

## Birbirine Benzer El Hareketlerinin Sınıflandırılmasında EMG Sinyallerinin Kullanımı

\*<sup>1</sup>Ayşe Dilan Derdiyok, <sup>2</sup>Ayşe Nur Ay, <sup>3</sup>Mustafa Zahid Yıldız

\*<sup>1</sup>Biyomedikal Mühendisliği Ana bilim Dalı, Lisansüstü Eğitim Enstitüsü, Sakarya Uygulamalı Bilimler Üniversitesi Türkiye

<sup>2</sup>Mekatronik Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye

<sup>3</sup>Elektrik Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Türkiye

### Özet

Rehabilitasyon cihazlarını destekleyen robotik sistemler ve el fonksiyonlarını karşılayan robotik protezleri iyileştirme arzusu, iskelet cihazlarının geliştirilmesinde büyük rol oynamıştır. Yüze Elektromiyografi (sEMG) sinyallerinin kullanıldığı bu tür cihazlarda protez kontrolünün gerçekleştirilmesi için sinyallerin özelliklerinin bilinmesi ve bu özellikler sayesinde el hareketlerinin sınıflandırılması mümkün hale gelir. Bu çalışmada, Myo TM Armbandı (Akıllı Kol Bant) tarafından elde edilmiş olan yüze elektromiyografik sinyallerinin benzer hareketleri ayırt etmede sınıflandırılması hedeflenmiştir. Bu çalışmada kullanılan 225 katılımcıdan alınan ve benzer el hareketi yapılmış olan açık kaynak EMG veri setini, öncelikle ön işleme adımlarından geçirildikten sonra, özellik çıkarımı adımları gerçekleştirilmiştir. Çıkarılan 10 özellik sınıflandırıcıya girdi olarak verilmiştir. Sınıflandırıcı olarak sırasıyla: Karar ağaçları (Decision Trees), Destek vektör makineleri (SVM), Toplu Öğrenme (Ensemble Learning), yakın K- en komşu algoritmaları (k-NN) denenmiş olup; doğruluk başarısı, bu algoritmalar içerisinde diğer algoritmalara oranla %87,6 olarak en yüksek olan k- en yakın komşu algoritması ile elde edilmiştir.

**Anahtar kelimeler:** EMG, makine öğrenmesi, sınıflandırma, k-NN algoritması

### Abstract

Robotic systems that support rehabilitation devices and the desire to improve robotic prostheses which meet hand functions have played a major role in the development of skeletal devices. In such devices where Surface Electromyography (sEMG) signals are used, the characteristics of the signals should be known in order to control the prosthesis and to classify hand movements. In this study, it is aimed to classify the surface electromyographic signals obtained by Myo TM Armband (Smart Armband) while distinguishing the similar movements. The open source EMG dataset which have been used in this study, was taken from 225 participants who made similar hand gestures, was first ran through pre-process, and then feature extraction steps were carried out. The 10 extracted features are given as input to the classifier. Decision trees, Support vector machines (SVM), Ensemble Learning, near K-neighbor algorithms (k-NN) have been tried as classifiers, respectively. Among these algorithms, the highest accuracy rate of 87.6% was obtained with the k-nearest neighbor algorithm compared to other algorithms.

**Key words:** EMG, machine learning, classification, k-NN algorithm

### 1. Giriş

Kas işaretlerinin ölçülmesinde kullanılan medikal bir yöntem olarak bilinen Elektromiyografi (EMG) kas ve sinir rahatsızlığı tedavilerinde, fizik tedavi ve rehabilitasyonda kullanılırken, protez sistemlerin geliştirilmesinde de kaynak sinyaldir. Bu bahsedilen alanlardaki yapılan çalışmaların temeli EMG sinyallerinin doğru bir şekilde sınıflandırılmasına dayanmaktadır. Sinyallerin sınıflandırılma başarısının artırılması, klinik uygulamalarda kas hastalıklarının tespitine ve protez

\*Corresponding author: Address: Department of Biomedical Engineering Sakarya University of Applied Sciences, 54187, Sakarya TURKEY. E-mail address: derdiyokaysedilan@gmail.com

organ geliştirme başarısındaki artışa dolaylı olarak katkı sağlayacak gelişmeleri de beraberinde getirmektedir. Bunu yapmak için, ölçülen EMG sinyallerin özelliklerinin iyi bilinmesi gerekmektedir. Çeşitli amaçlarla gerçekleştirilen el hareketlerinin tanınmasında ve birbirinden ayırt edilmesinde kullanılan makine öğrenmesinin altında incelenen en bilinen sınıflayıcılar arasında K-en Yakın Komşu (k-NN), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN), Derin Evrişimli Ağlar (DNN) bulunur [1]. Literatürde bu yöntemler kullanılarak el hareketlerini sınıflandıran birçok çalışma mevcuttur.

