

EMG Sinyalleri Kullanılarak GoogLeNet ve Çok Seviyeli DPD ile El Tutma Hareketlerinin Sınıflandırılması

Muhammed Buğracan ÖZKÜÇÜK¹, Ömer Faruk ALÇİN^{2*}, Muhsin Tunay GENÇOĞLU³

¹ Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

² Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

³ Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

¹ bugracan.ozkucuk@ozal.edu.tr, ^{2*} omer.alcin@ozal.edu.tr, ³ mtgencoglu@firat.edu.tr

(Geliş/Received: 04/05/2021;

Kabul/Accepted: 01/01/2022)

Öz: Elektromiyografi (EMG) elektriksel aktiviteyi ölçmek için kullanılan bir yöntemdir. Bu yöntem günümüzde hastalık tespitinde kullanılmasıyla yaygınlaşmış olsa da robotik, protez kontrolü, video oyunları gibi popüler alanlarda yer edinmiştir. Bu çalışmada altı temel el hareketinin EMG sinyalleri kullanılarak sınıflandırılması amaçlanmıştır. Bu amaç doğrultusunda transfer öğrenme yaklaşımı kullanılmıştır. EMG sinyalleri çok seviyeli dalgacık paket dönüşümü (DPD) ile zaman-frekans (ZF) görüntülerine çevrilmiştir. Bütün kanallara ait ZF görüntülerinin %80'i birleştirilerek GoogLeNet mimarisini eğitmek için kullanılmıştır. Hareket tanımadaki başarıyı artırmak için GoogLeNet'ten elde edilen derin öznetelikler Destek Vektör Makinesi (DVM) ile sınıflandırılmıştır. Önerilen yöntem altı temel el hareketini tanımadaki %98.833 doğruluk oranına sahiptir. Önerilen yöntem aynı veri setini kullanan çalışmalar ile karşılaştırılmıştır. Yapılan karşılaştırmalar sonucunda önerilen yöntemin mevcut yöntemlerden %0.8 daha yüksek performans sergilediği görülmüştür. Deneysel çalışmalar önerilen yaklaşımın EMG ile hareket tanımadaki kullanılabilecek etkin ve verimli bir yöntem olduğunu göstermiştir.

Anahtar kelimeler: EMG, Transfer Öğrenme, GoogLeNet, DVM, Çok Seviyeli DPD.

Classification of Hand Holding Gestures with GoogLeNet and Multi-Level WPT using EMG Signals

Abstract: EMG is a method used to measure electrical activity. Although this method has become widespread with its use in disease detection today, it has gained a place in popular areas such as robotics, prosthesis control, video games. This study, it is aimed to classify six basic hand movements using EMG signals. For this purpose, the transfer learning approach was used. EMG signals have been converted into Time-Frequency (TF) images with multi-level wavelet packet transformation (WPT). %80 of the ZF images of all channels were combined and used to train the GoogLeNet architecture. In order to increase the performance in motion recognition, deep features obtained from GoogLeNet were classified by Support Vector Machine (SVM). The proposed method has 98.833% accuracy in recognizing six basic hand gestures. The proposed method was compared with studies using the same data set. As a result of the comparisons, it was found that the proposed method performed 0.8% higher than the existing studies. Experimental studies have shown that the proposed approach is an effective and efficient method that can be used in motion recognition with EMG.

Key words: EMG, Transfer Learning, GoogLeNet, SVM, Multi Level WPT.

1. Giriş

İnsanın vücut ağırlığını taşımasını sağlayan kasların en temel elemanı motor birimidir. Motor birimlerinin bir araya gelmesiyle kas lifleri oluşur. Bir motor birimi uyarıldığında, 20-2000 μ V genlikli dalga şekli, 6~30 Hz deşarj frekansı oluşurken bu durum 3-5 ms aralığında gerçekleşmektedir. Böylelikle kas liflerinin kasılması daha yüksek genlikli ve yüksek frekanslı bir potansiyel sinyalin oluşmasına sebebiyet verir [1]. Bu elektriksel aktivite elektromiyogram (EMG) yöntemi ile ölçülebilmekte, hastalık teşhisinde uzmanlara yardımcı olabilmektedir.

EMG sinyalleri, hastalık tespitlerinin yanı sıra güncel olarak robotik, akıllı sistemler, video oyunları ve işaret dili tanıma gibi popüler olan sistemlerde de sıklıkla kullanılmaktadır. Bu nedenle EMG sinyallerinin sınıflandırılması önemli bir yer tutmaktadır. Literatürde, çeşitli örneklerle ve farklı yaklaşımlarla, EMG

