



## A decision-making mechanism based on EMG signals and adaptive neural fuzzy inference system (ANFIS) for hand gesture prediction

Deniz Hande Kısa<sup>1</sup>, Mehmet Akif Özdemir<sup>1\*</sup>, Onan Güren<sup>1</sup>, Ayşegül Alaybeyoğlu<sup>2</sup>

<sup>1</sup>Department of Biomedical Engineering, Faculty of Engineering and Architecture, İzmir Katip Çelebi University, 35620, İzmir, Türkiye

<sup>2</sup>Department of Computer Engineering, Faculty of Engineering and Architecture, İzmir Katip Çelebi University, 35620, İzmir, Türkiye

### Highlights:

- A novel hand gesture prediction approach based on EMG and ANFIS
- A new data representation based on feature extraction from Hilbert Spectrum images
- Comparison of gesture prediction performance with various data clustering and machine learning methods

### Keywords:

- Fuzzy Logic
- EMD
- EMG
- Hilbert-Huang Transform
- Time-Frequency Analysis

### Article Info:

Research Article  
Received: 18.11.2021  
Accepted: 16.06.2022

### DOI:

10.17341/gazimmfd.1025221

### Acknowledgement:

The authors thank the Scientific and Technological Research Council of Turkey (120E512) and İzmir Katip Çelebi University Scientific Research Projects Coordinator (2021-ÖDL-MUMF-0004 and 2022-GAP-MUMF-0001).

### Correspondence:

Author: Mehmet Akif Özdemir  
e-mail: makif.ozdemir@ikcu.edu.tr  
phone: +90 232 270 5557

### Graphical/Tabular Abstract

This work presents a novel classification method for electromyography (EMG) signals of hand gestures. The combination of a distinctive feature set from time-frequency (TF) representations of EMG data and an Adaptive Neuro-Fuzzy Inference System (ANFIS)-based decision-making mechanism was utilized to classify hand gestures. A detailed illustration of the steps followed in the proposed approach is presented in Figure A. Comparative experiments revealed that the ANFIS-based method has encouraging results.

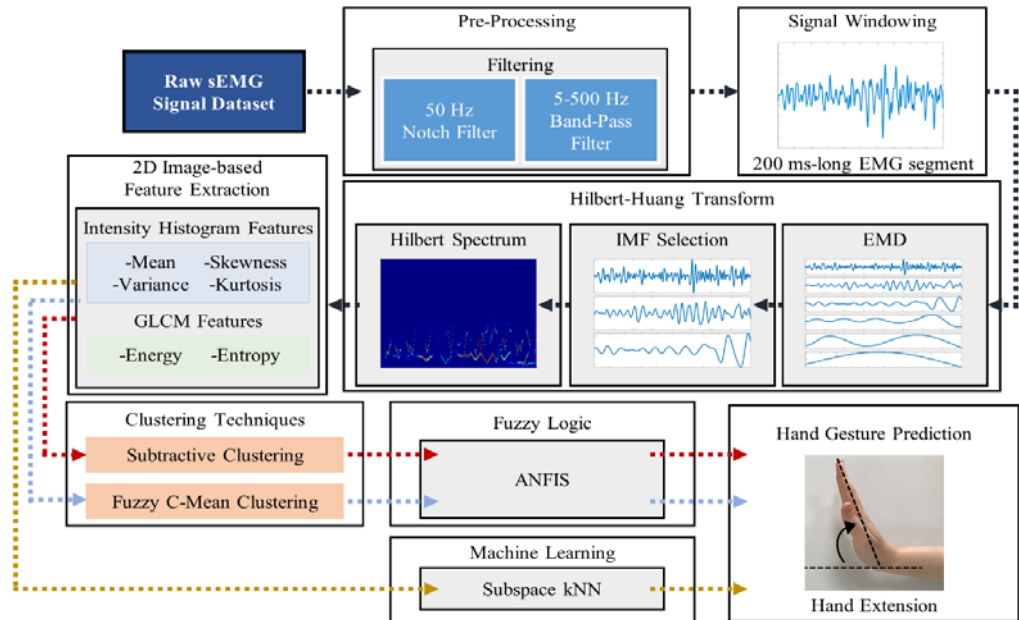


Figure A. The framework of this study

**Purpose:** The aim is to automatically predict 7 hand gestures using fuzzy logic (FL) and EMG signals.

**Theory and Methods:** EMG data were collected from 30 participants while they imitated seven different hand gestures. Filtered EMG data were segmented using a 200 ms window. High-resolution TF images were obtained by applying Hilbert-Huang Transform (HHT) to the Intrinsic Mode Functions (IMF) determined by a statistical selection method. Subtractive clustering (SC) and Fuzzy C-Means clustering (FCM) were applied to the TF image-based extracted feature set. Finally, the ANFIS was adopted for classification.

**Results:** In the ANFIS-based approach, the accuracies of SC and FCM models were obtained as 93.88% and 92.10%, respectively, using TF-based features. The machine learning (ML)-based approach has yielded an accuracy of 81.45% by using subspace k-NN. Also, subspace k-NN achieved 72.17% accuracy by utilizing the features extracted directly from the EMG signals.

**Conclusion:** Neuro-fuzzy-based ANFIS are provided well prediction capability for EMG-based biomedical data classification compared to conventional ML algorithms. The proposed approach based on joint TF features combined with FL techniques revealed promising results for the classification of nonstationary and nonlinear biological signals like EMG.



## El hareketi tahmini için EMG sinyalleri ve uyarlamalı sinirsel bulanık çıkarım sistemine (ANFIS) dayalı bir karar verme mekanizması

Deniz Hande Kısa<sup>1</sup>, Mehmet Akif Özdemir<sup>1\*</sup>, Onan Güren<sup>1</sup>, Ayşegül Alaybeyoğlu<sup>2</sup>

<sup>1</sup>İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, 35620, İzmir, Türkiye

<sup>2</sup>İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 35620, İzmir, Türkiye

### Ö N E Ç İ K A N L A R

- EMG ve ANFIS tabanlı yeni bir el hareketi tahmin yaklaşımı
- Hilbert Spektrum imgelerinden öznitelik edinimine dayalı yeni bir veri temsili
- Hareket tahminini performansının çeşitli veri kümeleme ve makine öğrenimi yöntemleri ile karşılaştırılması

### Makale Bilgileri

Araştırma Makalesi

Geliş: 18.11.2021

Kabul: 16.06.2022

### DOI:

10.17341/gazimmfd.1025221

### Anahtar Kelimeler:

Bulanık mantık,  
görgül kip ayrışımı,  
EMG,  
Hilbert-Huang dönüşümü,  
zaman-frekans analizi

### ÖZ

Üst ekstremitte hareketi tam olarak sağlanamadığında, yapay zeka (artificial intelligence/AI) sistemleri kullanıcılara amaçlanan hareketin uygulanması konusunda yardımcı olurlar. Kas aktivitesinin temsili olan elektromiyografi (EMG), sanal gerçeklik uygulamaları ve protez kontrolleri gibi AI-tabanlı sistemlerde kullanıldığında çeşitli faydalar sağlar. Bu çalışmada, bahsedilen sistemlere etkin kontrol sunmak ve tahmin performanslarını iyileştirmek amacıyla bulanık mantık (Fuzzy Logic/FL)-tabanlı bir karar verme mekanizması sunulmuştur. Bu bağlamda, 30 katılımcıdan yedi farklı el hareketini taklit etmesi sonucunda oluşan EMG sinyalleri toplandı. Gerekli ön işleme ve bölütleme işlemlerinin ardından elde edilen sinyallere Hilbert-Huang Dönüşümü'nün (HHD) ilk aşaması Görgül Kip Ayrışımı (GKA) metodu uygulandı ve İçsel Mod Fonksiyonları (İMF) elde edildi. İstatistiksel İMF seçim yöntemi ile belirlenen İMF'lere HHD uygulanmasıyla iyi çözünürlüklü zaman-frekans (time-frequency/TF) imgeleri elde edildi. Zaman ve frekans uzayının ortak temsiline dayalı görselleştirilmiş TF imgelerinden çeşitli ayırt edici öznitelikler çıkartıldı. İki farklı kümeleme tekniği uygulanan öznitelik veri seti, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi'ne (ANFIS) girdi olarak verildi. Yedi el hareketi sınıflandırması için Azaltımlı (Subtractive Clustering/SC) ve Bulanık C-ortalama (Fuzzy C-mean/FCM) kümeleme yöntemleri için ortalama doğruluk değerleri sırasıyla %93,88 ve %92,10 olarak elde edilmiştir. TF temsiline dayalı özniteliklerin FL yaklaşımlarıyla sınıflandırılması sonucu elde edilen bulgular, EMG gibi durağan ve doğrusal olmayan biyolojik sinyallerin sınıflandırılması için umut verici olduğunu göstermiştir.

## A decision-making mechanism based on EMG signals and adaptive neural fuzzy inference system (ANFIS) for hand gesture prediction

### H I G H L I G H T S

- A novel hand gesture prediction approach based on EMG and ANFIS
- A new data representation based on feature extraction from Hilbert Spectrum images
- Comparison of gesture prediction performance with various data clustering and machine learning methods

### Article Info

Research Article

Received: 18.11.2021

Accepted: 16.06.2022

### DOI:

10.17341/gazimmfd.1025221

### Keywords:

Fuzzy logic, empirical mode decomposition, EMG, Hilbert-Huang transform, time-frequency analysis

### ABSTRACT

Artificial intelligence (AI)-based technologies assist users in applying the intended action when upper extremity movement cannot be fully provided. Electromyography (EMG), a depiction of muscle activity, offers various advantages when employed with AI-based systems like virtual reality applications and prosthetics controls. In this paper, a fuzzy logic (FL)-based decision-making mechanism is presented in order to provide effective control and improve the prediction performance of the stated systems. In this regard, EMG signals were collected from 30 participants when imitating different seven hand gestures. After the necessary preprocessing and segmentation processes, the Empirical Mode Decomposition (EMD) method which is the first stage of the Hilbert-Huang Transform (HHT) was applied and Intrinsic Mode Functions (IMF) were obtained. High-resolution time-frequency (TF) images were obtained by applying HHT to the IMFs determined by a statistical selection method. Various distinctive features were extracted from the visualized TF images based on the joint representation of the time and frequency domain. The Adaptive Neuro-Fuzzy Inference System (ANFIS) was then fed these features, which used two alternative clustering approaches. For seven hand gesture classifications, the average accuracy scores for the Subtractive Clustering (SC) and Fuzzy C-mean (FCM) clustering methods were obtained as 93.88% and 92.10%, respectively. The proposed feature extraction method based on TF representation combined with FL techniques yielded encouraging results for the classification of nonstationary and nonlinear biological signals such as EMG.

\*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : denizhandekisa@hotmail.com, \*makif.ozdemir@ikcu.edu.tr, onan.guren@ikcu.edu.tr, aysegul.alaybeyoglu@ikcu.edu.tr / Tel: +90 232 270 5557

## 1. Giriş (Introduction)

İnsan hareketinin kısıtlandığı veya tam olarak gerçekleştirilemediği durumlarda, yardımcı cihazlar ve iyileştirici uygulamalar sayesinde hareket sistemindeki organlar desteklenerek vücudun hareket kabiliyeti artırılabilir [1]. Kaslar, hareket mekanizmasının en etkili üyesidir ve hareket hakkında en ilgili bilgiyi içlerinde barındırırlar [2]. Elektromiyografi (EMG), hareket esnasında kasların kasılması ya da gevşemesi sonucu oluşan ve kasların elektriksel aktivitesini gösteren, durağan olmayan biyolojik bir sinyaldir. Bir başka ifade ile motor ünite aksiyon potansiyellerinin (motor unit action potentials/MUAP) toplamı olarak da tanımlanabilir. Kasların davranışını ve durumunu incelemek için bu sinyaller kullanılmaktadır [3]. Tıpta EMG, kas ve sinir hastalıklarının teşhisi için kullanılmakla beraber mühendislik uygulamalarında protez gibi mekanik bir sistemin kontrolü veya modellenmesi için girdi olarak kullanılabilir [4]. Bu doğrultuda EMG, hareket hakkında kaslardan bilgi toplamak için avantajlı bir yaklaşımdır. Özellikle el hareketleri ve jestler insanın günlük yaşamında çok önemlidir ve bu hareketleri esas alan sistemlerde kullanılmak üzere el hareketlerinin analiz edilmesine ve sınıflandırılmasına ihtiyaç duyulmaktadır [5].

Hareketi destekleme konusunda insan hayatını kolaylaştırmak için birçok sistem geliştirilmiştir ve bu alanda çoğunlukla EMG tabanlı miyoelektrik cihazlar kullanılmaktadır. Örneğin, sanal gerçeklik sistemleri, el protezleri ve dış iskeletler EMG kontrollü sistemlere birer örnektir [6-8]. Bahsedilen bu ve benzeri sistemlerde kontrol yaklaşımlarında kullanılan EMG sinyalleri, hareketin belirlenmesinde büyük fayda sağlasa da doğrusal ve durağan olmayan yapıları nedeniyle sinyallerin analizi çeşitli zorlukları beraberinde getirir [8, 9]. Bu nedenle, EMG'nin örüntüsünü ortaya çıkarmaya yönelik çeşitli sinyal analiz yaklaşımları uygulanmaktadır. Hareket esnasında EMG sinyallerinin örüntüsünü iyi şekilde temsil etmek için zaman uzayından (time domain/TD) [10], frekans uzayından (frequency domain/FD) [11] veya ortak zaman-frekans (time-frequency/TF) uzaylarında [9] çeşitli öznelik edinimine dayalı yöntemler önerilmiştir. Ancak, zaman ve frekans uzaylarında ayrı ayrı elde edilen öznelikler hareketleri temsil etmede yetersiz kalabilmektedir [12]. Zaman uzayı öznelikleri frekans uzayına göre nispeten daha işlevsel sonuçlar sunsa da hem zaman hem de frekans bilgisi içeren ortak TF uzayı öznelikleri kadar kullanışlı olmayabilir [9, 13].