Wannous ve diğerleri (2008) protez ellerini kontrol etmek için altı el hareketini sınıflandırmak için destek vektör makinesi (SVM) yöntemini kullanmıştır. Sınıflandırma doğruluğu yaklaşık %88 çıkmıştır [2].

Oskoei ve Hu (2008), sınıflandırma için SVM kullanılan diğer bir çalışmada, EMG sinyallerini kullanarak üst ekstremite hareketlerini birbirinden ayırt etmişlerdir [3].

Rabin ve diğerleri (2020) tarafından yapılan çalışmada 6 farklı el hareketinin EMG ile sınıflandırmasında doğrusal olmayan boyutluluk ile standart doğrusal boyutluluk yöntemi arasındaki farkın analiz edilmesi amaçlanmıştır [4].

Ahmad, S.A., Chappell 2007 tarafından yapılan bir diğer çalışmada da 20 katılımcı bilek hareketleri yaparken izometrik kasılma ve karşı kasılma EMG sinyalleri yüzey elektrotlarıyla kaydedilmiş ve bu datalar sınıflandırılmıştır [5].

Arief, Z., Sulistijono, I. A., ve Ardiansyah, 2015 yılında yaptıkları çalışmada Myo kol bandı ile zaman domenindeki özelliklerden 5 tanesi ile başarı sonuçlarını tablolarla karşılaştırmışlardır. Ve bu çalışmada EMG sinyallerinin için MAV ve WL'nin en yüksek doğruluğa sahip zaman alanı sınıflandırılması olarak önerilmiştir [6].

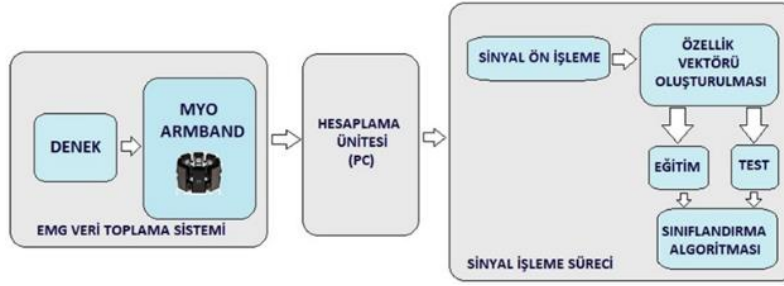
Güvenç tarafından 2014 yılında yapılan tez çalışmasında yapay uzuvların çok fonksiyonlu olabilmesi amacıyla farklı el ve kol hareketlerine ait EMG sinyalleri işlenerek bu hareketlerin sınıflandırılmasına çalışılmıştır. 8 bireyin kolundan alınan yüzey EMG sinyalleri işlenerek 7 farklı hareket sınıfının ayrıştırılması problemi YSA ile çalışılmıştır [7].

De La Cruz- S'anchez ve arkadaşlarının 225 farklı katılımcı ile gerçekleştirdikleri deneylerde 4 farklı el hareketine bağlı olarak EMG sinyallerini toplayıp; bu sinyallerden çıkardıkları 8 farklı özelliği sınıflandırıcıya girdi olarak vermişlerdir. Optimum özellik seçimi ile sınıflandırıcı performansını %82.2 olarak elde etmişlerdir [8].

Bu çalışmada, De La Cruz- S'anchez ve arkadaşlarının çalışmasından yola çıkarak onların açık erişimli EMG veri tabanından yeni özellikler çıkarılarak ve 4 farklı sınıflandırıcı algoritması denenerek en yüksek sınıflandırıcı başarısını elde etmek amaçlanmıştır. Böylece, günlük hayatta kullanılan el hareketlerinden elde edilen EMG sinyallerinin sınıflandırma başarısı artırılarak biyonik el geliştirme çalışmalarına ve rehabilitasyon ekipmanlarına katkı sağlamak hedeflenmiştir.