* Sorumlu yazar: omer.alcin@ozal.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-1466-2502, ² 0000-0002-2917-3736, ³ 0000-0002-1774-1986

sinyallerinin sınıflandırılmasına çalışılmıştır. Subası vd., EMG sinyallerinden Nöromusküler kas hastalığını belirlemeyi hedeflemişlerdir [2]. Bu hedef doğrultusunda ilk olarak EMG sinyallerinden öznitelik çıkarmak amacıyla bu sinyallere ayırık dalgacık dönüşümü (ADD) uygulanmış, dalgacık katsayılarının dağılımını belirtmek için ADD'nin istatistiksel değerleri hesaplamıştır. Kas ve sinir hastalıkları gibi nöromusküler hastalıkların tespiti amacıyla yapılan bu durumlar torbalama topluluk (TT) sınıflandırıcısına giriş verisi olarak verilmiş ve sonuçlar gözlemlenmiştir. Sapsanis vd., EMG sinyalleri için bir el hareketini tanımlama yöntemi üzerinde durmuşlardır [3]. Önerilen yaklaşımın test edilmesi için benzer yaşlarda beş sağlıklı denek seçilmiş ve bunlardan altı temel el hareketi, iki kanallı yüzey EMG sinyalleriyle toplanmıştır. Öncelikle, yüzey EMG sinyallerini içsel mod fonksiyonlarına (IMF) ayırmak için deneysel mod ayrıştırma (DMA) kullanılmış ve daha sonra entegre EMG (EEMG), uzunluk, Willison genliği, varyans, sıfır geçiş, eğim işareti değişiklikleri, çarpıklık ve basıklık dahil olmak üzere sekiz özelliği ortaya çıkarmak için çalışılmıştır. Son olarak, EMG sinyallerini sınıflandırmak için basit bir doğrusal sınıflandırıcı kullanılmıştır. Bu çalışmadan farklı olarak, sekiz özelliğe ilaveten EMG sinyallerinden medyan ve standart sapma olmak üzere iki yeni özellik eklenilerek yeni bir çalışma Sapsanis vd., tarafından ortaya konmuştur [4]. Boyutsallığı azaltmak amacıyla temel bileşen analizi (TBA) ve Relief özellik seçme algoritması kullanılmış olup yaklaşımları altı kişiden kaydedilen EMG sinyalleri üzerinde test edilmiştir. Kakoty ve Hazarika, EMG sinyalleri için elle kavrayan bir sınıflandırma yöntemiyle yaklaşmışlardır [5]. Altı kavrayışa karşılık gelen iki kanallı EMG sinyalleri 40 deneysel denekten elde edilmiştir. EMG sinyallerinin özellikleri, ayırık dalgacık dönüşümü katsayılarının temel bileşen analizi (TBA) kullanılarak çıkarılmıştır. El kavrayışlarının sınıflandırılması, radyal temel fonksiyon (RTF) çekirdek destek vektör makinesi (DVM) ile gerçekleştirilmiştir. Nazemi ve Maleki, el hareketlerini ve jestleri belirlemek için çok katmanlı algılayıcı (ÇKA), doğrusal diskriminant analizi (DDA) ve en küçük kareler destek vektör makinesinin (EKK-DVM) başarımları üzerinde durmuşlar ve karşılaştırılmasını yapmışlardır [6]. Başarım değerlendirmesi 27 denegin 52 el, parmak ve bilek hareketleri üzerinde gerçekleştirilmiştir. Öznitelik çıkarımı için kök ortalama kare, dalga şekli uzunluğu, ortalama mutlak değer, integral mutlak değer, konkordans korelasyonu, enerji ve iki enerji oranı yöntemi gibi yedi zamansal özellik kullanılmıştır. Deneysel sonuçlar, ÇKA'nın el hareketlerini tanıma başarısı açısından DDA ve EKK-DVM'den daha iyi olduğunu göstermektedir. Nishad vd., ayarlanabilir Q dalgacık dönüşümü (QDD) tabanlı filtre bankası (QDD-FB) kullanılarak temel bir el hareketi sınıflandırma yaklaşımı ile çözüme odaklanmışlardır [7]. İlk olarak, QDD-FB, EMG sinyallerinin çapraz kovaryansını belirlemek için kullanılmış ve ardından özellikleri çıkarmak için Kraskov entropisi kullanılmıştır. Son olarak, önerilen yaklaşımın performansını incelemek için bir k-NN sınıflandırıcısı kullanılmıştır. Belkhou vd., miyopati ve normal EMG sinyallerinin sınıflandırılmasını hedeflemişlerdir [8]. Bu hedef doğrultusunda EMG sinyallerine sürekli dalgacık dönüşümü ile dört istatistiksel öznitelik belirlenmiştir. Sinyallerin sınıflandırılmasını belirlemek için hem k-en yakın komşuluk hem de DVM sınıflandırıcısı kullanılmıştır. Yapılan çalışmalar sonucunda, KEYK sınıflandırıcısının başarım oranının DVM sınıflandırıcıya yakın olduğu sonucuna varılmıştır. Benazzouz vd., miyopati, ALS ve normal bireylere ait olan EMG sinyallerinin sınıflandırılmasını hedeflemişlerdir [9]. EMG sinyallerine ilk olarak ADD ve güç spektral yoğunluğu yöntemleri uygulanarak sinyallere ait öznitelik belirlenmiştir. Özniteliklerden en etkin olanı belirlemek için Relief algoritması kullanılmıştır. Belirlenen yeni öznitelikler RO ve KEYK sınıflandırıcılarına giriş verisi olarak verilmiştir. Babita vd., kısmen engellilerin hayatını kolaylaştırmak için EMG sinyallerinin zaman alanı ve zaman ölçeği özelliklerini DVM ile sınıflandırmışlardır [10]. Çalışmada, 18-30 yaş arası 8 katılımcıdan elde edilen 303 EMG verisi kullanılarak dalgacık paket dönüşüm (DPD) yöntemi ile öznitelik çıkarımı gerçekleştirilmiştir. Arozi vd., EMG sinyallerinde hareket tespitini hedeflemişlerdir [11]. Bu hedefle alınan 8 farklı harekete ait EMG sinyallerine ADD uygulanmış ve buradan gelen katsayılara bazı istatistiksel yöntemler uygulanarak öznitelik belirlenmiştir. Belirlenen bu öznitelikler yapay sinir ağı (YSA) ile sınıflandırılmıştır.