TF uzayına geçmek için sinyallere uygulanan yöntemler zaman-frekans analizi (time-frequency analysis/TFA) olarak adlandırılmaktadır. Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform/STFT) ve Dalgacık Dönüşümü (Wavelet Transform/WT) en bilinen geleneksel TFA yaklaşımlarıdır [14]. Bu dönüşümler sonucunda elde edilen imgeler zaman-frekans gösterimleri (time-frequency representations/TFR) olarak nitelendirilmekte ve TF katsayılarından çıkarılan öznelikler sinyal ve hareket hakkında ayırt edici bilgiler sunmaktadır [15]. Bahsedilen TFA yöntemlerine ek olarak uyarlanabilir bir yaklaşım olan Hilbert-Huang Dönüşümü (HHD), EMG gibi birçok biyolojik sinyalin analizinde kullanılan diğer bir dönüşüm tekniğidir ve geleneksel spektral analiz yöntemlerinin eksikliklerini iyileştirmedeki başarısı sayesinde sinyal analizindeki kullanılabilirlik potansiyeli oldukça fazladır [16]. HHD'nin EMG sinyallerinin analizinde, uygun EMG özneliklerini çıkarmak için motor birimlerinin belirlenmesi ve kaslar dışındaki ortamdaki (örneğin iç organlar, cihazlar) gelen gürültülerin ortadan kaldırılması konusunda sunduğu faydalar ile etkisi kanıtlanmıştır [15]. Geleneksel dönüşüm yöntemlerinde durağan olmayan sinyallerin frekans çözünürlüğü yorumlanabilirlik bakımından yetersiz kalabilir [9]. HHD ise EMG sinyalinin işsel özelliklerini belirlemeye yardımcı olurken aynı zamanda zamanın bir fonksiyonu olarak hem frekans hem de genlik bilgisini oluşturur ve

anlık frekans (instantaneous frequency/IF) ile anlık genlik (instantaneous amplitude/IA) özelliklerini elde etmeyi sağlar. HHD'nin durağan olmayan sinyallerin analizindeki faydaları ve geleneksel yöntemlerin eksikliklerini gidermesi nedeniyle son zamanlarda yaygın olarak kullanılmaktadır [17].

EMG sinyalinden elde edilen öznelikler veya TFA sonucu elde edilen imgelerin doğru sınıflandırılması sinyalin uygun hareketle eşleştirilmesini gerektirir. Sınıflandırma amacıyla makine öğrenmesi (machine learning/ML) [18], derin öğrenme (deep learning/DL) [19] ve bulanık mantık (fuzzy logic/FL) [20] olmak üzere birçok sınıflandırma yaklaşımı bulunmaktadır. EMG sinyali gibi biyolojik işaretler tekrar etmezler ve bazen beklenilenden farklı davranışlar gösterebilmektedir. Bu gibi durumlardan dolayı bulanık mantık, diğer yaklaşımların aksine insan düşünce sistemine en çok benzeyen işleyişiyle EMG tabanlı hareket sınıflandırma ve tahmin işlemi için tercih edilen bir yaklaşım olabilir. Özellikle literatürdeki protez el çalışmalarında, hareket sınıflandırma ve tahmin süreçlerindeki etkisi nedeniyle FL tabanlı sınıflandırıcılara yer verildiği görülmüştür [20, 21]. Bu çalışmada ise HHD tabanlı yeni bir veri temsilini ilk defa FL ile kullanarak miyoelektrik sistemler için yeni bir karar verme yaklaşımı oluşturulmuştur.

Makalenin geri kalanı şu şekilde yapılandırılmıştır: Bölüm 2'de literatürde yer alan teknoloji harikası çalışmalar özetlenmiştir. Bölüm 3'te, çalışmanın teorik altyapısı sunulmuştur. Bu bölümde, ön işleme ve bölütleme (Bölüm 3.1), sinyal analiz yaklaşımı (Bölüm 3.2), imgeden öznelik çıkarma yaklaşımı (Bölüm 3.3), kümeleme teknikleri (Bölüm 3.4), sinirsel bulanık sistemi (Bölüm 3.5) ve EMG veri seti (Bölüm 3.6) detaylı olarak sunulmaktadır. Deneysel çalışma Bölüm 4'te açıklanmıştır. Bunlarla birlikte, deneysel sonuçlar ve tartışma Bölüm 5'te sunulmuştur. Son olarak, çıkarımlar ve gelecek çalışmalar Bölüm 6'da açıklanmıştır.

## 2. Literatür Özeti (Literature Review)

Rehabilitasyonda kullanılan protezlerin ve dış iskeletlerin kontrolü, sanal gerçeklik vb. uygulamalar için zararsız ve invaziv olmayan bir yöntem olan yüzey EMG (surface EMG/sEMG) sinyallerinin analizi literatürde çokça tercih edilen bir yaklaşımdır. sEMG örüntü tanıma sistemlerini tasarlamak için AI yaklaşımları kullanılarak çeşitli yöntemler önerilmiştir. AI yaklaşımı olarak FL, EMG örüntü tanıma problemlerinde yaygın olarak kullanılmaktadır [22]. Bununla birlikte literatürde popüler olarak ML [18] ve DL [2] yaklaşımlarını kullanan birçok çalışma rapor edilmiştir. Bu sistemler sınırlı sayıda el hareketini belirleyebilir. Bunun aksine, EMG örüntü tanıma sistemi ile artırılabilen akıllı bir sinirsel-bulanık (neuro-fuzzy) yöntem sunan ve böylece sınıflandırılan el hareketlerinin sayısını ve serbestlik derecelerini artırmayı öneren çalışmalar bulunmaktadır [23, 24].

Protez kontrolü için gerçekleştirilen bir çalışmada [25], her adımda iyileştirilmiş performansla sahip işlevsel bir tekniğin kullanıldığı çok aşamalı bir sEMG örüntü tanıma sistemi tasarlanmıştır. Bahsedilen çalışmada sEMG sinyalleri kullanılarak el hareketi komutları Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi'ne (ANFIS) tanımlanmıştır. Zaman ve zaman-frekans alanları ile kombinasyonları sEMG sinyalinin öznelikleri olarak kullanılmıştır. Kombinasyon öznelikleri kullanarak ANFIS sınıflandırması ile önerilen tanıma modeli, karmaşık el hareketlerini belirlemede %92'lik ortalama sınıflandırma doğruluğu ile en iyi sonucu sağladığı görülmüştür. Başka bir çalışmada [1], üst ekstremitenin belirli hareketlerini karakterize etmek için sEMG sinyallerini kullanan bir sistemin geliştirilmesi ve incelenmesi amaçlanmıştır. Belirlenen yedi el ve kol hareketini tanımak için, 30 kişiye ait 8 kanallı EMG sinyallerinden elde edilen öznelik veri setindeki kare ortalamalarının karekökü

(root mean square/RMS) değerleri sinirsel-bulanık mantığına dayalı bir örüntü tanıma algoritmasında girdi olarak kullanılmıştır. Bu çalışmada ortalama doğruluk değeri %86 olarak elde edilmiştir. EMG ve el hareket tabanlı sistemlerdeki hareket sınıflandırılması probleminde yola çıkan diğer bir çalışmada [20], basit ve hesaplama açısından verimli bir sınıflandırma sağlayan teknik önerilmiştir. 4 katılımcının 2 kasından toplanan sEMG sinyallerine ait öznelikler, yeni bir birleşik zaman alanı öznelik çıkarma yöntemi kullanılarak çıkarılmıştır. Bulanık C-ortalama (FCM) kümeleme yöntemi ve dağılım grafikleri, önerilen çok öznelikli yöntem ile diğer doğruluğu ispatlanmış çoklu özneliklere karşı performansını değerlendirmek için kullanılmıştır. Özneliklerin ANFIS'te ve yapay sinir ağlarında (artificial neural network/ANN) sınıflandırılması sonucunda, hesaplama süresinde önemli ölçüde iyileştirme ve %88,90 sınıflandırma doğruluğu sunan ANFIS daha yüksek sınıflandırma başarısı göstermiştir.

sEMG sinyalleri ile kontrol, protezlerin yanı sıra tekerlekli sandalye gibi sistemlerde de kullanılabilir. Fiziksel engelli insanlar için düşük maliyetli tekerlekli sandalye ihtiyacından hareketle bir çalışmada [26], güneş enerjisiyle çalışan tekerlekli sandalyenin tasarımı ve uygulaması sunulmuştur. Tasarlanan tekerlekli sandalyeyi hareket ettirmek için kol kaslarına ait ham sEMG sinyalleri kullanılmış ve ham sEMG sinyallerinden çıkarılan modelleri ve öznelikleri sınıflandırmak için ANFIS kullanılmıştır. Sınıflandırma sonucunda sınıflandırma doğruluğu (%96,85) mevcut yöntemlere kıyasla nispeten yüksek bulunmuştur. Bir başka el hareketlerine ait EMG verisi sınıflandırma çalışmasında [27] ise iki kanallı yüzey elektrotları ile toplanan EMG sinyallerinden RMS, dalga biçimi uzunluğu (wavelength) ve basıklık (kurtosis) öznelikleri çıkarılmıştır. Öznelikleri sınıflandırmak için Mamdani tipi bulanık mantık tabanlı bir sınıflandırma yöntemi uygulanmış ve iki el hareketi için sınıflandırma işlemi ortalama %92,13 doğruluk ile gerçekleştirilmiştir. Çalışma [28]'de, beş parmak hareketini sınıflandırmak için ANFIS kullanılmıştır. EMG sinyallerinden çıkartılan 16 öznelik temel bileşen analizi (principal component analysis/PCA) kullanarak üçe indirilmiş ve sınıflandırma ortalama doğruluğunu %72 olarak elde etmiştir. Çalışma [6] ise proteze girdi sağlamak için sensörlerden elde edilen EMG sinyalinin işlenmesi ve örüntü tanıma kullanılması ile ilgili bir sistem önermişlerdir. Sinyallerden çıkartılan bir özneliğe ait değerler ANFIS'te sınıflandırılmasıyla %98,09 doğruluk elde edilmiştir. Bu gibi çalışmalar ile sEMG ve FL tabanlı sınıflandırıcı yaklaşımlarının bilek fleksiyonu/ekstansiyonu, ön kol supinasyonu/pronasyonu ve protez cihazların el açma/kapama hareketlerini gerçekleştirmede kullanılabilir olduğu vurgulanmıştır.

EMG sinyalleri gibi biyolojik sinyallerin rassal yapısı nedeniyle, tipik istatistiksel sınıflandırıcılar verileri doğru şekilde tanımlayamaz. Bununla birlikte, sınıf sayısı artırıldığında istatistiksel sınıflandırıcıların aksine bulanık sistem gibi akıllı sınıflandırıcılar, veri setindeki en önemli bilgileri tespit ederek hareket tanıma oranındaki düşüşü çözebilir. Literatüre yer alan ANN ve bulanık mantığın diğer yeni yaklaşımlara göre teorik avantajları göz önüne alındığında, sinirsel-bulanık ve ANN tabanlı sınıflandırıcıların bir kombinasyonu olan ANFIS, yüksek doğruluk ve kısa işlem süreleri ile basit ve doğru sınıflandırma yapmak ve miyoelektrik kontrol sistemleri oluşturmak için potansiyel çözümlerdir [20]. Tüm olumlu etkiler düşünülüğünde bulanık mantık tabanlı sistemlerin EMG hareket verisi sınıflandırmada önemli bir potansiyele sahip olduğu söylenebilir [25]. Sınıflandırıcı seçiminin yanında girdi verilerinin temsili de önemli bir konudur. Hareket tahmini için girdi değeri, EMG sinyalinin doğrudan kendisi veya sinyalden öznelik çıkartılarak elde edilen değerler olabileceği gibi [27], sinyalin TD'sinden, FD'sinden veya TFR'lerinden öznelik çıkartılarak elde edilen değerler de olabilmektedir [13]. EMG gibi sinyallere sınıflandırma işleminden

önce analiz yönteminin uygulanması, sinyal içerisinden hareket hakkında daha net bir bilgi ulaşılmaya olanak tanımaktadır [5]. Çünkü TF analiz yöntemleri sonucu oluşan TFR'ler hem zaman hem de frekans bilgisi taşırlar ve TF katsayılarından elde edilecek özneliklerin ANFIS'te kullanılması, harekete ait öznelik değerlerini daha ilgili ve spesifik hale getirebilir. Bununla birlikte HHD, klasik yöntemlerden farklı olarak enerji sızıntısını önleyerek sinyalin daha fazla bilgisini korur [29]. HHD sonucu oluşan Hilbert-Huang spektrumu (HHS), fiziksel olarak da anlamlı ve iyi çözünürlükte sinyal temsilleri ortaya çıkarmaktadır [30].