## 2. Materyal ve Metot

İlk olarak katılımcı verileri bilgisayar ortamına aktarılmıştır. EMG sinyalleri MATLAB üzerinden ön işleme adımlarından geçirildikten sonra, her bir hareket için özellik vektörleri oluşturularak, hareket için tanımlı sınıfa ayrılıp; makina öğrenmesi için denetimli öğrenme ağları kullanılarak eğitilmiş ve test aşamasına geçilmiştir. Bu çalışmanın blok diyagramı Şekil 1' de gösterilmiştir.




Şekil 1. Çalışmanın blok diyagramı

## 2.1 Katılımcılar ve EMG verilerinin toplanması

Bu çalışmada kullanılan EMG verilerinin kayıtları, Thalmic Labs tarafından geliştirilen Myo Armband olarak adlandırılan EMG kol bandı kullanılarak elde edilmiştir [8].

Sınıflandırılması istenen temel el hareketleri: yumruk, küre kavrama, silindirik kavrama ve kalem sıkıştırma. Bu hareketler sağlıklı 225 kişi tarafından gerçekleştirilmiş ve insanların günlük yaşamlarında farklı aktivitelerin gelişimi sırasında gerekli olan hareketlerden oluşturulmuştur.

Silindirik kavrama egzersizleri için katılımcı, 8 cm çapında ve yaklaşık 12 cm uzunluğunda plastik bir silindir ile egzersizi yapmıştır. Küresel kavrama egzersizleri için kullanıcı 9 cm çapında plastik bir küre almıştır. Hassas kavramanın geliştirilmesi için kullanıcı, başparmağı ve işaret parmağıyla ticari bir kalem tutmuştur. Yumruk hareketi için ise kullanıcı sadece yumruğunu kapatıp test bitene kadar bu pozisyonda kalmıştır. Şekil 2. de, deneylerde gerçekleştirilen dört temel el hareketi verilmiştir.



Şekil 2. Kullanıcı tarafından yapılacak el hareketleri. a) Silindirik kavrama b) Küre kavrama c) Yumruk d) Hassas kavrama

Katılımcılardan alınan bu verilerin sınıflandırma algoritmasında eğitmek için büyük bir veritabanı oluşturmak gerektiği için, yukarıda açıklanan her hareket için verilerin 5 saniye süreyle kaydedildiği belirtilmiştir. Genellikle katılımcı, hareketini 3 saniyede gerçekleştirip; kalan sürede katılımcının tepki vermesi ve hareketi gerçekleştirmesi için bir marj görevi (oluşabilecek hatalara karşı verilen zaman) görmesi sağlanmıştır. Her hareket için farklı katılımcılarla 225 test yapılmış olup dört hareket için ise toplam 675 test yapılmıştır. Tüm testler dominant olmayan ele karşılık gelen kol ile yapıлып, deneklerin yaşı, her iki cinsiyetten 20 ila 45 yaş arasında oluşturulması sağlanmıştır. Kullanılan bu veri seti Japonya Ulusal İleri Bilim Teknoloji Enstitüsü tarafından el hareketlerinin tanınması S-CRC (Spectral Collaborative Representation)'ye dayalı temsil tabanı sınıflandırmalarda kullanılmak üzere hazırlanmıştır. EMG sinyalleri gönüllülerden elde edilip, veri

tabanı açık erişimlidir [8]. Katılımcılardan alınan verilerin hareketlere göre test sayıları Tablo 1’ de gösterilmiştir.

**Tablo 1.** Cinsiyet ve el hareketine göre toplanan örnek sayısı.

Hareket	Cinsiyet	Katılımcı (Test) Sayısı
Yumruk	Erkek/Kadın	146/79
Silindir Kavrama	Erkek/Kadın	146/79
Kalem sıkıştırma	Erkek/Kadın	146/79
Küre Kavrama	Erkek/Kadın	146/79

Numunelerin her biri, Myo TM kol bandının 8 sEMG sinyalinin her biri için 1000 veri noktasına sahip ayrı bir .txt uzantı dosyasında saklanmıştır. Bu çalışmada kullanılan MyoArm Band aşağıdaki şekilde verilmiştir [9].