Bu çalışmada EMG sinyallerinden hareket sınıflama için derin öğrenme yaklaşımı düşünülmüştür. Bu amaçla bu çalışmada Sapsanis EMG veri seti [12] kullanılmıştır. Derin öğrenmede, girdi sayısının hedeflenen veri setinde az olduğu durumlarda, transfer öğrenme yaklaşımı kullanılmaktadır. Transfer öğrenmeyi gerçekleştirmek için GoogLeNet ön-eğitilmiş mimarisinden yararlanılmıştır. EMG sinyalleri çok seviyeli DPD yöntemi ile Zaman-Frekans domeni görüntülerine dönüştürülmüştür. Ardından ZF görüntüleri, GoogLeNet'e giriş olarak uygulanmıştır. Hareket tanımadaki başarımları artırmak için GoogLeNet'in tam bağlı katmanından elde edilen derin öznitelikler DVM ile sınıflandırılmıştır. Ayrıca, bu çalışmada; veri seti, GoogLeNet, DVM sınıflandırıcısı, çok seviyeli dalgacık paket dönüşümü ve performans ölçütleri tanıtılmıştır. Deneysel çalışma ayrıntılı bir şekilde anlatılmış ve elde edilen sonuçlar tartışılmıştır.

2. Materyal ve Metot

Bu bölümde veri seti, GoogLeNet, DVM sınıflandırıcısı, çok seviyeli dalgacık paket dönüşümü ve performans ölçütleri yer almaktadır.

2.1. Veri Seti

EMG veri seti altı temel el hareketi varsayılarak, üçü kadın, ikisi erkek olmak üzere beş katılımcı ile oluşturulmuştur. Her bir hareket için üç kanallı 100 tekrar ile EMG sinyalleri kaydedilmiştir. EMG sinyalleri girişimleri önlemek için 50 Hz çentik ve 15-500 Hz bant geçiren filtrelenmiştir [12]. Şekil 1'de, EMG sinyallerinin bir örneği verilmiştir. EMG veri seti, 2500 örnek uzunluğunda 600 sinyalden oluşmaktadır.



Şekil 1. EMG sinyal örneği

2.2. GoogLeNet

GoogLeNet [13] içeriğinde bulunan başlangıç modüllerinden dolayı karmaşık bir yapıdır. Bu yapı ana hatlarıyla, ardışık bir durum olan konvolüsyon ve havuzlama katmanlarını üst üste istiflemekten uzaklaşan ilk CNN yapılarından birisidir. Katmanların hepsini yığmaktır ve çok sayıda filtre eklemek, hesaplama ve bellek maliyeti getireceğinden bu model bellek ve güç kullanımı üzerinde önemli bir etkiye sahiptir. GoogLeNet'te bu durumla başa çıkmak için paralel olarak birbirine bağlı olan modüller Şekil 2.a'daki gibi kullanılmıştır. Başlangıç modülü, parametrelerin ölçeğini ve model karmaşıklığını sınırlandırmaya yardımcı olan küçük boyutlu (1×1 , 3×3 ve 5×5 vb.) birkaç evrilmiş çekirdekte oluşmaktadır. Buradaki problem işlem karmaşası, çıkış boyutunun büyüklüğü ve parametre sayısının paralel işlemlerden dolayı oldukça büyümesidir. Bu problemi çözmek için şekil 2.b'deki gibi 1×1 evrilmiş çekirdek katmanı diğer evrilmiş katmanların öncesine eklenerek boyut azaltma işlemi gerçekleştirilmektedir. GoogLeNet'te mimariyi oluşturmak için kullanılan 9 başlangıç modülü ve 100'den fazla katman vardır.