Bu çalışma kapsamında yapılan literatür taraması sonucunda, EMG örüntü tanıma ve tahmin sistemlerinin performansında veri seti ve optimize edilmiş sonuçlar bakımından bazı eksiklikler olabileceği görülmüştür. Başarılı olduğu öne sürülen yöntemlerin çoğunun sonucu istatistiksel olarak detaylı inceleme yapılmadan genellikle tek bir doğruluk değeri ile sunulmuştur. Bununla birlikte yapılan çalışmalarda kullanılan veri setleri katılımcı, kanal, hareket ve öznelik sayısı itibariyle dengesiz olabilmektedir. Bu çalışmada önerilen yöntem, TFR tabanlı bir yaklaşımla imgelerden öznelik çıkararak yeni ve gelişmiş tahmin performansı sunmaktadır. TFR'nin sinyal hakkında daha iyi bilgi sağlayabileceği ve HHD'nin mevcut konvansiyonel yöntemlere kıyasla avantajlı olduğu bildirilmiştir. Bu çalışmada, EMG'nin HHD ile analizinden elde edilen HHS imgelerinden çıkartılan çeşitli öznelikleri ustaca kullanarak el hareketi tahmini gerçekleştiren FL tabanlı yaklaşım literatüre alternatif ve yeni bir yöntem olarak sunulmuştur.

### 3. Teorik Altyapı (Theoretical Background)

Bu çalışma, zaman alanındaki gürültüden temizlenmiş bir boyutlu (1B) EMG sinyallerine HHD uygulanması ile HHS elde edilmesi ve bu TF imgelerinden çıkarılan çeşitli öznelikler kullanarak hareket tahmini yapılması temeline dayanmaktadır. TFA sonucunda elde edilen üç boyutlu (3B) HHS'ler anlık enerji değerlerinin renkler ile temsil edildiği iki boyutlu (2B) imgelere dönüştürülmektedir. 2B imgelerin gri düzleme atılması ile imgelerden öznelik çıkarılacak format elde edilmektedir. Zaman alanındaki verilerin imge temsiline dönüştürülmesi ile 1B sinyalden öznelik çıkarmak yerine literatürden farklı bir bakış açısı ile 2B temsillerinden öznelik çıkartılarak hareket tahmini gerçekleştirilmiştir. Bu çalışmadaki veri seti, yedi el hareketinin 30 katılımcı tarafından gerçekleştirilmesi sonucu oluşan EMG sinyallerini içermektedir. EMG sinyallerine ön işleme ve bölütleme uygulandıktan sonra HHD işlemi uygulanır. HHD'nin ilk adımı olan Görgül Kip Ayrışımı (GKA) ile içsel mod fonksiyonlarının (İMF) elde edilmesinin ardından İMF seçimi ile Hilbert Dönüşümü (HD) uygulanacak anlamlı İMF'ler belirlenir ve dönüşüm işlemi gerçekleştirilir. Hareket tahmini için kullanılan sınıflandırıcıya gerekli olan girdi verisini elde etmek amacıyla, imgeden öznelik çıkarma işlemi ile HHD sonucu oluşan HHS imgelerinden altı adet imgeye ait öznelikler çıkartılır. Daha sonra, azaltımlı kümeleme (subtractive clustering/SC) ve bulanık C-ortalama (fuzzy C-mean/FCM) kümeleme yöntemleri, elde edilen yeni öznelik veri setine uygulanır ve bu işlemler sonucu elde edilen yeni veri setleri ANFIS'te hareket tahmini için sınıflandırılır. Her bir kümeleme yaklaşımı için ANFIS mimarisi, k-katlamalı çapraz doğrulama (k-fold cross-validation) yöntemi ile eğitilir. Son olarak, tahmin başarımını değerlendirmek amacıyla Alt Uzak k-En yakın komşu (subspace k-nearest neighbors/k-NN) mimarisinde sınıflandırma gerçekleştirilir ve SC-ANFIS ile FCM-ANFIS'in sonuçlarıyla karşılaştırılır.

#### 3.1. Ön İşleme ve Bölütleme (Preprocessing and Segmentation)

Hareketlere ait EMG sinyallerinin analizi, sinyal sınıflarının belirlenmesi, öznelik seçimi, sınıflandırma algoritmasının

belirlenmesi ve elde edilen tahmin doğruluğundan oluşur. sEMG, el hareketini tespit etmenin en etkili yöntemlerinden biri olsa da toplanan sEMG sinyalleri, iç organlar veya elektrikli cihazlar gibi çevreden gelen gürültüleri içerdiğinden ve komşu kaslardan etkilendiğinden, bazı temel elektriksel gürültülerden muzdariptir [18]. sEMG sinyalinden bir hareketin kesin bilgisini çıkarmak için, sinyallere filtreleme işlemleri uygulanır, böylece ilgisiz bilgiler (artifaklar vb.) çıkarılır [31]. Buna göre 0-10 mV ( $\pm 5$ ) aralığındaki EMG sinyallerine 5-500 Hz frekansında dijital bant geçiren filtre ve 50 Hz frekansında çentik filtresi uygulanır. Bölütleme, sinyal içerisinde ilgili ve bilgi içeren bölgeleri çekmek amacıyla gerçekleştirilen, kasın kasıldığı ve dinlendiği zaman dilimlerini tanımlamak için kullanılır. Bu nedenle, veri setinde yer alan 6 sn'lik harekete ait sinyal segmentlerinin başlangıç ve bitişteki 1 sn'lik geçiş durumları alınmayarak sadece ortadaki 4 sn'lik sabit durum sinyali kayan pencereler (sliding windows) yönteminde kullanılmak üzere alınmıştır [9]. Bu çalışmada 200 ms uzunluğundaki %75 örtüşmeli (150 ms overlapping) pencereler kullanılmıştır. Bu işlemlerin tümü MATLAB® R2021a (The MathWorks Inc., ABD) ortamında gerçekleştirilmiştir.

### 3.2. Sinyal Analiz Yaklaşımı (Signal Analysis Approach)

Sinyal analiz yaklaşımında, 1B EMG sinyallerinden 2B EMG imgelerinin elde edilmesi amaçlanmaktadır. TFA, genellikle düzenli zaman aralıklarında bir spektrum hesaplayarak çeşitli sinyal frekanslarının mevcut olduğu zamanları belirlemeye olanak tanımaktadır. Sinyaller belirli zaman aralıklarında analiz edildiğinde, sinyallerin frekans spektrumları daha iyi gözlemlenebilir. Zaman ve frekansta sınırlı fonksiyonlar kullanılarak sinyal analiz edilirse, sinyalin spektral özelliklerinin zaman ve frekans düzlemlerinde daha iyi incelenebileceği bilinmektedir. Sinyal işlemede sıklıkla kullanılan TFA yöntemleri, zaman uzayındaki bir sinyali, zaman ve frekansın fonksiyonu ile eşleştirmeyi sağlar. Bu yöntemler, zamanla değişen spektrum temsillerinden oluşur [16]. Sinyal analizinde STFT, Fourier Dönüşümü (Fourier Transform/FT), WT ve Gabor Dönüşümü (Gabor Transform/GT) gibi farklı uygulama alanına sahip çeşitli dönüşüm teknikleri kullanılmaktadır [32]. Biyolojik sinyallerin durağan ve doğrusal olmayan yapısı göz önünde bulundurulursa sinyalin karakteristiği ile ilgili doğru bilgiler IF değeri tarafından elde edilebilir ve bu değerinin HD ile sinyalin karakteristik bilgilerinin en iyi şekilde tespiti sağlanabilir [16].

#### 3.2.1. Hilbert-Huang dönüşümü (Hilbert-Huang transform)

Hilbert-Huang Dönüşümü, sinyalin analizi ile birlikte sinyalin içsel mod fonksiyonlarına ayrıştırmasını ve IF bilgilerinin öğrenilmesini sağlar. Doğrusal ve durağan yapıda olmayan sinyallerin analizi için geliştirilmiş olan bu yöntem, Görgül kip ayrışımı ve Hilbert Dönüşümü olmak üzere iki temel aşamadan oluşur. Bununla birlikte GKA sonucu oluşan İMF'lerden hangilerine HD uygulanacağını tespit etmek amacıyla ara bir işlem olan İMF seçimi de bu dönüşümün bir parçası olarak düşünülebilir.

#### 3.2.2. Görgül kip ayrışımı (Empirical mode decomposition)

GKA, doğrusal olmayan ve durağan olmayan yapıya sahip olan EMG sinyalinin, İMF adı verilen sonlu bir dizi bileşene ayrıştırılmasına ve sinyali analiz etmesine olanak tanıyan uyarlanabilir bir yöntemdir [33]. Verilen bir  $x(t)$  sinyali için GKA algoritması aşağıdaki gibi özetlenebilir:

*Adım 1:*  $x(t)$  sinyalinin tüm yerel maksimum ve yerel minimum değerleri bulunur.

*Adım 2:* Yerel ekstrem noktalarına interpolasyon yapılır ve sinyalin alt zarfı  $e_{min}(t)$  ve üst  $e_{max}(t)$  zarfı oluşturulur.

*Adım 3:* Alt ve üst zarfların ortalaması alınarak  $m(t)$ , Eş. 1'deki gibi hesaplanır:

$$m(t) = [e_{min}(t) + e_{max}(t)] / 2 \quad (1)$$

*Adım 4:*  $d(t)$  olarak tanımlanan ayrıştırma fonksiyonunu elde etmek için Eş. 2'de verildiği gibi orijinal sinyal  $x(t)$ 'den,  $m(t)$  çıkarılır:

$$d(t) = x(t) - m(t) \quad (2)$$

*Adım 5:* İMF olma koşulu kontrol edilir. Eğer  $d(t)$ 'nin yerel ekstremum sayısı sıfır geçiş sayısına eşit veya birden farklıysa ve  $d(t)$ 'nin ortalaması sıfıra yakınsa,  $\hat{IMF}_1 = d(t)$  olur. Eğer değilse, yeni  $d(t)$  5. adımdaki İMF koşulunu sağlayana kadar,  $x(t)$  sinyali yerine  $d(t)$  kullanarak 1. adımdan 4. adıma kadar olan işlemler tekrarlanır.

*Adım 6:*  $r(t)$  olarak tanımlanan artık fonksiyon Eş. 3'teki gibi hesaplanır:

$$r(t) = x(t) - d(t) \quad (3)$$

*Adım 7:*  $r(t)$ 'nin birden fazla sıfır geçişi varsa, 1. adıma dönülür ve durdurma koşulu sağlanana kadar yeni İMF'i hesaplamak için işlemler tekrarlanır. Sonuçta, orijinal sinyal  $x(t)$ , Eş. 4'teki gibi tanımlanan dikey İMF'lerden oluşmaktadır. Bu şekilde,  $x(t)$  sinyalinin ayrışması sağlanır ve  $x(t)$ , İMF'ler artı bir artık bileşen toplamı olarak Eş. 4'te gösterildiği gibi yazılabilir:

$$x(t) = \sum_i \hat{IMF}_i(t) + r(t) \quad (4)$$

Eş. 4'teki İMF'ler birinci dereceden İMF'ler olarak adlandırılır. Tüm ayrıştırma işlemi sınırlı sayıda İMF ile bitmektedir. EMG sinyalindeki en yüksek frekans salınımı ilk İMF ile sembolize edilir ve sonrakiler, sinyalin daha düşük frekanslı salınımlarını içerir. Nihai  $r(t)$ , sinyalin yalnızca genel eğilimlerini gösterir [34].

#### 3.2.3. İMF seçimi (IMF selection)

HD için uygun İMF'lerin seçimi, tahmin başarısına olumlu bir katkı sağlar [35]. Biyolojik bir sinyalin İMF seçimi için birçok yöntem bulunmaktadır. İMF seçimi için korelasyona dayalı [36], olasılık dağılım fonksiyonuna (probability distribution function/PDF) dayalı [37] veya *t-test* gibi istatistiksel anlamlılığa dayalı çeşitli yöntemler sıklıkla kullanılmaktadır. Bu yöntemlerden istatistiksel anlamlılığa dayalı yöntem, İMF seçiminde etkili sonuçlar sağlar ve EMG için uygun bir yaklaşımdır. Bu yöntemde, istatistiksel anlamlılığı incelemek için verilerin dağılımının normal olup olmadığını belirten  $H$  değeri ve verilerin istatistiksel anlamlılığını belirtip eşik olarak kabul edilen  $p$  değeri (0,05) hesaplanır. İMF'nin  $p$  değeri hesaplandığında, eşikten büyükse İMF'nin istatistiksel önemi vardır ( $H=0$ ), değilse İMF normal dağılıma sahip değildir ( $H=1$ ) [35]. Bu çalışmada, her bir İMF'nin  $p$  ve  $H$  değerleri hesaplanır ve büyükten küçüğe doğru sıralanır.

#### 3.2.4. Hilbert dönüşümü (Hilbert transform)

Hilbert Dönüşümü, belirli bir sinyalin analitik bir karşılığını elde etmek için kullanılan yöntemdir. Zaman ve frekans bilgisini içeren 3B bir grafik (zaman-frekans-enerji) oluşturmak mümkündür. İMF'lerin oluşturulması ve dönüşüm için kullanılacak İMF seçiminden sonra 3B HHS imgesi,  $H(\omega, t)$ , aşağıdaki adımlar ile elde edilir:

- Her İMF'nin anlık özelliklerinin tahmini ( $a(t)$ ;  $\theta(t)$ ;  $\omega(t)$ ).
- Genliğin TF düzlemine yerleştirildiği 3B temsiline oluşturulması,  $H(\omega, t)$  [38].