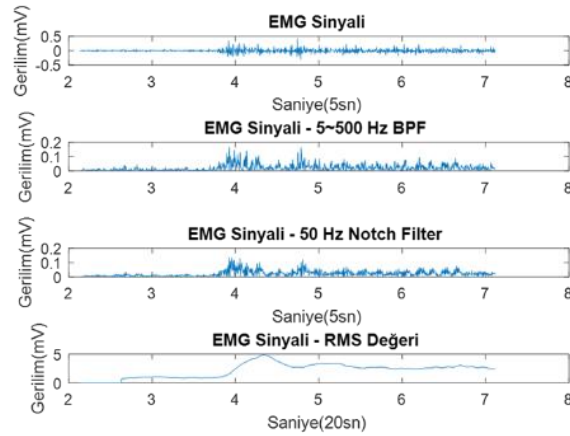
**Şekil 3.** Thalmic Myo Armband

Şekilde de görüldüğü gibi EMG kol bandında, (Myo Armband) kol kaslarından EMG verilerini alabilen dairesel şekilde yerleştirilmiş sekiz adet EMG sensörü bulunmaktadır. EMG sensörlerinin yanında kol bandının içerisinde ivmeölçer, jiroskop ve manyetometre bulunmaktadır [10, 11].

## 2.2 EMG sinyallerinin işlenmesi ve özellik çıkarımı

Kullanılan hazır veri seti MATLAB programında sinyal işleme adımlarından; ham EMG sinyalinin alınması ve sinyale tam dalga doğrultma işlemi yapılmış ve her bir hareket için sinyallere 5Hz' lik bir kesme frekansında üçüncü dereceden bir bant geçiren filtre (butterworth) ile düzeltilip filtrelenmiştir. Bu çalışmada kaydedilen EMG sinyalleri 1 kHz'lik örnekleme frekansı değeriyle örneklendirilmiştir.

EMG sinyalinin düzeltilmesi işlemi, beyaz Gauss gürültüsünü ortadan kaldırmak ve yalnızca kas aktivitesi bilgisini içeren çok düşük frekans modülasyonlu sinyallerle çalışmak için kanalların her biri için mutlak değer fonksiyonu ile gerçekleştirilmiştir. 50Hz' lik şehir şebekesi gürültüsünü yok etmek için band durdurucu (Notch) filtre kullanılmıştır. Örnek bir sinyal ön işleme çıktısı Şekil.3'te gösterilmiştir.



Şekil 3. EMG sinyalinin ön işleme adımları

Sinyal ön işleme adımlarından sonra her bir hareket için özellik vektöründen oluşan kod MATLAB'ta hazırlanmıştır.

Kullanılan özellik vektörleri aşağıdaki gibidir:

- Dalga Biçimi Uzunluğu (WL),
- Ortalama Mutlak Değer (MAV)
- Ortalama Kök Kareler (RMS)
- Basıklık (Kutozis)
- Sıfır Geçiş (ZC)
- Willison Genliği (WAMP)
- Eğim İşareti Değişiklikleri (SSC)
- Entropi (H)
- Otoregresif model (AR)
- Varyans (VAR)

Bu 10 özellik her bir hareket için ayrı ayrı normalize hale getirilip sınıflandırma algoritmasına girdi olmak için hazırlanmıştır.

### 2.3 EMG sinyallerinin sınıflandırılması

MATLAB Classification Learner uygulamasını kullanarak Makine öğrenmesi metotlarından sırasıyla; Karar ağaçları (Decision Tress), Destek vektör makineleri (SVM), Toplu Öğrenme (Ensemble Learning) ve En yakın K-komşu algoritmaları (k-NN) eğitilip, test aşamasından geçirilmiştir.

#### Adım.1 Karar ağaçları

Karar ağaçları modelinin yorumlanması kolay, tahminleri hızlı, bellek kullanımı düşüktür. Tablo 2' de karar ağaçları metotlarına ait bilgiler verilmiştir.