2.3. DVM Sınıflandırıcılar

Destek Vektör Makineleri genellikle büyük veri sınıflandırma problemlerini çözmeye yardımcı olabilecek klasik makine öğrenme tekniklerinden biri olup Vapnik tarafından ortaya atılmış bir öğrenme yöntemidir[14]. Bu öğrenme yöntemi eğitim aşamasındaki verilerin hangi sınıfa ait olduğu belli olan denetimli öğrenme kapsamına girer. Destek vektör makinesi doğrusal olan veya doğrusal olmayan modellere ayrılabilir.

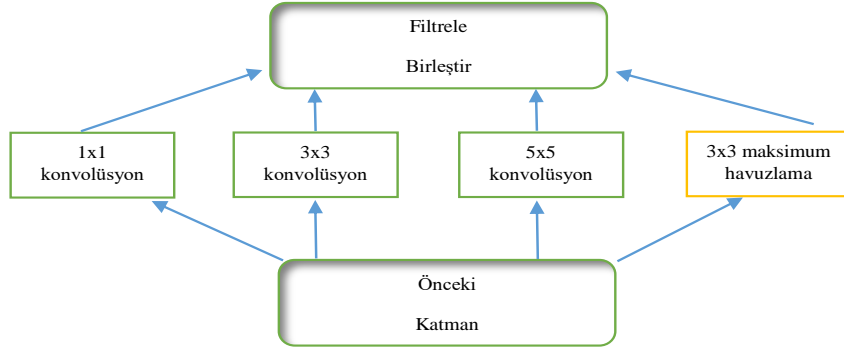
Veri alanı, orijinal alandaki sınıfları ayırmak için doğrusal olarak bölünebilirse yani sırasıyla veri alanının bir yanıt kümesine eşlenmesi ve veri alanının bölünmesi adımları gerçekleşirse, buna doğrusal destek vektör makinesi denir. Denklem 1'de olduğu gibi basitçe ifade edilir.

$$y = wx' + z$$

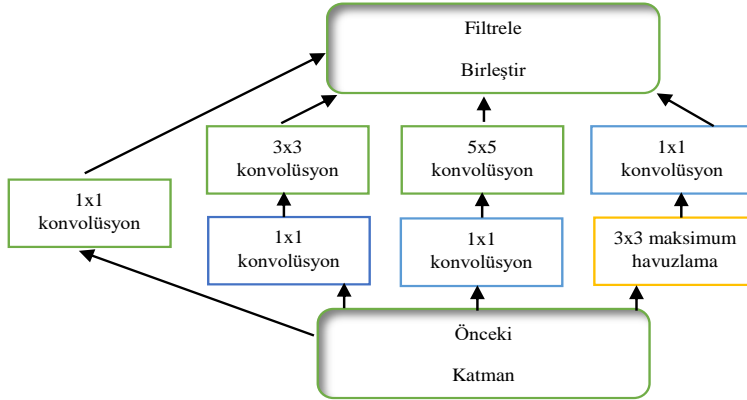
(1)

Veri alanı doğrusal olarak bölünemiyorsa, veri alanının sınıfları ayırmak için doğrusal olarak bölünebileceği özellik alanı olarak adlandırılan bir boşluğa dönüştürülebiliyorsa buna doğrusal olmayan destek vektör makinesi denir. Bu durumda sırasıyla bir çekirdek işlevi kullanılarak veri alanının bir özellik uzayına eşlenmesi, özellik alanının yanıt kümesine eşlenmesi ve ardından veri alanının bölünmesi adımları gerçekleşir. Denklem 2’de olduğu gibi basitçe ifade edilir [15].

$$y = w\phi x' + z \quad (2)$$



(a) Naif versiyon başlangıç modülü



(b) Boyut azaltma özelliğine sahip başlangıç modülü

Şekil 2. Başlangıç modülü

2.4. Çok Seviyeli Dalgacık Paket Dönüşümü

Dalgacık Paket Dönüşümü, Ayrık Dalgacık Dönüşümü yönteminin genişletilip, geliştirilmesi ile gerçekleşmektedir. Ayrık dalgacık dönüşümünde her seviye için sinyalin sadece yaklaşım kısımlarına ayrışım uygulanmaktadır. Dalgacık paket dönüşümünde ise sinyalin yaklaşım kısmının yanı sıra ayrıntılı kısımlarına da ayrışım uygulanmaktadır [16]. DPD, sinyal işlemeye, özellikle durağan olmayan sinyallere uygundur. Çünkü aynı frekans bant genişlikleri, yüksek ve düşük frekanslardan bağımsız olarak iyi çözünürlük sağlayabilir. DPD, dalgacık dönüşümünün bir genellemesidir ve dalgacık paket işlevi de bir zaman-frekans işlevidir [17]. Dalgacık paket dönüşümünün parametrelere göre ifadesi Denklem 3’teki gibi yazılabilir.

$$W_{b,c}^a(t) = 2^{\frac{b}{2}} W^a(2^b t - c) \quad (3)$$

Burada b ve c tam sayıları indeks ölçeği ve çeviri işlemleri, a indisi ise bir işlem modülasyon parametresi veya salınım parametresidir.