Analitik sinyal, orijinal  $x(t)$  giriş sinyalinde olduğu gibi tüm bilgiyi koruyan tek taraflı spektrumla birlikte karmaşık bir sinyal olarak tanımlanabilir. Gerçek kısmı orijinal giriş zaman serisidir ve karmaşık kısmı orijinal sinyalin HD'sidir.  $z(t)$  analitik sinyal olarak düşünülürse Eş. 5'te gösterildiği şekilde bir tanımlama yapılabilir:

$$z(t)=x(t)+iy(t)=a(t)e^{j\theta(t)} \quad (5)$$

Eş. 5'te,  $x(t)$  orijinal zaman serisidir ve  $y(t)$  de  $x(t)$  'nin HD'sidir.  $z(t)$ 'nin anlık özellikleri Eş. 6, Eş. 7 ve Eş. 8'de gösterildiği gibi tanımlanabilir:

$$a(t)=[x(t)^2+y(t)^2]^{1/2} \quad (6)$$

$$\theta(t)=\arctan(y(t)/x(t)) \quad (7)$$

$$\omega(t)=\frac{d\theta(t)}{dt} \quad (8)$$

Bahsedilen tanımlamalarda (Eş. 6 – Eş. 8)  $a(t)$ ,  $\theta(t)$  ve  $\omega(t)$  sırasıyla anlık genlik, anlık faz (instantaneous phase/IP) ve anlık frekanstır [33]. Zaman-frekans düzleminde elde edilen 3B grafikler daha sonra 2B düzleme eşlenerek anlık enerji değerleri zaman ve frekans ekseninde renkli imgeler olarak temsil edilebilir. Bu çalışmada HHD işlemi, 4 sn sabit durum EMG sinyaline 50 ms artırımlı kayan pencereler yöntemi uygulanması ile elde edilen 200 ms uzunluğundaki sinyal segmentleri ile gerçekleştirilmiştir. İlk aşamada GKA metodu ile üretilen IMF'lerden *t-testi* sonucu anlamlı bulunan ( $p>0,05$ ) yani normal dağılıma sahip ilk üçüne Hilbert Dönüşümü uygulanır ve 3B HHS spektrumları elde edilir. Son aşamada 3D HHS spektrumları projeksiyon eşleştirme yöntemiyle 2D renkli spektrumlara dönüştürülür.

### 3.3. İmgeden Öznelik Çıkarma (Image-based Feature Extraction)

Öznelik, bir nesnenin veya imgenin ölçülebilir bazı özelliklerini belirten bir veya daha fazla ölçümün bir fonksiyonu olarak tanımlanabilir. FL ve ML gibi yöntemler tahmin veya sınıflandırma işleminden önce ek bir öznelik çıkarma aşamasına ihtiyaç duyarlar. Öznelikler ait oldukları sınıfları temsil ederler ve sınıflandırıcılara girdi olarak kullanılırlar. Bu çalışmada görselleştirilmiş HHS imgelerinden doğrudan çıkarılan özneliklerin sınıflandırıcıda kullanılması ile hareket tahmini işlemi gerçekleştirilmiştir. Çeşitli hesaplamalı yöntemlerle elde edilebilen imge öznelikleri dikkatli bir

şekilde seçildiği takdirde, imgenin karakterizasyonunu sunabilir ve analizi için gerekli olan maksimum ilgili bilgiyi temsil edebilmektedir. Bu çalışmada HHS imgerini temsil etmek için yoğunluk histogram öznelikleri (intensity histogram features) [39] ve Gri Düzey Eş-Oluşum Matrisi (grey level co-occurrence matrices/GLCM) özelliklerine [40] dayalı öznelikler kullanılmıştır. Spektrum veya genel olarak imge analizi araştırıldığında, önceki çalışmaların ortalama, varyans, entropi vb. gibi çeşitli istatistiksel özneliklere yer verdiği görülmüştür [41]. Bu çalışmada da öznelik çıkarma işlemi için yoğunluk histogram özneliklerinden ortalama, varyans, çarpıklık ve basıklık; GLCM tabanlı özneliklerden ise enerji ve entropi olmak üzere toplam altı adet öznelik belirlenmiştir.  $M \times N$  boyutundaki bir HHS görüntüsünün  $(i,j)$  lokasyonundaki piksel değeri  $p(i,j)$  olduğu varsayılırsa, bahsedilen öznelik değerleri Tablo 1'de gösterilen formüller ile hesaplanabilir.

### 3.4. Kümeleme Teknikleri (Clustering Techniques)

Kümeleme, belirli problemleri tahmin ve analiz ederken birçok fayda sunan veri bölütlemesi işlemidir. Gauss üyelik fonksiyonlarını otomatik oluşturmak için farklı kümeleme algoritmaları kullanılmaktadır. Bu algoritmaların ikisi bulanık C-ortalama ve azaltımlı kümelemedir. Uygulama açısından farklılık olsa da her iki teknik de bulanık *eğer-ise* (fuzzy if-then) kurallarını oluşturur. Azaltımlı kümeleme, karmaşık problemleri formüleştirmeden çözebilen öğrenme kabiliyetine sahiptir. Ayrıca küme sayısı ve küme merkezlerini belirlerken hızlı ve tek geçişli bir algoritma sunarken; bulanık C-ortalama ise, veri seti için yüksek doğrulukta sonuç sunar ve bir veri noktasının birden fazla kümeye ait olabileceğinin bilgisini verir [21, 42]. Azaltımlı kümelemenin zor problemlerdeki başarısı ve bulanık C-ortalamanın kesin sınır tayininin zor gerçekleştirildiği verilerdeki başarısı düşünüldüğünde ve benzer çalışmalar göz önüne alındığında [20, 25], bu çalışmada gerçekleştirilen el hareketi tahmininde de başarı gösterebilecekleri öngörülmüştür. Bu nedenle iki kümeleme tekniği karşılaştırmalı olarak ele alınmıştır.

#### 3.4.1. Azaltımlı kümeleme (Subtractive clustering)

Azaltımlı kümeleme, veri kümesindeki küme sayısını ve küme merkezlerinin konumunu tahmin etmede kullanılan hızlı ve tek yönlü bir tekniktir. Küme sayısı kesin olarak belirlenmediğinde, bu yöntemi uygulamak anlamlıdır. SC yönteminde, her veri noktasının potansiyel bir küme merkezi olduğunu varsayılır ve her noktanın küme merkezini belirlemedeki olasılığının bir ölçüsü hesaplanır [42].

**Tablo 1.** Yoğunluk histogram ve GLCM tabanlı öznelikler (Intensity histogram and GLCM-based features)

Özneliğin Adı	Tanım	Formül
Ortalama ( $\mu$ ) (Mean)	Bir görüntünün piksel değerlerinin toplamının piksel sayısına bölünmesiyle ortalama yoğunluk seviyesini tanımlar.	$\mu = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} p(i,j)$
Varyans ( $\sigma^2$ ) (Variance)	Standart sapmanın ( $\sigma$ ) karesidir, ortalama etrafındaki yoğunlukların değişimini temsil eder.	$\sigma^2 = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (p(i,j) - \mu)^2$
Çarpıklık ( $S$ ) (Skewness)	Histogramın ortalama değer etrafında piksel dağılımının asimetri derecesini karakterize etmeyi sağlar.	$S = \frac{1}{MN} \frac{\sum (p(i,j) - \mu)^3}{\sigma^3}$
Basıklık ( $K$ ) (Kurtosis)	Verilerin normal dağılıma göre tepe değerini veya düzlüğünü ölçer.	$K = \frac{1}{MN} \frac{\sum (p(i,j) - \mu)^4}{\sigma^4}$
Enerji ( $E_n$ ) (Energy)	Enerjinin diğer tanımı tekdüzeliktir ve [0 1] aralığında tanımlanır. GLCM özelliklerinin karelerinin toplamını döndürür.	$E_n = \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} p^2(i,j)$
Entropi ( $E$ ) (Entropy)	Bir görüntünün ne kadar düzensiz veya rastgele olduğunun bir ölçütü olarak tanımlanır.	$E = - \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} p(i,j) \log_2 p(i,j)$

Eğer belirlenen bir noktanın çok komşu noktası varsa yoğunluğu yüksek nokta olarak kabul edilir. Bu durumda, tüm noktaların yoğunluğu hesaplanır ve en yüksek yoğunluğa sahip olan nokta birinci küme merkezi olarak tanımlanır. Bir küme merkezine komşu olan noktaların yeni bir merkez olmaması için noktaların yoğunluğu güncellenerek bu işlem devam eder. SC fonksiyonu, bir matris C'de küme merkezini döndürür ve C'deki satırlar küme merkezlerinin konum bilgisini içerir. Küme sayısını da sağlayan bu fonksiyon, bir küme merkezinin etki aralığını tanımlayan ve sigma değerlerini içeren bir "S" vektörünü de döndürür. Buradan elde edilen küme tahminleri, ANFIS'i başlatmak için kullanılabilir.

#### 3.4.2. Bulanık C-ortalama (Fuzzy C-means)

FCM, her veri noktasının üyelik dereceleriyle belirlenen ölçülerde tanımlanan kümelerle ait olduğunu söyler. Kümelenen veri ve küme sayısı fonksiyonun parametreleridir. Fonksiyon ilk tahminle başlar, ancak tahmin büyük olasılıkla yanlıştır. Bununla birlikte, fonksiyon her bir veri noktasına kümeyle ait bir üyelik derecesi atar ve yinelemeli olarak günceller. Bu işlem ile küme merkezleri doğru konuma taşınır. Bahsedilen yineleme, bir veri noktasından o veri noktasına ait üyelik derecesine göre değer verilmiş küme merkezine olan uzaklığı en aza indirerek gerçekleştirilir. Yinelemeler sırasında fonksiyon, nihai küme merkezlerinin matrisini, nihai üyelik fonksiyon matrisini ve hedeflenen fonksiyon değerlerini döndürür [42]. Bu işlemler sonucunda, oldukça hassas ve yaklaşık küme merkezleri elde edilir.

#### 3.5. Sinirsel Bulanık Sistem (Neuro-Fuzzy System)

Bulanık çıkarım sistemi (fuzzy inference system/FIS) 1965'te Zadeh tarafından önerilmiştir [43]. Bulanık mantık sistemleri, insan karar verme sürecini diğer birçok sınıflandırıcıdan daha çok taklit edebilir [25] ve taklit işlemini *eğer-ise* kuralları biçiminde oluşturabilir. Mamdani ve Sugeno olmak üzere yaygın olarak kullanılan iki tip FIS vardır. Bulanık mantık sistemi, EMG gibi biyolojik sinyallere ait bir model sınıflandırabilme yeteneğine sahiptir. Örneğin, bir miyoelektrik sinyalin RMS değerinin '*biraz yüksek*' gibi günlük yaşam diline ait bir ifade ile açıklanması durumunda, bahsedilen değer bulanık küme modelindeki bulanık üyelik değerleri ile ifade edilebilir. FIS'te girişler [0,1] aralığındaki bir değere bulanıklaştırılır. Kümeye ait olma veya olmama durumu aşamalıdır ve açıklamak için kullanılan bulanık üyelik fonksiyonu (membership function/MF) ile karakterize edilerek *eğer-ise* kurallarına göre yorumlanır [26].

#### 3.5.1. Uyarlamalı sinirsel bulanık çıkarım sistemi (Adaptive neuro-fuzzy inference system)

ANFIS, sinir ağı öğrenme algoritmalarını ve bulanık mantığı kullanan çok katmanlı ağ yapısıdır. Diğer bir deyişle, Takagi-Sugeno tipi FIS'e dayanan ileri beslemeli bir tür ANN olduğu söylenebilir. İlk kez 1993'te başlangıçta verilen bulanık sistemine ve mevcut girdi uzayı ile çıktı uzayının eşleşmesini sağlamak için önerildi [44]. Doğrusal olmayan zaman serilerini modellemek için gelişmiş bir yapıya sahiptir. Sugeno'nun daha etkili ve hesaplamada verimli yapıda olması, ANFIS'te Mamdani yerine Sugeno tipi FIS kullanılmasındaki temel nedenlerdendir. Sonuç değeri, doğrusal bir denklem olduğunda birinci dereceden Sugeno FIS olarak adlandırılır. Eğer sonuç sabit bir katsayı ise sıfır dereceli Sugeno FIS denir. Sistemin  $x_1$  ve  $x_2$  olarak iki girişi,  $y$  çıktısı ve kural tabanının Takagi-Sugeno tipi iki bulanık *eğer-ise* kuralı içerdiği varsayılırsa kuralların temsili Eş. 9'daki gibi ifade edilebilir:

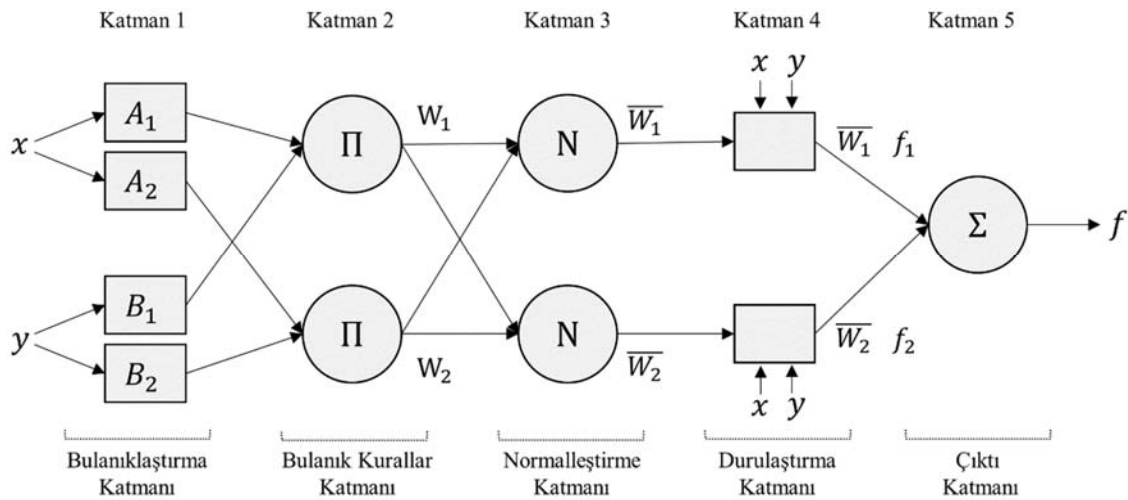
$$\text{Kural}_1: \text{EĞER } (x_1=A_1) \text{ VE } (x_2=B_2) \\ \text{İSE } f_1=p_1x_1+q_1x_2+r_1 \quad (9)$$

$$\text{Kural}_2: \text{EĞER } (x_1=A_2) \text{ VE } (x_2=B_2) \\ \text{İSE } f_2=p_2x_1+q_2x_2+r_2.$$

Eş. 9'da  $p_i$ ,  $q_i$  ve  $r_i$ , FIS'in sonuç kısmındaki doğrusal parametrelerdir.  $x_1$  ve  $x_2$ ,  $i$  düğümünün net girdileridir ve  $A_i$  ve  $B_i$  dilsel etiketlerdir. ANFIS'in mimarisi beş katmandan oluşmaktadır:

- 1. Katman: Dilsel bir etiketin üyelik derecesini oluşturur.
- 2. Katman: Çarpma yoluyla  $w$  kuralının tetikleme gücünü hesaplar.
- 3. Katman:  $i$ 'inci kuralın tetikleme gücünün oranını hesaplar.
- 4. Katman:  $i$ 'inci kuralının genel çıktıya katkısını hesaplar.
- 5. Katman: Genel çıktıyı her kuralın katkısının toplamı olarak hesaplar [44].

Şekil 1'de ANFIS yapısı gösterilmektedir. Her katman, düğüm işlevi tarafından tanımlanan birkaç düğüm içerir. Dikdörtgenler ile gösterilen uyarlanabilir düğümler, bu düğümlerde ayarlanabilen parametre setlerini temsil ederken, dairelerle gösterilen sabit düğümler sistemde sabitlenmiş parametre setlerini temsil eder. Önceki katmanlardaki düğümlerden gelen çıktı verileri mevcut katmandaki girdilerdir [25].



Şekil 1. İki kurallı, iki girişli Sugeno bulanık modeli için ANFIS mimarisi (ANFIS architecture for the two-rule, two-input Sugeno fuzzy model)

ANFIS, model parametrelerini güncellemek için "dereceli alçalma (gradient descent)" ve "en küçük kareler (least-squares)" yöntemlerinin kombinasyonundan oluşan hibrit öğrenme algoritmasını uygular. Bu hibrit öğrenme sürecinin her eğitim adımı (epoch), bir ileri geçiş ve bir geri geçişten (forward and backward pass) oluşmaktadır. Hibrit öğrenme prosedürünün ileri geçişinde döngü çıkışı, 4. katman ve sonuçtaki parametreler en küçük kareler yöntemi ile tanımlanana kadar ileri gider. Geriye doğru geçişte, hata sinyali geriye doğru yayılır ve öncül parametreler dereceli alçalma ile güncellenmektedir [44]. Bahsedilen eğitim adımı, ANFIS'in eğitimindeki yinleme sayısıdır. Bu sayı, hatanın büyüklüğü ile ilgili bir eğitim durdurma kriteri olan hata toleransına ulaşmak için üzerinde çalışılan veri setine göre değişmektedir.

### 3.6. EMG Veri Seti (EMG Dataset)

Bu çalışmada kullanılan veri setinin (çevrimiçi erişilebilir: [45]) etik kurul onayı İzmir Katip Çelebi Üniversitesi Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etik Kurulu tarafından 19/10/2020 tarihli ve 2020-BA2FEN-0001 onay kodu ile sağlanmıştır. 30 sağlıklı katılımcının (15'i kadın ve 15'i erkek) yedi el hareketini gerçekleştirdiği sırada oluşan sEMG sinyalleri, 4 kanaldan Ag/AgCl yüzey bipolar elektrotları kullanılarak MP36 model BIOPAC® cihazı ile toplandı. Şekil 2'de çalışmada kullanılan yedi hareket, dinlenme hali (rest), ekstansiyon (extension), fleksiyon (flexion), bileğin ulnar deviasyonu (ulnar deviation) ve radyal deviasyonu (radial deviation), yumruk (punch) ve açık el (open hand) olarak şekilde 2 kHz örnekleme frekansı ile gerçekleştirilmiştir. Bir hareketin oluşumundan birden fazla kas sorumlu olabildiğinden, belirlenen hareketler için uygun olduğu düşünülen dört farklı yüzey kası uzman hekim yardımıyla seçildi. *Fleksör karpi radialis (flexor carpi radialis)*, *fleksör karpi ulnaris (flexor carpi ulnaris)*, *ekstansör karpi radialis (extensor carpi radialis)* ve *ekstansör karpi ulnaris (extensor carpi ulnaris)* bu çalışma için seçilen ve ölçüm alınan ön kol kaslarıdır. Dört yüzey elektrotu, kasların konumu gözetilerek, mümkün olan en iyi pozisyona göre ön kola yerleştirilmiştir. Bir kişiye ait sinyal kaydının tamamı, her döngüde yedi hareket olmak üzere tekrarlanan 5 döngüden oluşmaktadır. Her hareket 6 sn gerçekleştirilmiştir ve bir kişinin toplam kayıt süresi 490 sn'dir.

### 4. Deneysel Çalışma (Experimental Study)

Veri setinden temin edilen uzun 490 sn EMG sinyallerinden, gürültüsüz ve hareket bilgisini içeren sinyalleri elde edebilmek için ön işleme; hareketin gerçekleştiği anlarını elde edebilmek ve ANFIS sınıflandırıcısına daha çok veri sağlamak için bölütleme işlemleri MATLAB®'da uygulandı. Ön işleme aşamasında sinyallere 5-500 Hz arası dijital bant geçiren filtre ve 50 Hz çentik filtre uygulandı. Filtrelenen sinyaller, hareketin anlarını tespit etmek ve HHD'yi kolaylıkla uygulamak için bölütleme işlemine tabi tutulmuştur. Her bir segment, hareketin gerçekleştirmesi esnasındaki yaşanmış olabilecek gecikmeler göz önünde bulundurularak 6 sn yerine orta kısımda bulunan kararlı durumlarından 4 sn'lik segmentler halinde bölütlenmiştir. Son aşamada 50 ms artırımlı 200 ms'lik dikdörtgen pencereler ile her bir harekete ait toplamda 77 adet sEMG segmenti


oluşturulmuştur. Nihai EMG segmentlerine HHD uygulanması sonucunda Hilbert-Huang spektrumları elde edilir ve bu spektrumlardan imge bazlı öznelik çıkarma prensibi gözetilerek MATLAB® ile spektrumlara ait altı adet öznelik (ortalama, varyans, çarpıklık, basıklık, enerji, entropi) çıkartılır. Veri seti, ANFIS mimarisinde k-katmanlı çapraz doğrulama yöntemi ile eğitilmek üzere hazırlanmış ve k değeri 5 olarak seçilmiştir. Sınıflandırmadan önce ANFIS için imgelere ait altı öznelikten oluşan yeni veri kümesine sırasıyla SC ve FCM kümeleme işlemleri uygulanmıştır. Her iki yöntem için de hibrit optimizasyon uygulanıp eğitim sürecinin adım sayısı (epoch) 100 ve hata tolerans değeri 0 olarak kabul edilmiştir. SC parametreleri MATLAB®'da ANFIS ara yüzündeki parametre ekranından ayarlanmıştır. FCM'de ise 'genfis' komutu kullanılarak hesaplanan parametreler ANFIS ara yüzüne aktarılmıştır. İki kümeleme yönteminde de çapraz doğrulama işlemi yapıldığından her tekrar için en iyi sonucu veren parametreler ile MF sayıları belirlenmiş ve verilere uygulanmıştır. SC yöntemi uygulanırken etki aralığı (range of influence), sıkıştırma faktörü (squash factor), kabul oranı (accept ratio) ve red oranı (reject ratio) parametreleri kullanılmaktadır. Etki aralığı bir kümenin yarıçapını gösterirken, sıkıştırma faktörü ise bir küme merkezinin komşuluğunu belirleyen yarıçap değerlerini çarpmak için kullanılan kümenin uzak noktalarının potansiyelini bastırmak için kullanılır. Kabul oranı ilk küme merkezinin potansiyelini belirler ve yüksek değerler küme merkezi olmak için yüksek potansiyeli ifade eder. Red oranı ise ilk küme merkezinin potansiyelini belirler ve bu değer altında kalanlar küme merkezi olarak reddedilir. Bu parametrelerin değerleri ara yüzdeki orijinal gösterimiyle Tablo 2'de sırası ile verilmiştir. Bunlara ek olarak, toplam verinin (80.850 = 30 kişi x 5 tekrar x 7 hareket x 77 segment) her parçasında 16.170 satır veri olacak şekilde eşit parçalara ayrılmış hali (P1, P2, P3, P4, P5), hangi parçalarının eğitim ve test verisi olarak kullanıldığı, girilen parametreler sonucu elde edilen ve en iyi sınıflandırma sonucunu sağlayan MF sayıları (kural sayıları) Tablo 2'de gösterilmektedir.

FCM için ANFIS sisteminde yer alan parametreler (FCM options) aşağıda yer almaktadır:

- Bulanık bölüm matrisi ( $U$ ) için üs değeri,
- Pozitif tamsayı olarak belirtilen maksimum yinleme sayısı,
- Pozitif skaler olarak belirtilen iki ardışık yinleme arasındaki nesnel işlevde minimum iyileşme,
- Her yinlemeden sonra nesnel işlev değerinin gösterilip görüntülemeyeceğini belirten gösterge.

Buradaki son parametre (iv) doğru veya yanlış (true/false) değerini almaktadır ve bu çalışmada bu parametrenin doğru veya yanlış olma durumu '0' ve '1' ile gösterilmiştir. Diğer FCM parametrelerinin alabileceği değer aralığı gözetilerek veri setine en uygun ve en iyi sonucu veren parametreler belirlendi ve her tekrar için uygulandı. Tablo 2'de bu parametreler yukarıdaki sıra ile (i, ii, iii, iv) yer almaktadır.

Sınıflandırma sonuçlarından her bir tekrara ait karışıklık matrisleri (confusion matrix/CM) elde edilmiştir. Karışıklık matrisleri, sınıflandırma işlemini ve sonuca ilişkin çıktılarını analiz etmede fayda



Şekil 2. 7 el hareketi: a) dinlenme, b) ekstansiyon, c) fleksiyon, d) ulnar ve e) radyal deviasyon, f) yumruk ve g) açık el hareketi (7 hand gestures: a) rest, b) extension, c) flexion, d) ulnar and e) radial deviation, f) punch, and g) open hand)



**Tablo 2.** SC ve FCM yöntemleri için uygulanan parametreler (Applied parameters for SC and FCM methods)

Yöntem	Tekrar	Eğitim Setleri	Test Seti	Parametreler	MF Sayısı
SC	1	P2, P3, P4, P5	P1	0.24 , 1.3 , 0.4 , 0.395	30
	2	P1, P3, P4, P5	P2	0.26 , 1.0 , 0.4 , 0.395	38
	3	P1, P2, P4, P5	P3	0.24 , 1.4 , 0.4 , 0.395	25
	4	P1, P2, P3, P5	P4	0.3 , 1.33 , 0.4 , 0.395	16
	5	P1, P2, P3, P4	P5	0.3 , 1.33 , 0.4 , 0.395	19
FCM	1	P2, P3, P4, P5	P1	1.5 , 85 , 0.001 , 0	18
	2	P1, P3, P4, P5	P2	1.5 , 85 , 0.001 , 0	16
	3	P1, P2, P4, P5	P3	1.5 , 85 , 0.001 , 0	26
	4	P1, P2, P3, P5	P4	1.5 , 85 , 0.001 , 0	17
	5	P1, P2, P3, P4	P5	1.5 , 85 , 0.001 , 0	16

sağlamaktadır. Bu matrisler kullanılarak değerlendirme metrikleri hesaplanabilir ve analizi sayısal değerlerle ifade ederek karşılaştırma yapmaya olanak tanır. Sınıflandırma sonuçları, doğru sınıf (true class) ve tahmin edilen sınıf (predicted class) olarak matris şeklinde görselleştirilmiştir. Duyarlılık (sensitivity), özgüllük (specifity), hassasiyet (precision), doğruluk (accuracy) ve F<sub>1</sub>-Skor (F<sub>1</sub>-Score) ölçütleri her bir yönteme ait karışıklık matrislerinden aşağıda verilen Eş. 10-Eş. 14'e göre hesaplanmıştır [46]:

$$\text{Duyarlılık} = \frac{GP}{GP+YN} \quad (10)$$

$$\text{Özgüllük} = \frac{GN}{GN+YP} \quad (11)$$

$$\text{Hassasiyet} = \frac{GP}{GP+YP} \quad (12)$$

$$\text{Doğruluk} = \frac{GP+GN}{P+N} = \frac{GP+GN}{GP+GN+YP+YN} \quad (13)$$

$$F_1\text{-Skor} = 2 \cdot \frac{\text{Duyarlılık} \times \text{Hassasiyet}}{\text{Duyarlılık} + \text{Hassasiyet}} \quad (14)$$