Tablo 2. Karar ağaçları özellikleri tablosu

Model	Maksimum Parti Bölme Sayısı	Bölme kriterleri	Vekil karar bölmesi
Fine Tree	1-100	Gini'nin çeşitlilik indeksi	Off
Medium Tree	1-100	Gini'nin çeşitlilik indeksi	-
Course Tree	1-100	Gini'nin çeşitlilik indeksi	-

Bu tabloda Bölme Sayısı, bölme ölçütü max sapma azaltmadır ve sınıflandırma ağacında yalnızca bir sınıf içeren saf düğümlere optimize etmeye çalışır.

Elde edilen sonuçlara göre Fine tree max 100 bölme sayısına medium tree max 20 bölme sayısına coarse tree max 4 bölme sayısına sahip olduğundan, karar ağacı modelinde Tablo 2’ de denenen özelliklere göre sırasıyla %77,6, %75,2, %63,4 doğruluk değerleri alınmıştır.

### Adım. 2 Destek Vektör Makineleri (SVM)

Destek vektör makineleri modeli yorumlanması Lineer SVM için kolay diğer türler için zordur, tahmin etme oranları orta hızdadır. SVM analizi tablosunda sınıflandırıcıyı hesaplamak, çarpanların izin verilen değerlerini sınırlı bir bölgede tutmak, bir sınıfı diğerlerinden ayırt etmek ve mesafe ölçümlerini ayarlamak için tablodaki değerler alınan doğruluk (accuracy) değerine göre değiştirilmiştir. Destek vektör makinelerinin özellikleri Tablo 3’te verilmiştir.

**Tablo 3.** Destek vektör makineleri özellikleri

Model	Kernel fonksiyon	Kernel oran model	Kutu kısıtlama düzeyi
Linear SVM	Gaussian	Auto	1
Quadric SVM	Gaussian	Auto	40
Cubic SVM	Cubic	Auto	1
Fine Gauss SVM	Gaussian	2.5	40
Coarse G. SVM	Gaussian	Auto	40
Medium SVM	Gaussian	10	41

Kernel function; sınıflandırıcıyı hesaplamak için çekirdek işlevini belirtir. Kernel oran model; Çekirdek ölçek modunu Auto olarak ayarladığında, yazılım ölçek değerini seçmek için buluşsal bir prosedür kullanır. Lagrange çarpanlarının izin verilen değerlerini bir kutuda, sınırlı bir bölgede tutmak için kutu kısıtlamasını belirtir. SVM modelinde Tablo 3’ te denenen özelliklere göre sırasıyla %84,9, %87,2, %84,9, %77,8, %82,2, %84,94 değerinde kendi içinde olabilecek en iyi doğruluk tahminleri alınmıştır.

### Adım. 3 Toplu öğrenme (Ensemble Learning)

Topluluk sınıflandırıcıları, birçok zayıf veriden elde edilen sonuçları tek bir yüksek kaliteli topluluk modelinde birleştirir. Nitelikler, algoritma seçimine bağlıdır. Tablo 4’ te toplu öğrenme özellikleri verilmiştir.

**Tablo 4.** Toplu öğrenme algoritmasının özellikleri

Model	Toplu öğrenme metodu	Öğrenme Tipi	Öğrenme Oranı
Boosted Tree	Ada Boost	Karar Ağacı	0.1
Bagged Trees	Bag	Karar Ağacı	30
S. Discriminant	Subspace	Discriminant	52

Toplu öğrenme algoritmasında öğrenme tiplerine göre, öğrenme oranı değerleri kıyaslanmıştır. Bu değerlere göre S. Discriminant modelinde en yüksek öğrenme oranına sahip olmasına rağmen

Bagged Tree doğruluk tahmini değeri daha yüksek çıkmıştır.

#### Adım. 4 En yakın k-komşu algoritması (k-NN)

K-NN modelinde tahmin yaparken her noktayı sınıflandırmak için bulunacak en yakın komşu sayısı değeri, noktalara olan mesafeyi belirlemek için mesafe metriği, mesafe fonksiyonu ve doğrulama (Cros Validation) seçerek modelin görmediği veriler üzerindeki performansını mümkün olduğunca doğru şekilde değerlendirmek için kullanılan örnekleme yöntemleri özellikleridir. K en yakın komşu sınıflandırıcısı (k-NN), denetlenmeyen bilgisayar öğreniminin parametrik olmayan bir yöntemidir, bu sınıflandırıcıda, öğrenilen kavramla ilişkili bir model olmadığı için tüm olası eğitim durumları ezberlenir [12]. Tablo 5’ te k-NN’e ait özellikler verilmiştir.