Denklem 4 ve Denklem 5 ölçekleme ve ana dalgacık fonksiyonlarıdır.

$$W_{0,0}^0(t) = \theta(t) \quad (4)$$

$$W_{0,0}^1(t) = \varphi(t) \quad (5)$$

Burada $a=2,3, \dots$ olduğunda Denklem 6 ve Denklem 7 ile tanımlanabilir.

$$W_{0,0}^{2a}(t) = \sqrt{2} \sum_c h(c) W_{1,c}^a(2t - c) \quad (6)$$

$$W_{0,0}^{2a+1}(t) = \sqrt{2} \sum_c g(c) W_{1,c}^a(2t - c) \quad (7)$$

Burada $h(c)$ ve $g(c)$ önceden tanımlanmış ölçekleme fonksiyonu ve ana dalgacık fonksiyonu ile ilişkili kareleme ayna filtresidir. DPD açılan seviyesi b ile gösterilirse $k=2^{b+1}-1$ katsayısı elde edilmektedir. Her bir katsayının entropisi sinyali temsil edebilecek niteliktedir. Böylece $b=7$ alınırsa bir sinyali temsil edebilen 255 öznitelik elde edilmektedir.

Bu çalışmada çok seviyeli dalgacık paket dönüşümü kullanılmıştır. Çok seviyeli yaklaşım sinyalini bütünüyle kullanmak yerine pencereleme ile sinyalin bir parçasına DPD uygulanması şeklinde tanımlanabilir. Bu yapıya göre herhangi bir sinyal belirlenen pencere genişliğinde artırım aralıkları ile taranmaktadır. Çok seviyeli yaklaşım ile bir sinyalden denklem 8'de belirtilen n sayıda alt sinyal elde edilir [18-19].

$$n = \frac{L-W}{S} + 1 \quad (8)$$

Burada n elde edilen alt sinyal, L sinyal uzunluğu, W pencere genişliği ve S ise pencere artım aralığını sembolize etmektedir. Çalışmada pencere genişliği $W=256$, artırım aralığı $S=32$ ve $j=7$ deneysel yolla belirlenmiştir. EMG sinyal uzunluğu ise $L=2500$ 'dir.

2.5. Performans Ölçütleri

Bu çalışmada önerilen yöntemi değerlendirmek için doğruluk (Doğ), duyarlılık (Duy), özgüllük (Özg), hassaslık (Has) metrikleri ve alıcı çalışma karakteristiği (ROC) eğrisi kullanılmıştır. Doğruluk, Duyarlılık, Özgüllük ve Hassaslık metrikleri Denklem 9-12'de ifade edilmiştir.

$$Doğ = \frac{A+B}{A+B+C+D} \times 100 \quad (9)$$

$$Duy = \frac{A}{A+D} \times 100 \quad (10)$$

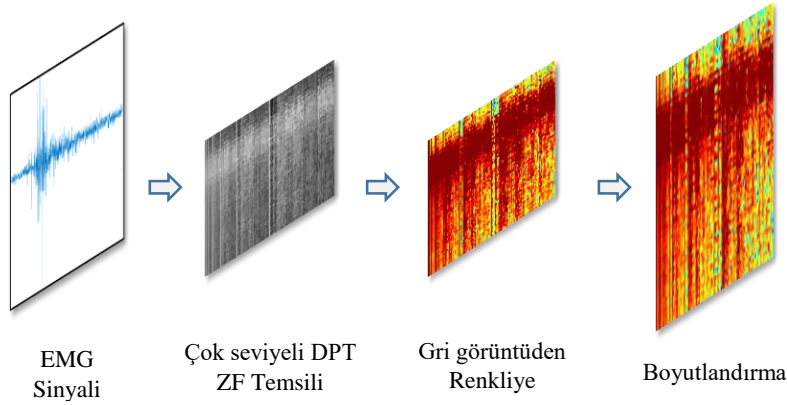
$$Özg = \frac{B}{B+C} \times 100 \quad (11)$$

$$Has = \frac{A}{A+C} \times 100 \quad (12)$$

Burada, A sınıflandırıcının gerçek pozitif sayılarını, B sınıflandırıcının gerçek negatif sayılarını, C sınıflandırıcının gerçek olmayan pozitif sayılarını ve D sınıflandırıcının gerçek olmayan negatif sayılarını sembolize etmektedir. ROC eğrisi, Se sınıflandırıcısı ile yanlış pozitif oranları arasındaki ilişkiyi verir [20-21].