Yukarıda yer alan eşitliklerde (Eş. 10-Eş. 14) *P* doğru olarak nitelendirilen ve *N* yanlış olarak nitelendirilen toplam sınıf sayısını, *YP* yanlış pozitif sayısını, *YN* ise yanlış negatif sayısını, *GP* gerçek pozitif sayısını ve *GN* gerçek negatif sayısını göstermektedir. Bunlarla birlikte, iki bulanık mantık kümeleme işleminin sonuçlarını değerlendirmek için farklı ölçütlerden de yararlanılmıştır. Bu çalışmada, SC ve FCM için korelasyon katsayısı (coefficient of correlation/R), kare ortalamalarının karekökü (root mean squared error/RMSE), ortalama mutlak hata (mean absolute error/MAE) ve determinasyon katsayısı (coefficient of determination/R<sup>2</sup>) değerleri aşağıda yer alan Eş. 15-Eş. 18'e göre hesaplanmıştır:

$$R = \frac{N \sum xy - \sum x \sum y}{\sqrt{[N \sum x^2 - (\sum x)^2][N \sum y^2 - (\sum y)^2]}} \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (16)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (17)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (18)$$

Buradaki eşitliklerde (Eş. 15 – Eş. 18), *y*'nin tahmin edilen değeri  $\hat{y}$  ile ve *y*'nin ortalama değeri  $\bar{y}$  ile ifade edilmektedir. SC-ANFIS ve FCM-ANFIS tabanlı yaklaşımlar için bu değerler, çapraz doğrulama işleminin her bir aşamasında hesaplanmıştır. Bulanık mantık yaklaşımlarının sonuçlarını kıyaslamak amacıyla ML yöntemi olan Alt Uzay k-NN modeli aynı verilerle k-katmanlı çapraz doğrulama (*k*=5) stratejisi ile MATLAB® *Statistics and Machine Learning Toolbox* ortamında gerçekleştirilmiştir. Ayrıca önerilen HHS tabanlı

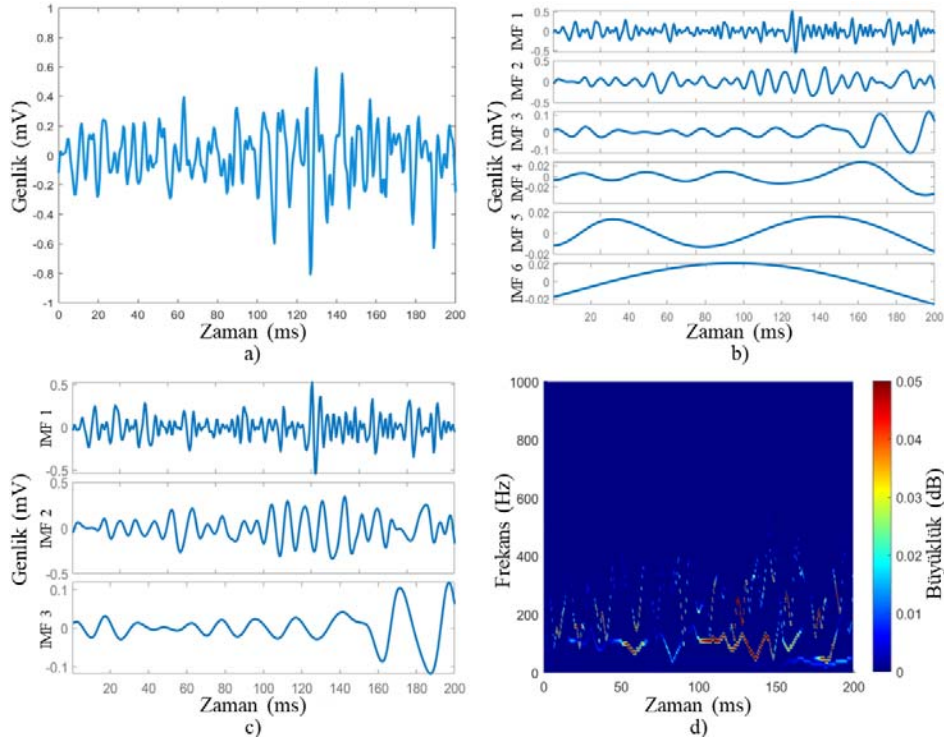
TF imgelerinden öznelik çıkarmayı amaçlayan yöntemin başarısını sınamak amacıyla, geleneksel yöntem olan ön işlenmiş ve bölütlenmiş sEMG verilerinden doğrudan öznelikler çıkartılmıştır. Bu öznelikler daha önce bahsedilen 6 özneliğin (ortalama, varyans, çarpıklık, basıklık, enerji ve entropi) 1B EMG sinyallerine doğrudan uygulaması ile gerçekleştirilmiştir. Bu öznelikler Alt Uzay k-NN modellerinde eğitilerek sınıflandırma performansları karşılaştırılmıştır.

## 5. Deneysel Sonuçlar ve Tartışmalar (Experimental Results and Discussions)


Ön işleme ve bölütleme uygulanan EMG sinyallerine GKA uygulanması ile değişen sayılarda İMF'ler elde edilmiştir. Tüm İMF'ler içerisinde, *t-test* tabanlı istatistiksel seçim yöntemiyle normal dağılıma sahip (*p*>0,05) ilk üç İMF, HD'de kullanmak için belirlenmiştir. HHD işleminin sonucunda tüm katılımcılara ait toplamda 80.850 adet Hilbert-Huang spektrum imgesi elde edilmiştir. Ham sEMG verisinden bir 2B TF temsili elde edilmesi aşmasına dair bir örnek Şekil 3'te gösterildiği gibidir. Spektrum imgelerinden çıkarılan altı öznelik kullanılarak oluşturulan veri seti ile zaman serisi analiz yöntemini kullanan yeni bilgi temsili elde edilmiştir. İlk yirmi dört sütun (6 öznelik x 4 kanal) öznelik (girdi) ve son sütun sınıf (çıkış) sütunu olmak üzere 80.850x25 boyutunda bir veri seti oluşturulmuştur. Daha sonra veri küçültme amacıyla farklı kanallardan elde edilen her bir öznelik değerinin ortalaması alınmış ve sütun sayısı 6'ya indirgenmiştir. Bu verilerin %80'i (64.680) eğitim için, %20'si (16.170) ise test için ayrılarak iki farklı sinirsel-bulanık tabanlı yaklaşımda kullanılmıştır. Çapraz doğrulamadaki tekrarlardan birine en iyisine ait MATLAB®'da oluşturulan 19 kuralı (MF'li) ANFIS ağ yapısı örnek olarak Şekil 4'te gösterilmektedir.

Yukarıda detayları açıklanan modellerle ait test verilerinin birinci tekrarlarına ait karışıklık matrisleri Şekil 5'te gösterilmektedir. 16.170 test verisi içerisinde, her harekete ait 2.310 veri bulunmaktadır. Karışıklık matrislerindeki değerler kullanılarak duyarlılık, özgüllük, hassasiyet, doğruluk ve F<sub>1</sub>-Skor ölçütleri her bir kümeleme yönteminin her bir tekrarı için hesaplanmış ve ortalamaları Tablo 3'te gösterilmiştir. Tablodaki metriklerde görüldüğü üzere SC-ANFIS yaklaşımı FCM-ANFIS yaklaşımına göre daha iyi sınıflandırma performans sağlamıştır.

Yukarıda yer alan Tablo 3 tekrar bazında bir değerlendirme sunmaktadır. Hareket bazında bir değerlendirme yapıldığında, karışıklık matrislerinde de görüldüğü gibi her el hareketi için sınıflandırma değerleri birbirinden farklı olarak elde edilmiştir. **Şekil 5**'teki matrisler sadece birinci tekrara aittir ve diğer tekrarlar elde edilen matrisler de dahil edildiğinde her hareket için SC-ANFIS ve FCM-ANFIS yöntemlerinin test verisi sonuçlarından hesaplanan ortalama değerler incelenmiştir. Önceki kısımda belirtildiği gibi her hareket için SC tabanlı yöntem ile daha iyi sonuçlar elde edilmiştir. Yedi el hareketi arasında kıyaslama yapıldığında ise en iyi



**Şekil 3.** a) Ekstansiyon hareketine ait 200 ms sEMG sinyali, b) GKA sonucu oluşmuş altı İMF, c) İMF seçimi ile belirlenen ilk üç İMF, d) ilk üç İMF'in Hilbert-Huang Spektrumu  
(a) 200 ms sEMG signal of the extension gesture, b) six IMFs obtained from the GKA, c) the first-three IMFs determined by the IMF selection, d) Hilbert-Huang Spectrum of the first-three IMFs)



**Şekil 4.** Sınıflandırma sonucu oluşan 19 kurallı ANFIS modeli (ANFIS model with 19 rules resulting from classification)

sınıflandırılan hareket yumruk hareketidir. Ancak, diğer el hareketlerindeki başarı yumruk hareketinin başarısından çok da farklı değildir. Bu harekette doğruluk SC-ANFIS için %99,00 ve FCM-ANFIS için %97,10 olarak elde edilmiştir. Bu harekette diğer hareketlere kıyasla kas aktivasyonunun yüksek düzeyde olduğu düşünülürse, hareket sonucunda oluşan sinyaller ve dolayısıyla HHS imgelerinde diğer hareketlere kıyasla daha ayırt edici bir örüntü elde edilmiş olabilir. Bu nedenle bu hareketle ilgili imgelerden çıkarılan öznitelikler de diğer hareketlere göre daha iyi ayırt edilebildiği

düşünülmektedir. Yumruk hareketinden sonra fleksiyon (SC için %98,36 ve FCM için %95,97) hareketi ise %95'in üzerinde doğruluk değeri elde etmiştir. Performans değerlerine göre bu hareketlerden sonra gelen sırasıyla açık el, dinlenim ve radial deviasyon hareketleri her iki kümeleme yöntemi için de %93'ün üzerinde doğruluk sunmuştur. Son olarak her iki kümeleme yönteminde en az sınıflandırma doğruluğu sunan hareketler sırasıyla ulnar deviasyon (SC için %89,87 ve FCM için %88,57) ve ekstansiyon (SC için %88,27 ve FCM için %82,81) olmuştur.

Sınıflandırma sisteminin farklı hareketler için farklı doğruluk değerleri sağladığı görülmektedir. Bu durumda yanlış tanımlama ve sınıflandırma durumunun etkisi vardır. Hareketin doğası gereği her bir harekete dahil olan kasların sayısı, türü veya hareketler arasındaki benzerlik değişkenlik gösterir. Bu durum sınıflandırma performansındaki değişkenliğin nedeni olabilir. İlgili ve uygun sayıda kastan EMG temini, daha iyi ön işleme ve büyük veri kümesi kullanılmasıyla değişkenlik en aza indirilebilir. Örneğin, birincil aktivasyon kasları aynı olan hareketler benzer kabul edilebilmektedir [25]. Bu nedenle, yanlış sınıflandırma durumlarında bahsedilen koşulların etkisinin olabileceği düşünülmektedir.

Kullanılan her iki yöntemin (SC-ANFIS ve FCM-ANFIS) performansını değerlendirmek amacıyla eğitim ve test verileri için ayrı ayrı hesaplanan R, RMSE, MAE ve  $R^2$  değerleri Tablo 4'te sunulmuştur. Tablo 4'teki RMSE ve MAE değerleri SC-ANFIS model sınıflandırma tahminlerinin, FCM-ANFIS modeline kıyasla deneysel değere daha yakın olduğunu göstermektedir. R korelasyon

katsayılarında ise, 1'e yakın değerlerin değişkenler arası doğru yönlü bir ilişki olduğunu ifade ettiği bilindiğinden, girdi verileri ile SC'nin FCM'ye göre daha iyi bir ilişki kurduğunu ortaya koyar. Benzer şekilde, elde edilen regresyon denkleminin veriye uygunluğunu test eden  $R^2$  determinasyon katsayısında, test verileri için SC yönteminin FCM'ye göre daha üstün olduğu görülmektedir.