**Tablo 5.** k-NN sınıflandırma parametreleri

Parametreler	Değer
Komşu sayısı	1
Mesafe fonksiyonu	Spearman
Mesafe	Eşit
Doğrulama	50

Tablo 5’te k-NN modelinde tahmin yaparken her noktayı sınıflandırmak için bulunacak en yakın komşu sayısı değeri 1, 10 ve 100 olan farklı modeller eğitilip alınan değerler sırasıyla olarak değiştirilip %87,6, %80,4, %79,7, %78,4, %73,0, %81,2 değerinde kendi içinde olabilecek en iyi doğruluk tahmini alınmıştır.

### 3. Sonuçlar

Yapılan çalışmalar sonucunda Makine öğrenmesi uygulamalarından alınan en yüksek performans sınıflandırma algoritması ortalama olarak %87,6 değerinde k-NN Yakın Komşuları ve %87,2 değerinde Destek Vektör makineleri algoritmalarıdır. Bu çalışmadaki tüm sınıflandırıcı algoritmalarının performans kıyaslamaları Tablo 6’ da verilmiştir.

**Tablo 6.** Kullanılan sınıflandırıcıların performansları

Model	Doğrululuk	Tahmin hızı	Eğitim zamanı	AUC
Fine Tree	%77,6	1800 obs/sec	5.058 sec	0.80
Medium Tree	%75,2	2200 obs/sec	6.355 sec	0.84
Course Tree	%63,4	2100 obs/sec	12.901 sec	0.72
Linear SVM	%84,9	970 obs/sec	15.695 sec	0.96
Quadric SVM	%87,2	1100 obs/sec	16.212 sec	0.95
Cubic SVM	%84,9	1000 obs/sec	25.267 sec	0.95
Fine Gauss SVM	%77,8	720 obs/sec	28.118 sec	0.91
Coarse G. SVM	%82,2	990 obs/sec	17.341 sec	0.95
Medium G. SVM	%84,9	920 obs/sec	23.889 sec	0.94
Boosted Tree	%83,7	550 obs/sec	128.25sec	0.96
Bagged Trees	%86,9	530 obs/sec	32.147 sec	0.96
S. Discriminant	%81,2	320 obs/sec	26,834 sec	0.93
Fine k-NN	%87,6	390 obs/sec	6.899 sec	0.92
Medium k-NN	%80,4	1500 obs/sec	4.0389 sec	0.93

Cubic k-NN	%79,7	270 obs/sec	11.436 sec	0.91
Cosine k-NN	%78,4	900 obs/sec	4.034 sec	0.91
Coarse k-NN	%73,0	1300 obs/sec	3.374 sec	0.88
Weight k-NN	%81,2	1100 obs/sec	3.333 sec	0.94

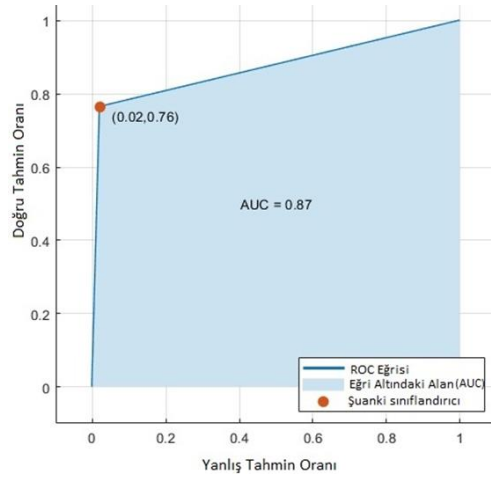
Tablo 6’ da denetimli öğrenme modellerinin tahmin hızları, eğitim zamanı ve modelin eğitimdeki başarı değerleri gösterilmektedir. Tablodanda görüldüğü üzere en iyi tahmin değerleri Fine k-NN ve Quadric SVM algoritmalarından elde edilmiştir. Alınan bu değerler elde edilen veriler sonucunda performans değerlendirme metriklerini görmek için Karışıklık Matrisi (Confusion Matrix)’nden veri setinde var olan k-NN modelimizin doğru ve yanlış tahminlerinin sayısal verileri Şekil 4’ te ifade edilmiştir.