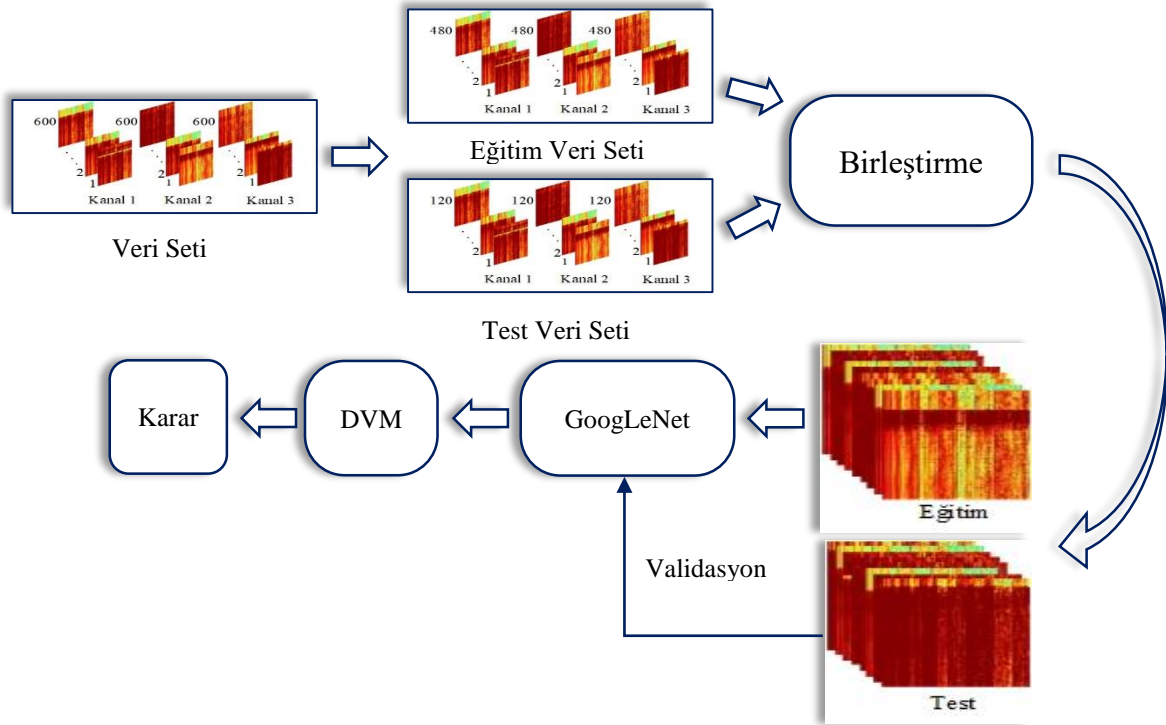
3. Deneysel Çalışma ve Sonuçlar

Bu çalışmada EMG sinyalleri ile hareket belirlenmesi yapılmıştır. Önerilen yaklaşımda derin öğrenme kullanılmıştır. EMG kayıtlarının azlığı sebebiyle transfer öğrenme kullanılmıştır. Bulanık dalgacık dönüşümü kullanılarak EMG sinyallerinin iki boyutlu zaman-frekans görüntüleri elde edilmiştir. Bir EMG sinyali çok seviyeli DPD ile $n \times k$ boyutunda bir görüntüye çevrilmektedir. Bölüm 2.4'te verilen parametreler dikkate alındığında 71×255 boyutunda gri seviye görüntü elde edilmiştir. Ardından GoogLeNet giriş görüntü büyüklüğüne uygun olması için $224 \times 224 \times 3$ boyutuna dönüştürülmüştür. Bir EMG sinyali için ZF görüntü elde etme işlemi Şekil 3'te gösterilmiştir.