Gerçekleştirilen tüm sınıflandırma sonuçlarına ait değerlendirme ölçütlerinin karşılaştırması Tablo 5'te verilmiştir. HHS imgelerinden elde edilen özneliklerin Alt Uzak k-NN aracılığı ile sınıflandırılması ile %81,45'lik bir doğruluk elde edilmiştir. Aynı özneliklerin 1B versiyonlarının doğrudan sEMG sinyalinden çıkartılması ve Alt Uzak k-NN ile eğitilmesi sonucu model %72,17'lik bir başarı sağlamıştır. İki model arasında neredeyse %9,28'lik bir başarı farkı ortaya çıkarmıştır. Bu durum HHD aracılığı ile elde edilen özneliklerin el hareketlerini sınıflandırmada daha anlamlı sonuçlar ürettiğini kanıtlar. Bu ara yöntem doğrusal ve durağan olmayan sinyallerin el hareketi örüntüsünün çıkartılması adımında gerekliliğini ortaya koyar. Aynı

Gerçek Değerler	Tahminlenen Değerler						
	Açık el	Dinlenim	Ekstansiyon	Fleksiyon	Radyal Deviasyon	Ulnar Deviasyon	Yumruk
Açık el	2221		2	2	23	21	41
Dinlenim	1	2214	56	23	4	5	7
Ekstansiyon	16	3	2046	121	23	98	3
Fleksiyon	3	3	2	2272	20		10
Radyal Deviasyon	17	2	10	50	2197	22	12
Ulnar Deviasyon	12	3	2	3	172	2076	42
Yumruk	1	5	7	4	3	3	2287

a)

Gerçek Değerler	Tahminlenen Değerler						
	Açık el	Dinlenim	Ekstansiyon	Fleksiyon	Radyal Deviasyon	Ulnar Deviasyon	Yumruk
Açık el	2186	2	8	6	34	18	56
Dinlenim	7	2186	72	18	3	10	14
Ekstansiyon	13	11	1913	182	32	157	2
Fleksiyon	24	2	1	2217	21	12	33
Radyal Deviasyon	32	4	15	52	2155	25	27
Ulnar Deviasyon	36	5	15	21	146	2039	48
Yumruk	19	8	11	6	17	6	2243

b)

**Şekil 5.** Test verilerinin birinci tekrarlarına ait karışıklık matrisleri: a) SC-ANFIS'ye ait sınıflandırma, b) FCM-ANFIS'ye ait sınıflandırma  
(Confusion matrix of the first-fold of test data: a) Classification for SC-ANFIS, b) Classification for FCM-ANFIS)

**Tablo 3.** SC ve FCM test sonuçlarına ait performans değerlendirme ölçütleri (Performance evaluation metrics for SC and FCM test results)

Yöntem	Tekrar	Duyarlılık (%)	Özgüllük (%)	Hassasiyet (%)	Doğruluk (%)	F1-Skor (%)
SC	1	94,70	99,12	94,81	94,70	94,69
	2	95,18	94,07	94,00	94,62	94,59
	3	94,52	92,90	92,76	93,69	93,63
	4	94,93	92,76	92,58	93,82	93,74
	5	92,58	90,53	90,29	91,53	91,42
	Ortalama	93,61	93,67	92,89	93,88	94,38
FCM	1	92,39	98,73	92,50	92,39	92,35
	2	92,45	89,96	89,80	91,18	91,11
	3	92,38	91,63	91,53	92,00	91,95
	4	93,22	90,42	90,11	91,77	91,64
	5	91,99	89,77	89,49	90,85	90,72
	Ortalama	91,55	91,64	90,69	92,10	92,49

**Tablo 4.** SC ve FCM'nin eğitim ve test sonuçlarına ait performans değerleri (Performance values of training and test results for SC and FCM)

Model	R	RMSE	MAE	$R^2$
SC (Eğitim)	0,9919	0,8318	0,1937	0,9841
SC (Test)	0,9624	0,8973	0,2671	0,9327
FCM (Eğitim)	0,9828	0,8796	0,3296	0,9658
FCM (Test)	0,9554	0,9098	0,3858	0,9136

zamanda, SC-ANFIS'in %93,88 doğruluk değeri ile FCM-ANFIS (%92,10) modeline göre daha iyi ve her iki bulanık mantık yaklaşımının da doğruluk değerleri klasik makine öğrenmesi algoritmalarından olan Alt Uzak k-NN'ye göre daha yüksek elde edilmiştir. Sadece YN ya da YP değil tüm hata oranlarını içeren bir ölçme metriği olması nedeniyle F1-skor sonuçları önemli bir ölçüttür. Bu nedenle üç modele ait metrikler içerisinde F1-Skor sonuçları incelendiğinde, Alt Uzak k-NN'nin performansı, SC-ANFIS ve FCM-ANFIS ile karşılaştırıldığında geride kaldığı görülmektedir. Bununla birlikte, SC-ANFIS yaklaşımı FCM-ANFIS'e göre daha iyi sonuçlar sunması nedeniyle elde edilen öznel veri setine uygulanabilirlik açısından daha tercih edilebilir bir yaklaşım olduğu sonuçlarla desteklenmiştir.

Son olarak, önerilen hareket tahmin sisteminin sonuçlarını değerlendirmek için son yıllarda gerçekleştirilmiş FL-tabanlı bazı çalışmalarla karşılaştırma yapıldı. FL-tabanlı sınıflandırıcı yöntemler arasında tam, kapsamlı ve adil bir karşılaştırma elde etmek için, kişi sayısı, kas türleri, el hareketlerinin sayısı, kullanılan öznel veri sayısı ve diğer faktörler yer alacak şekilde Tablo 6 oluşturulmuştur. Bununla birlikte, bu çalışma içerisinde uygulanan SC ve FCM tabanlı yöntemler kendi arasında ve daha sonra diğer literatür çalışmaları ile karşılaştırılmıştır. Karmaşıklık düzeyine, el hareketi sınıf sayısına, kas sayısına, öznel veri sayısına ve veri setindeki kişi sayısına göre, önerilen yöntemin üstün olduğu gösterilmiştir. Bu çalışma veri seti yapısı itibari ile de Tablo 6'daki çalışmalarda kullanılan verilerin çoğuna göre daha kapsamlı olduğu görülmektedir. Bununla birlikte, kullanılan öznel veri türleri karşılaştırıldığında, diğer çalışmalar doğrudan sinyalin zaman alanından [1, 20, 25, 27] veya TFR'lerden [25] öznel verileri elde etmiştir. Bu çalışmada ise sinyal analiz yönteminden (HHD) sonra elde edilen TF spektrum imgelerinden çıkartılan öznel veriler kullanılarak gerçekleştirilen sınıflandırma yöntemiyle %94,38 (SC) gibi bir F1-Skoru ve %93,88 (SC) doğruluk yüzdesi sunulmuştur. Çalışma [1]'de, kişi sayısı önerdiğimiz çalışma ile aynı olmasına ve 8 elektrot kullanımına karşın, sadece RMS değerinin öznel veri olarak kullanılması nedeniyle sınıflandırmada tek bir parametreye bağlı kaldığı için veri temsilinde yetersiz bilgi olabileceği düşünülmektedir. Çalışma [25] sonuç itibari ile yüksek doğruluk verse de kişi sayısı ve kas (elektrot)

sayısı olarak diğer çalışmalar gibi yetersiz kalmıştır. Çünkü bilindiği üzere sinyal ölçümü yapılan kas sayısındaki artış, doğruluk değeri ile doğru orantılı olarak artış göstermektedir [47].

Tablo 6'da yer alan diğer yöntemler kişi sayısı bakımından incelendiğinde, çalışma [26], [27] ve [28]'de sadece bir kişiye ait verilerin kullanıldığı görülmüştür. Bu durum bahsedilen çalışmaların doğruluk değerleri yüksek olsa da yöntemlerini ve sonuçlarını tartışmaya açık kalmıştır. Bu çalışmalarda elde edilen performans değerleri yalnızca kişisel kullanım için gerçekleştirilecek bir modelleme için uygun olabilir. Aksi takdirde oluşturulan model yeni verileri test etmede yetersiz kalabilir. Bu çalışma ile aynı sayıda hareketi sadece bir tane öznel veri kullanarak sınıflandıran çalışmada [6], yüksek bir doğruluk elde edilse de kişi sayısı ile ilgili bilgi sunulmamıştır. Bunlarla birlikte, çalışmalarda uygulanan çeşitli bulanık mantık yaklaşımları farklı sonuçlara neden olmaktadır. Çalışma [27] diğer çalışmaların aksine Mamdani tipi bulanık mantık sistemi kullanmıştır. Bu nedenle bulanık kurallar, manuel bir şekilde öznel veriler ve hareketler gözetilerek oluşturulmuştur. Bahsedilen çalışmanın sonucu iyi olsa da diğer yaklaşımlarda uygulandığı gibi manuel bir şekilde kuralları oluşturmak yerine ANFIS'in kuralları kendi ağırlarında oluşturması daha çok tercih edilen bir yaklaşımdır. Mamdani tipi sınıflandırma çoklu veri setleri için uygun olmayacağından Sugeno tabanlı ANFIS sistem oluşturulduğunda kolaylık sağlar. Çalışma [48]'de ise diğer çalışmalardan farklı olarak bir genetik bulanık sınıflandırıcı geliştirilerek üç hareket sınıflandırılmış ve %67 test doğruluğu elde edilmiştir. Fakat çalışma [48]'de de Mamdani tipi çıkarım sistemi kullanılmıştır ve elde edilen test doğruluğu da Mamdani tipi sınıflandırmanın çoklu veri setleri için uygun olmayacağı bilgisini doğrular niteliktedir. Ayrıca, elde edilen performans değerleri diğer çalışmalara göre hayli düşüktür. Bunlara ek olarak, iki kümeleme yönteminin önceki çalışmalarda (çalışma [25] (SC) ve çalışma [20] (FCM)) ayrı ayrı kullanıldığı görülmüştür. Bu çalışmada ise kümeleme yöntemleri aynı veri seti ile kullanılmış ve bu sayede iki farklı yöntem için karşılaştırılabilir bir yaklaşım sunulmuştur. Literatürde farklı yöntemlerle elde edilmiş SC-ANFIS kullanan bir çalışmanın [25], FCM-ANFIS kullanan diğer bir çalışmaya [26] göre daha yüksek doğruluk sunduğu görülmüştür. Önerilen bu çalışmada da benzer durum aynı veri seti üzerinde test

**Tablo 5.** SC-ANFIS, FCM-ANFIS ve Alt Uzak k-NN yöntemleri sonucu elde edilmiş sınıflandırma performansları (Classification performances obtained as a result of SC-ANFIS, FCM-ANFIS and Subspace k-NN methods)

Model	Duyarlılık (%)	Özgüllük (%)	Hassasiyet (%)	Doğruluk (%)	F1-skor (%)
SC-ANFIS	93,61	93,67	92,89	93,88	94,38
FCM-ANFIS	91,55	91,64	90,69	92,10	92,49
Alt Uzak k-NN	77,99	85,89	87,63	81,45	82,53
Alt Uzak k-NN (sEMG tabanlı)	70,88	73,63	75,26	72,17	73,01

**Tablo 6.** Literatürde yer alan çalışmaları içeren karşılaştırma tablosu (Comparison table of the current studies in literature)

Çalışma	Yıl	Sınıflandırıcı Tipi	Hareket sayısı	Kişi sayısı	Kanal sayısı	Öznelik sayısı	Doğruluk (%)
[25]	2011	Sugeno (SC-ANFIS)	6	4	2	4	92,00
[1]	2013	Sugeno (Sinirsel-bulanık)	7	30	8	1	86,00
[20]	2015	Sugeno (FCM-ANFIS)	4	4	2	6	88,90
[26]	2016	Sugeno (ANFIS)	4	1	2	4	96,85
[27]	2017	Mamdani (Fuzzy Logic)	2	1	2	3	93,12
[28]	2018	Sugeno (ANFIS)	5	1	8	13	72,00
[6]	2020	Sugeno (ANFIS)	7	-	8	1	98,09
[48]	2022	Genetik Bulanık Sınıflandırıcı	3	36	8	1	67,00
Önerilen yöntem	2022	Sugeno (SC-ANFIS ve FCM-ANFIS)	7	30	4	6	SC-ANFIS: 93,88 FCM-ANFIS: 92,10

edilmiştir. Sonuçlar SC dayalı yöntemin FCM'ye göre daha başarılı olmasını doğrular niteliktedir. Bu durumun temel nedeni; FCM'nin yerel minimum noktalarına sıkışmasından ve verilerdeki aykırı değerlerin üstesinden gelememesinden kaynaklı olabilir [49]. Ayrıca elde edilen sonuçlar HHD dönüşümü ile oluşturulan TF imgelerinin sınıflandırma çalışmalarında kullanılabilirliğini destekler. Son olarak, FL-tabanlı sistemin ML yöntemine göre daha iyi sonuç üretmesi, kural tabanlı sistemlerin de sınıflandırma problemleri için kullanılabilirliğini önerir.