	0	1	2	3
Doğru Sınıf	92%	2%	10%	10%
1	2%	91%	3%	5%
2	6%	3%	87%	4%
3		4%	<1%	81%
Doğru Tahmin Değeri	92%	91%	87%	81%
Yanlış Bulgu Oranı	8%	9%	13%	19%
	0	1	2	3
	Tahmin Sınıfı			

Şekil 4. k-NN algoritması Karışıklık Matrisi (Confusion Matrix) tablosu

Karışıklık matrisi tablosundaki 0, 1, 2, 3 hareket sınıflarımızı nitelendirmekte olup, gerçek pozitif (true positive) tahmin değerleri modelin doğru tahmin ettiği yüzdelik dilimi ifade etmektedir. Yanlış pozitif değerleri (false positive) ise modelin her hareketten ne derece yanlış tahminde bulunduğu göstermektedir. Şekil 4’de 0. hareket (yumruk hareketi) için %92 doğru tahminde bulunmakta iken %2’sini 1. hareket olarak %10’unu 2. hareket ve diğer %10’unu ise 3. hareket olarak yanlış tahminde bulunmaktadır. Makine öğrenmesinde performans ölçüm grafiklerinden ROC eğrisi sınıflandırma performans eğrilerinden biridir. Buradada sınıflandırmanın ne kadar iyi düzeyde yapıldığını görmek adına ROC eğrisi değerlendirme olarak kullanılmıştır k-NN algoritması ROC curve eğrisi verilmiştir şekil 5’ te verilmiştir.





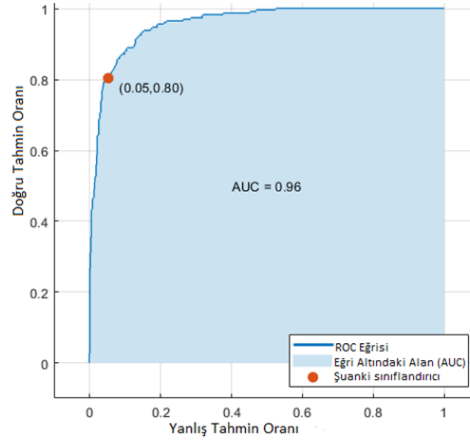
Şekil 5. k-NN algoritması ROC curve eğrisi

AUC eğrinin altında kalan alanı 0,87 oranında olup, bu sonuç k-NN modelinin sınıfları ayırt etmedeki başarısının değerini göstermektedir. Şekil 6' da SVM modelin Confusion Matris tablosu verilmiştir.

0	84%	5%	7%	7%
1	5%	87%	1%	3%
2	8%	2%	91%	3%
3	4%	6%	<1%	87%
Pozitif Tahmin Değeri	84%	87%	91%	87%
Yanlış Bulgu Oranı	16%	13%	9%	13%
	0	1	2	3
	Tahmin Sınıfı			

Şekil 6. SVM algoritması Karışıklık Matrisi (Confusion Matrix) tablosu

SVM modelinin ROC curve değeri 0.96 bulunmuştur. Şekil 7'de SVM algoritması ROC curve eğrisi verilmiştir.