Şekil 3. Bir EMG sinyalinden ZF görüntü elde edilmesi

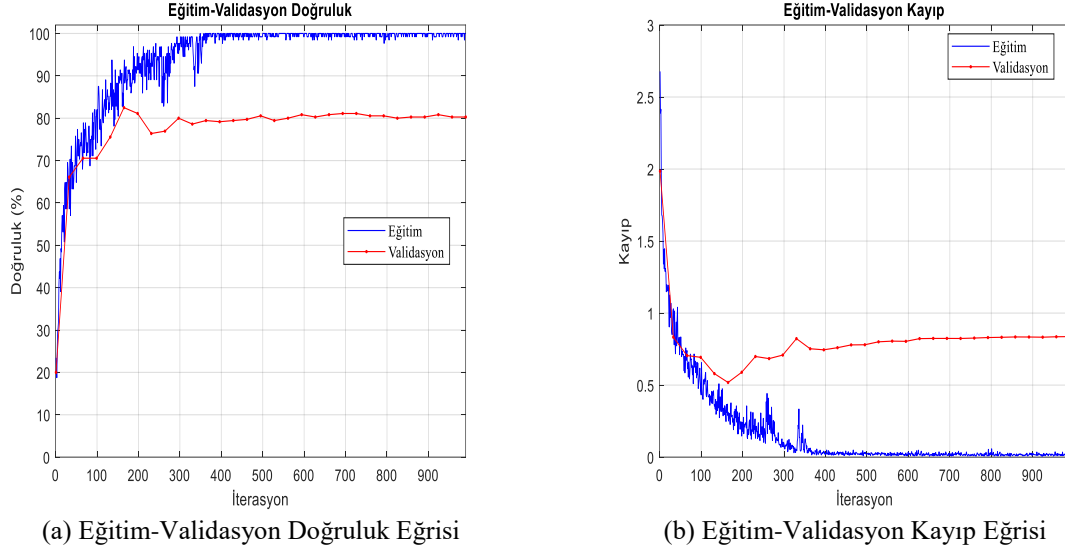
Şekil 3'te görüldüğü gibi çok seviyeli DPT ile bir EMG sinyalinin ZF görüntüsü elde edilmiştir. Ardından gri seviye ZF ölçeklendirilip RGB görüntüye çevrilmiştir. RGB ZF görüntüsü 224×224 olacak şekilde boyutlandırılmıştır. Veri seti daha önce bahsedildiği gibi [3-4, 12] üç kanaldan oluşmaktadır. Eğitim aşamasında veri setinin rastgele seçilen %80'i kullanılırken kalan kısım ise ağıın doğrulamasında ve yöntemin test edilmesinde kullanılmıştır. EMG sinyalinden ZF görüntüleri oluşturulurken ve veri seti bölünürken kanallar birbirine karıştırılmamıştır. Yani aynı kayda ait üç kanal eğitim ya da test kümesinde bulunmaktadır. Eğitim ve doğrulama aşamasında üç kanal birleştirilerek değerlendirilmiştir. Bu yaklaşım Şekil 4'de verilmiştir.



Şekil 4. Önerilen yöntem

Şekil 4'te görüldüğü gibi üç kanal birleştirilerek GoogLeNet modelin daha fazla giriş görüntüsü ile eğitilmesi amaçlanmıştır. GoogLeNet eğitimi sırasında test ZF görüntüleri ile ağıın validasyonu yapılmıştır. GoogLeNet ağı

sgdm optimizasyon ile her iterasyonda 32 adet görüntü ve 0.001 öğrenme oranı ile eğitilmiştir. Eğitim sürecine ait eğriler Şekil 5'te verilmiştir.



Şekil 5. GoogLeNet eğitim eğrileri

Şekil 5.a'da görüldüğü gibi eğitim 300-400 iterasyon arasında %100 doğruluğa ulaşırken, validasyon %80 civarında seyretmiştir. Şekil 5.b'den görüldüğü gibi kayıp yaklaşık 0.83 iken eğitim süreci tamamlanmıştır. Tablo 1'de GoogLeNet ve DVM sınıflandırıcısı üç kanal birleştirilmiş test görüntülerine ait sonuçlar verilmiştir. Yapılan deneylerde gauss çekirdeğinin DVM sınıflandırıcısı için en uygun çekirdek fonksiyonu olduğu belirlenmiştir.

Tablo 1. Sınıflandırma sonuçları (%)

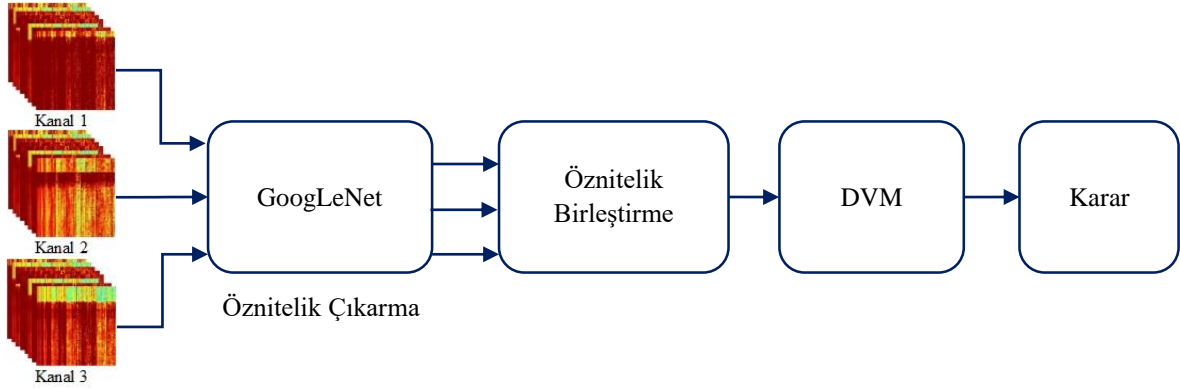
Sınıflandırıcı	Doğ	Duy	Özg	Has
GoogLeNet	81.111	81.111	96.222	81.502
DVM	82.222	82.222	96.444	82.942

Tablo 1'de görüldüğü gibi, DVM sınıflandırıcısı GoogLeNet'ten yaklaşık %1 daha iyi doğrulukla sınıflandırmıştır. Diğer metriklerde de DVM daha yüksek başarımlar değerlerine sahiptir. Her bir kanalın GoogLeNet sınıflandırıcı katmanına ait test sonuçları Tablo 2'de verilmiştir.

