiroskop verilerinin de eklenmesiyle bilek açısı tahmin oranları P1x'te %50'ye; P2x ve P3x verilerinde %80'nin üzerine çıktığı belirlenmiştir. Kol pozisyonunun belirlenmesi amacıyla yapılan G5 etiketli grupta kol pozisyonu belirlemede EMG+ivme verisinin daha yüksek sınıflama başarısı (%97,78) gösterdiği tespit edilmiştir.

Sınıflandırıcı performansı olarak yapılan çalışmalarda Tablo 4, Tablo 6 ve Tablo 13 değerlendirildiğinde genel olarak DVM sınıflandırıcısı daha yüksek sınıflama performansı göstermekle beraber YSA'nın da iyi sonuçlar verdiği gözlenmiştir.

Sonuç olarak farklı kol pozisyonu ve bilek açıları yapılan hareketlerin, hareket tahmini başarısına etkileri incelenmiştir. Gelecek çalışmalarda katılımcı sayısı artırılarak daha büyük veri setleri elde edilebilir. Daha büyük veri setleri elde edilmesiyle derin ağ yapıları kullanılabilir. Verilerin elde edildiği kanal sayısının sınıflandırma başarısına etkileri incelenebilir. Çevrimdışı eğitimin yanı sıra çevrimiçi eğitim modelleri kullanılabilir.

Teşekkür (Acknowledgment)

Bu çalışma Marmara Üniversitesi BAPKO birimi FEN-K-090518-0244 no'lu "Bilgisayar Destekli El Rehabilitasyon Sistemi" isimli proje kapsamında desteklenmektedir.

Kaynaklar (References)

- Xu H., Xiong A., Advances and disturbances in sEMG-Based intentions and movements recognition: A review, IEEE Sensors Journal, 21 (12), 13019–13028, 2021.
- Subba T., Chingtham T. S., A Survey: EMG Signal-Based Controller for Human-Computer Interaction, Advances in Communication, Cloud, and Big Data., Singapore, 117–125, 16 Haziran 2019.