Şekil 7. SVM algoritması ROC curve eğrisi algoritması

Veri setinin alındığı grubun yayınladığı makaleye göre, EMG sinyalinden 8 özellik çıkarılmış ve yapılan 4 hareket içerisinde hassas tutuş hareketi değerlendirmede yeterli verim alınmadığı için sonuçlara dahil edilmemiş olup; çalışma 3 el hareketi ile tamamlanmıştır [8]. Öncelikle bu çalışmada aynı 8 özellik kullanıldığında çok yakın doğruluk değerleri alındığı görülmüştür. Bunun üzerine benzer hareketlerde daha yüksek verimlilikte doğruluk değeri alınabilmesi amacıyla özellik sayısını 10'a çıkararak hareket sayısına da hassas tutuş hareketini ekleyip hareketi 4'e çıkararak, çalışma daha kapsamlı hale getirilmiştir. Yapılan çalışma 8 özellik ve 3 hareket ile %81,2 doğruluk değerini bulurken bu çalışmada %87,6 doğruluk değerine ulaşılabilmiştir. Literatürde yapılan çalışmalarda daha farklı hareket çeşitleri kullanılmasına rağmen benzer veya daha düşük düzeylerde sonuçlar elde edildiği görülmüştür. Bu çalışmalardan bazıları: Bağcı ve Koçal'ın yaptığı Biyonik el kontrolü için EMG işaretlerinin makine öğrenmesi yöntemiyle sınıflandırılması çalışmasında 6 kadın ve erkek sağlıklı bireyden alınan, 6 farklı hareket ile yapılmış bu çalışmada k-NN modeli kullanılarak alınan değer %84,2 olduğu görülmüştür [13]. Çerçi ve Temeltaş'ın yaptığı EMG işaretlerinin özneliklerinin çıkarılması çalışmasında 8 kişiden alınmış 8 hareket sınıfı ile k-NN modeli kullanılarak %62 değerinde doğruluk tahmini alınmıştır [14]. Literatürde %90'ların üstünde doğruluk tahmini alınan çalışmalar bulunmaktadır ancak; bunlar kısıtlı katılımcı sayısı, el hareketleri veya belli sayıda öznelikten oluşmaktadır. Bu çalışmada, yumruk (Fist) ve silindir kavrama (Cylindrical grasp) birbirine benzer hareketler olduğu için sınıflandırması zor hareketlerdir ancak; buna rağmen çıkarılan fazla sayıda öznelikler ile sınıflandırma değeri performansının yüksek olmasına katkı sağlanmıştır.

#### 4. Tartışma

Tablo 6'da görüldüğü üzere en iyi tahmin değerinin Fine k-NN ve Quadric SVM algoritmalarında çıktığı görülmektedir. Alınan bu değerlerle elde edilen veriler sonucunda performans değerlendirme metriklerini görmek için Karışıklık Matrisi (Confusion Matrix)'nden veri setinde var olan k-NN modelimizin doğru ve yanlış tahminlerinin sayısal verileri incelenmiştir. K-NN algoritmasında değerlendirme yaparken, özelliklerin sayısının artırılmasına gidilse de doğruluk performansının belli düzeyde değiştiğini, çok sayıda özelliğin daha yüksek bir performansı garanti etmediği görülmüştür. Özellik sayısı olarak 10 farklı özelliğin benzer hareketlerin sınıflandırılmasında ideal olabileceği veri sonuçlarından öngörülmüştür.

## 5. Değerlendirme

Bu çalışmada, EMG sinyallerinin benzer el hareketlerine göre sınıflandırılması hedeflenmiştir. Bu doğrultuda denenen birçok makine öğrenmesi algoritmasının içerisinde Fine k-NN algoritmasında sınıflandırıcı performansının %87,6 ile diğerlerine göre daha yüksek değere ulaştığı tespit edilmiştir. Deneylerde gerçekleştirilen el hareketleri birbirine benzer olmasına rağmen elde edilen doğruluk değerinin yüksek olduğu görülmüştür. Literatürde benzer çalışmalar bulmak mümkün olsa da bu çalışmaların çoğunda veri tabanı özellikleri detaylandırılmamış olup; kısıtlı sayıda katılımcı ile tek bir algoritma üzerinden değerlendirme yapılmıştır. Referans alınan makalede 225 katılımcıdan elde edilen verilerle yapılan bu çalışmada öz nitelikler artırılmış ve Makine öğreniminde algoritmaların veri seti üzerinde kıyaslamaları yapılmıştır. Kullanılan katılımcıların verilerine, cinsiyetlerine, özelliklerin seçilmesine ve çıkarılmasına bağlı olarak hesaplama sürelerinden tasarruf edilmesinin yanı sıra algoritma performanslarındaki iyileşmeler de gelecek çalışmalar için belirleyici bir etken olmuştur. Aynı veri seti ile yapılan çalışmadan elde edilen %81,2'lik doğruluk değeriyle bile robotik bir el kontrolünün sağlanabileceği gösterildiği için, bu çalışmada kullanılan yöntemle bulunan %87,6 daha iyi doğruluk performans değeri ile kontrol çalışmalarında daha başarılı sonuçlar elde edilebileceği öngörülmüştür.