## 6. Sonuçlar (Conclusions)

Bu çalışmada, el hareketi tahmini için ANFIS'e dayalı yeni bir yaklaşım önerilmiştir. 30 katılımcının dört ön kol kasından toplanan yedi el hareketine ait sEMG verilerinin yer aldığı geniş bir veri seti kullanılmıştır. Bununla birlikte, önerilen çalışma benzer nitelikteki veri seti içeren FL-tabanlı çalışmalarından, sınıflandırma için daha fazla öznelik kullanması ile ayrılmaktadır. Özellikle, HHS imgelerinden çıkarılan imgeye ait çeşitli öznelikler kullanılarak yeni bir veri seti ile sınıflandırma gerçekleştirilmesi diğer çalışmalardan farklı ve özgün bir bakış açısıyla sınıflandırma probleminin ele alınmasını sağlamıştır. Bildiğimiz kadarıyla HHS imgelerinin daha önce FL-tabanlı bir sistemde el hareketini sınıflandırmak için veri olarak kullanılmamıştır. Bu çalışmada TF imgelerine ait özneliklerin hareketi sınıflandırma amacıyla kullanılması, EMG gibi analizi zor olan durağan ve doğrusal olmayan biyolojik sinyallerle ilgili uygulamalara alternatif bir sınıflandırma yaklaşımı sunmuştur. TF imgelerine ait altı öznelik verileri iki farklı kümeleme yöntemine tabi tutulmuş ve kümeleme yöntemlerinin sınıflandırma üzerindeki başarısı da incelenmiştir. SC-ANFIS (%93,88) tabanlı sistemin FCM-ANFIS'e (%92,10) göre, seçilen yedi el hareketinin her birini tanımak için daha yüksek doğruluk elde ettiği ve aynı zamanda her iki yöntemin de aynı veriler kullanarak bilinen ve literatürde yer alan bir ML yaklaşımı olan Alt Uzak k-NN ile yapılan sınıflandırmadan yüksek doğruluk değeri elde ettiği görülmüştür. Ayrıca HHD imgelerinden ve doğrudan sinyalin kendisinden çıkartılan özneliklerin sınıflandırılması sonucu elde edilen başarı farkı (%9,28), HHD yönteminin el hareketi sınıflandırmadaki üstünlüğünü ortaya çıkartmaktadır. Hareketler arasında sınıflandırma başarımı kıyaslandığında ise yumruk ve fleksiyon hareketlerinin diğer hareketlere göre daha başarılı sonuçlar verdiği tespit edilmiştir. Önerilen yöntemde, yedi el hareketi için SC ve FCM için F1-skor değerleri sırasıyla %94,38 ve %92,49 olarak elde edilmiştir. Sonuç olarak, önerilen çalışma ile literatürdeki FL yöntemlerine göre daha kapsamlı bir sınıflandırma yaklaşımı ve değerlendirmesi sunulmuştur. Önerilen yöntemin karmaşık el hareketlerinin sınıflandırılmasında etkili bir şekilde kullanılabileceği görülmüştür. Sinirsel-bulanık tabanlı yöntemlerin, invaziv olmayan sEMG tabanlı biyolojik sistemler için iyi bir sınıflandırma kabiliyeti sağlayabileceği ve alternatif bir yaklaşım olabileceği gösterilmiştir. Gelecek çalışmalar, EMG tabanlı el hareketi sınıflandırmada iyi çözünürlüklü ve çok kanallı analiz yöntemleri ile elde edilecek TF temsilleri ile zaman ve frekans uzaylarından ayrı ayrı çıkartılacak farklı özneliklerinin karşılaştırmalı analizine odaklanacaktır. Ayrıca, uzun kısa süreli bellek (long short-term memory/LSTM) yaklaşımlarına dayalı yöntemlerin analizi ile el hareketi sınıflandırma performansını artırmak ve gerçek zamanlı sistemler için tepki süresini düşürmek gelecek çalışmalar için cesaret verici bir yönelim olacaktır.

## Teşekkür (Acknowledgement)

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 120E512 numaralı proje ve İzmir Katip Çelebi Üniversitesi Bilimsel Araştırma Projeleri (BAP) Koordinasyon Birimi tarafından 2021-ÖDL-MÜMF-0004 ve 2022-GAP-MÜMF-0001 numaralı hibeler kapsamında desteklenmiştir.

## Kaynaklar (References)

1. Balbinot A., Favieiro G., A Neuro-Fuzzy System for Characterization of Arm Movements, *Sensors*, 13 (2), 2613–2630, 2013.
2. Fajardo J.M., Gomez O., Prieto F., EMG hand gesture classification using handcrafted and deep features, *Biomed. Signal Process. Control*, 63 (March 2020), 102210, 2021.
3. Zahak M., Signal Acquisition Using Surface EMG and Circuit Design Considerations for Robotic Prosthesis, *Computational Intelligence in Electromyography Analysis - A Perspective on Current Applications and Future Challenges*, Naik G.R., IntechOpen, London, United Kingdom: IntechOpen, 2012.
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. Ozdemir M.A., Kisa D.H., Guren O., Onan A., Akan A., EMG based Hand Gesture Recognition using Deep Learning, *2020 Med. Technol. Congr.*, 1–4, 2020.
6. Arozi M., Ariyanto M., Kristianto A., Munadi, Setiawan J.D., EMG Signal Processing of Myo Armband Sensor for Prosthetic Hand Input using RMS and ANFIS, *2020 7th Int. Conf. Inf. Technol. Comput. Electr. Eng.*, 36–40, 2020.
7. De la Cruz-Sánchez B.A., Arias-Montiel M., Lugo-González E., EMG-controlled hand exoskeleton for assisted bilateral rehabilitation, *Biocybern. Biomed. Eng.*, 42 (2), 596–614, 2022.
8. Kisa D.H., Ozdemir M.A., Guren O., Akan A., EMG based Hand Gesture Classification using Empirical Mode Decomposition Time-Series and Deep Learning, *2020 Med. Technol. Congr.*, 1–4, 2020.
9. Ozdemir M.A., Kisa D.H., Guren O., Akan A., Hand gesture classification using time–frequency images and transfer learning based on CNN, *Biomed. Signal Process. Control*, 77 103787, 2022.
10. Lee K.H., Min J.Y., Byun S., Electromyogram-Based Classification of Hand and Finger Gestures Using Artificial Neural Networks, *Sensors*, 22 (1), 225, 2021.
11. Narayan Y., Hb vsEMG signal classification with time domain and Frequency domain features using LDA and ANN classifier, *Mater. Today Proc.*, 37 (Part 2), 3226–3230, 2021.
12. Zhai X., Jelfs B., Chan R.H.M., Tin C., Short latency hand movement classification based on surface EMG spectrogram with PCA, *2016 38th Annu. Int. Conf. IEEE Eng. Med. Biol. Soc.*, 327–330, 2016.
13. Phinyomark A., Phukpattaranont P., Limsakul C., Feature reduction and selection for EMG signal classification, *Expert Syst. Appl.*, 39 (8), 7420–7431, 2012.
14. Srhoj-Egkher V., Cifrek M., Medved V., The application of Hilbert-Huang transform in the analysis of muscle fatigue during cyclic dynamic contractions., *Med. Biol. Eng. Comput.*, 49 (6), 659–69, 2011.
15. Revilla L.M., Delis A.L., Olaya A.F.R., Evaluation of the Hilbert-Huang Transform for myoelectric pattern classification: Towards a method to detect movement intention, *2013 Pan Am. Heal. Care Exch.*, 1–6, 2013.
16. Huang N.E., Shen Z., Long S.R., Wu M.C., Shih H.H., Zheng Q., Yen N., Tung C.C., Liu H.H., Mathematical S.P., Sciences E., The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis, *Proc. Math. Phys. Eng. Sci.*, 454 (1971), 903–995, 1998.
17. Lin C.-F., Zhu J.-D., Hilbert–Huang transformation-based time-frequency analysis methods in biomedical signal applications, *Proc. Inst. Mech. Eng. Part H J. Eng. Med.*, 226 (3), 208–216, 2012.
18. Wahid M.F., Tafreshi R., Al-Sowaidi M., Langari R., Subject-independent hand gesture recognition using normalization and machine learning algorithms, *J. Comput. Sci.*, 27 69–76, 2018.
19. Gadekallu T.R., Srivastava G., Liyanage M., M. I., Chowdhary C.L., Koppu S., Maddikunta P.K.R., Hand gesture recognition based on a Harris Hawks optimized Convolution Neural Network, *Comput. Electr. Eng.*, 100 107836, 2022.
20. Jahani Fariman H., Ahmad S.A., Hamiruce Marhaban M., Ali Jan Ghasab M., Chappell P.H., Simple and Computationally Efficient Movement Classification Approach for EMG-controlled Prosthetic Hand: ANFIS vs. Artificial Neural Network, *Intell. Autom. Soft Comput.*, 21 (4), 559–573, 2015.
21. Karlik B., Tokhi M.O., Alci M., A fuzzy clustering neural network architecture for multifunction upper-limb prosthesis, *IEEE Trans. Biomed. Eng.*, 50 (11), 1255–1261, 2003.

22. Subasi A., Classification of EMG signals using combined features and soft computing techniques, *Appl. Soft Comput.*, 12 (8), 2188–2198, 2012.
23. Khezri M., Jahed M., Real-time intelligent pattern recognition algorithm for surface EMG signals, *Biomed. Eng. Online*, 6 (1), 45, 2007.
24. Ouyang G., Zhu X., Ju Z., Liu H., Dynamical Characteristics of Surface EMG Signals of Hand Grasps via Recurrence Plot, *IEEE J. Biomed. Heal. Informatics*, 18 (1), 257–265, 2014.
25. Khezri M., Jahed M., A Neuro-Fuzzy Inference System for sEMG-Based Identification of Hand Motion Commands, *IEEE Trans. Ind. Electron.*, 58 (5), 1952–1960, 2011.
26. Kaiser M.S., Chowdhury Z.I., Mamun S. Al, Hussain A., Mahmud M., A Neuro-Fuzzy Control System Based on Feature Extraction of Surface Electromyogram Signal for Solar-Powered Wheelchair, *Cognit. Comput.*, 8 (5), 946–954, 2016.
27. Ulkir O., Gokmen G., Kaplanoglu E., Emg Signal Classification Using Fuzzy Logic, *Balk. J. Electr. Comput. Eng.*, 5 (2), 97–101, 2017.
28. Caesarendra W., Tjahjowidodo T., Nico Y., Wahyudati S., Nurhasanah L., EMG finger movement classification based on ANFIS, *J. Phys. Conf. Ser.*, 1007 (1), 012005, 2018.
29. Andrade A.O., Nasuto S., Kyberd P., Sweeney-Reed C.M., Van Kanijn F.R., EMG signal filtering based on Empirical Mode Decomposition, *Biomed. Signal Process. Control*, 1 (1), 44–55, 2006.
30. Lingling Chen, Peng Yang, Linan Zu, Xin Guo, Movement recognition by electromyography signal for transfemoral prosthesis control, 2009 4th IEEE Conf. Ind. Electron. Appl., 1127–1132, 2009.
31. 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.
32. Karlsson S., Yu J., Akay M., Time-frequency analysis of myoelectric signals during dynamic contractions: A comparative study, *IEEE Trans. Biomed. Eng.*, 47 (2), 228–238, 2000.
33. Xie H., Wang Z., Mean frequency derived via Hilbert-Huang transform with application to fatigue EMG signal analysis, *Comput. Methods Programs Biomed.*, 82 (2), 114–120, 2006.
34. Huang N.E., Introduction to the Hilbert–Huang Transform and its related mathematical problems, *Hilbert–Huang Transform and Its Applications*, Shen S.S., World Scientific, 1-26, 2014.
35. Zahra A., Kanwal N., ur Rehman N., Ehsan S., McDonald-Maier K.D., Seizure detection from EEG signals using Multivariate Empirical Mode Decomposition, *Comput. Biol. Med.*, 88 132–141, 2017.
36. Peng Z.K., Tse P.W., Chu F.L., A comparison study of improved Hilbert–Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing, *Mech. Syst. Signal Process.*, 19 (5), 974–988, 2005.
37. Komaty A., Boudraa A.-O., Augier B., Dare-Emzivat D., EMD-Based Filtering Using Similarity Measure Between Probability Density Functions of IMFs, *IEEE Trans. Instrum. Meas.*, 63 (1), 27–34, 2014.
38. Andrade A., Kyberd P., Nasuto S., The application of the Hilbert spectrum to the analysis of electromyographic signals, *Inf. Sci. (Ny)*, 178 (9), 2176–2193, 2008.
39. Hafizah W.M., Supriyanto E., Yunus J., Feature Extraction of Kidney Ultrasound Images Based on Intensity Histogram and Gray Level Co-occurrence Matrix, 2012 Sixth Asia Model. Symp., 115–120, 2012.
40. Ozdemir M.A., Ozdemir G.D., Guren O., Classification of COVID-19 electrocardiograms by using hexaxial feature mapping and deep learning, *BMC Med. Inform. Decis. Mak.*, 21 (1), 170, 2021.
41. Vasantha M., Bharathi D.V.S., Dhamodharan R., Medical Image Feature, Extraction, Selection And Classification, *Int. J. Eng. Sci. Technol.*, 2 (6), 2071–2076, 2010.
42. Jia G., Lam H.-K., Ma S., Yang Z., Xu Y., Xiao B., Classification of Electromyographic Hand Gesture Signals Using Modified Fuzzy C-Means Clustering and Two-Step Machine Learning Approach, *IEEE Trans. Neural Syst. Rehabil. Eng.*, 28 (6), 1428–1435, 2020.
43. Zadeh L.A., Fuzzy Sets, *Inf. Control*, 8 338–353, 1965.
44. Jang J.-S.R., ANFIS: adaptive-network-based fuzzy inference system, *IEEE Trans. Syst. Man. Cybern.*, 23 (3), 665–685, 1993.
45. Ozdemir M.A., Kısa D.H., Guren O., Akan A., Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures, *Data Br.*, 41 107921, 2022.
46. Peldek S., Becerikli Y., Recognition of human action in motion detected images with GMACA, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 2018 (18–2), 1025–1044, 2018.
47. Khushaba R.N., Kodagoda S., Takruri M., Dissanayake G., Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals, *Expert Syst. Appl.*, 39 (12), 10731–10738, 2012.
48. Palmer H., Cohen K., Genetic Fuzzy Hand Gesture Classifier, Explainable AI and Other Applications of Fuzzy Techniques, Rayz, j., Raskin, V., Dick, S., and Kreinovich, V., Springer, Cham, 332-342, 2022.
49. Eker A.F., Çil A.Y., Çil I., Capacitated vehicle routing problem with simulated annealing algorithm with initial solution improved with fuzzy c-means algorithm, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (2), 783–798, 2022.