3. Cifrek M., Medved V., Tonković S., Ostojčić S., Surface EMG based muscle fatigue evaluation in biomechanics, *Clinical Biomechanics*, 24 (4) 327–340, 2009.
4. Kılıç E., Başer Ö., Kızıllan H., EMG-based stiffness estimation of ankle joint and real-time implementation on a variable stiffness ankle exoskeleton robot, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 225–240, 2020.
5. Li K., Zhang J., Wang L., Zhang M., Li J., Bao S., A review of the key technologies for sEMG-based human-robot interaction systems, *Biomedical Signal Processing and Control*, 62, 102074, 2020.
6. Başpınar U., Varol H. S., Yıldız K., Classification of hand movements by using artificial neural network, *International Symposium on Innovations in Intelligent Systems and Applications (INISTA 2012)*, Trabzon-Türkiye, 1-4, 2-4 Haziran, 2012.
7. Caesarendra W., Lekson S. U., Mustaqim K. A., Winoto A. R., Widoyatriatmo A., A classification method of hand EMG signals based on principal component analysis and artificial neural network, *International Conference on Instrumentation, Control and Automation (ICA 2016)*, Bandung-Indonesia, 22-27, 29-31 Ağustos, 2016.
8. Saeed B., Zia-ur-Rehman M., Gilani S. O., Amin F., Waris A., Jamil M., Shafique M., Leveraging ANN and LDA Classifiers for Characterizing Different Hand Movements Using EMG Signals, *Arabian Journal for Science and Engineering*, 46 (2), 1761–1769, 2021.
9. Sayin F. S., Ozen S., Başpınar U., Hand Gesture Recognition by Using sEMG Signals for Human Machine Interaction Applications, *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, Poznan- Poland, 27–30, 19-21 Eylül, 2018.
10. Chung E. A., Benalcázar M. E., Real-time hand gesture recognition model using deep learning techniques and EMG signals, *European Signal Processing Conference, A Coruna – Spain*, 1-5, 2-6 Eylül, 2019.
11. Asif A. R., Waris A., Gilani S. O., Jamil M., Ashraf H., Shafique M., Niazi I. K., Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG, *Sensors (Basel)*, 20 (6), 1642, 2020.
12. Alba-Flores R., Hickman S., Mirzakani A. S., Performance analysis of two ANN based classifiers for EMG signals to identify hand motions, *SoutheastCon 2016*, Norfolk VA-USA, 1-5, 30 Mart – 3 Nisan, 2016.
13. Cerci C., Temeltas H., Feature extraction of EMG signals, classification with ANN and kNN algorithms, *26th Signal Processing and Communications Applications Conference (SIU)*, İzmir-Türkiye, 1–4, 2-5 Mayıs, 2018.
14. Kisa D. H., Özdemir M. A., Güren O., Alaybeyoğlu A., A decision-making mechanism based on EMG signals and adaptive neural fuzzy inference system (ANFIS) for hand gesture prediction, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (3), 1417–1430, 2023.
15. Yoshikawa M., Mikawa M., Tanaka K., Real-time hand motion estimation using EMG signals with support vector machines, *2006 SICE-ICASE International Joint Conference*, Busan-Korea (South), 593–598, 18-21 Ekim, 2006.
16. Rekhi N. S., Arora A. S., Singh S., Singh D., Multi-class SVM classification of surface EMG signal for upper limb function, *3rd International Conference on Bioinformatics and Biomedical Engineering (iCBBE 2009)*, Beijing-China, 1-4, 11-13 Haziran, 2009.
17. Alkan A., Günay M., Identification of EMG signals using discriminant analysis and SVM classifier, *Expert Systems with Applications*, 39 (1), 44–47, 2012.
18. Altan E., Pehlivan K., Kaplanoglu E., Comparison of EMG based finger motion classification algorithms, *27th Signal Processing and Communications Applications Conference (SIU 2019)*, Sivas-Türkiye, 1-4, 24-26 Nisan, 2019.
19. Tavakoli M., Benussi C., Alhais Lopes P., Osorio L. B., de Almeida A. T., Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier, *Biomedical Signal Processing and Control*, 46, 121–130, 2018.
20. Benatti S., Casamassima F., Milosevic B., Farella E., Schönle P., Fateh S., Benini L., A Versatile Embedded Platform for EMG Acquisition and Gesture Recognition, *IEEE Transactions on Biomedical Circuits and Systems*, 9 (5), 620–630, 2015.
21. Subasi A., Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders, *Computers in Biology and Medicine*, 43 (5), 576–586, 2013.
22. Rossi M., Benatti S., Farella E., Benini L., Hybrid EMG classifier based on HMM and SVM for hand gesture recognition in prosthetics, *Proceedings of the IEEE International Conference on Industrial Technology*, Seville-Spain, 1700-1705, 17-19 Mart, 2015.
23. Ali H., Yanen W., SVM Classification for Novel Time Domain IMU and EMG fused features for control of 6-DOF industrial robot, *IEEE International Conference on Mechatronics and Automation (ICMA 2020)*, Beijing-China, 18-22, 13-16 Ekim, 2020.
24. Reaz M. B. I., Hussain M. S., Mohd-Yasin F., Techniques of EMG signal analysis: Detection, processing, classification and applications, *Biological Procedures Online*, 8 (1), 11–35, 2006.
25. Hudgins B., Parker P., Scott R. N., A New Strategy for Multifunction Myoelectric Control, *IEEE Transactions on Biomedical Engineering (TBME)*, 40 (1), 82–94, 1993.
26. Sarcevic P., Pletl S., Kincses Z., Comparison of time- and frequency-domain features for movement classification using data from wrist-worn sensors, *IEEE 15th International Symposium on Intelligent Systems and Informatics (SISY 2017)*, Proceedings, Subotica-Serbia, 261-266, 14-16 Eylül, 2017.
27. Bangaru S. S., Wang C., Busam S. A., Aghazadeh F., ANN-based automated scaffold builder activity recognition through wearable EMG and IMU sensors, *Automation in Construction*, 126, 103653, 2021.
28. Waris A., Zia ur Rehman M., Niazi I. K., Jochumsen M., Englehart K., Jensen W., Haavik H., Kamavuako E. N. A., A Multiday Evaluation of Real-Time Intramuscular EMG Usability with ANN, *Sensors*, 20 (12), 3385, 2020.
29. Sunnetci K. M., Alkan A., Biphasic majority voting-based comparative COVID-19 diagnosis using chest X-ray images, *Expert Systems with Applications*, 216, 119430, 2023.
30. Küçük H., Eminoğlu İ., Balcı K., Classification of neuromuscular diseases with artificial intelligence methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 1725-1741, 2019.