Tablo 2. Her bir kanalın sınıflandırma sonuçları (%)

Kanal	Doğ	Duy	Özg	Has
Kanal 1	76.667	76.667	95.333	80.748
Kanal 2	84.167	84.167	96.833	84.664
Kanal 3	80.000	80.000	96.000	82.024

Tablo 2'den görüldüğü gibi, Kanal 2 hareketlerin sınıflandırılmasında diğer kanallardan daha iyi performans göstermiştir. Deneysel çalışma üç kanalın birlikte değerlendirilmesi ile sürdürülmüştür. Bu yaklaşım test başarımlarını artırmak için uygulanmıştır. Her bir kanala ait test görüntüsü bireysel olarak uygulandığında yapılan deneysel çalışmalarda başarımların düşük olduğu gözlenmiştir. Bu deneysel yaklaşım Şekil 6'da gösterilmiştir.



Şekil 6. Önerilen test yaklaşımı

Test aşamasında ise her bir kanala ait derin öznelikler elde edilerek birleştirilmiştir. Derin öznelikler GoogLeNet'in tam bağlı katmanından (fc) elde edilmiştir. Her bir kanal için 600×6 öznelik matrisi ve üç kanal birleştirildiğinde ise 600×18 boyutlu matris elde edilmiştir. Birleştirilen derin öznelikler DVM sınıflandırıcısı ile sınıflandırılmıştır. Sınıflandırma geçerliliği 10-kat çapraz doğrulama ile değerlendirilmiştir. Birleştirilmiş öznelik matrisinin sonuçları Tablo 3'te verilmiştir.

Tablo 3. Birleştirilmiş kanallara ait sınıflandırma sonuçları (%)


Doğ	Duy	Özg	Has
98.833	98.833	99.767	98.836

Tablo 2'deki sonuçlar göz önüne alındığında, önerilen test yaklaşımının yaklaşık %16 doğruluk artışı sağladığı görülmektedir. Bu yaklaşımda her bir hareketin sınıflandırma sonuçları incelenmiş ve bu sonuçlar Tablo 4'te verilmiştir.

Tablo 4. Her sınıfın performans sonuçları (%)

	Doğ	Duy	Özg	Has
Askı	100.000	100.000	100.000	100.000
Avuç	97.000	97.000	99.600	97.980
Düz	97.000	97.000	99.600	97.980
Küresel	100.000	100.000	100.000	100.000
Parmak Ucu	99.000	99.000	99.400	97.059
Silindir	100.000	100.000	100.000	100.000

Tablo 4'te görüldüğü gibi, Askı, Küresel ve Silindir nesne tutma hareketlerinden tam bir ayırım yapılmıştır. Avuç ve Düz nesne tutma hareketleri %97 doğruluk performansı sağlamıştır. Parmak Ucu ile nesne tutma hareketi %99 başarımla belirleyebilmiştir. Analizler Şekil 7'de verilen ROC eğrisi ile desteklenmiştir.



Şekil 7. Önerilen yaklaşıma ait ROC eğrisi

ROC eğrisi incelendiğinde, önerilen Askı, Düz ve Silindir yaklaşım sınıflarının tam eğri altında alana sahip olduğu görülmektedir. Yine Tablo 4’den görüleceği gibi Parmak ucu, Avuç ve Düz sınıflarından daha iyi ayırt edilmiştir. Önerilen yöntemin aynı veri setini kullanan diğer çalışmalar ile karşılaştırılması Tablo 5’te verilmiştir.

Tablo 5. Karşılaştırma sonuçları

Çalışma	Doğ (%)
Sapsanis C. [12]	75.00
Sapsanis ve diğerleri [3]	80.00
Arı ve diğerleri [22]	92.00
Arı ve diğerleri [23]	93.167
Alçin Ö. F. [24]	96.833
Aslan M. [25]	98.00
Önerilen Yöntem	98.833

Tablo 5’te verilen çalışmalar incelenecek olursa, Sapsanis, elin altı temel hareketini belirlemeyi amaç edinmiştir [12]. Bu doğrultuda sınıflandırma başarı oranını arttırmak için temel bileşen analizi ve Relief özellik seçme algoritması kullanılmış, boyutu azaltmak için ise EMD uygulanmıştır. Sapsanis vd., EMG sinyalleri için bir el hareketini tanımlama yöntemi üzerinde durmuşlar ve altı temel el hareketi iki kanallı yüzey EMG sinyalleriyle toplamışlardır [3]. Öncelikle, EMG sinyallerini içsel mod fonksiyonlarına (IMF) ayırmak için deneysel mod ayrıştırma (DMA) kullanılmış ve daha sonra entegre EMG (EEMG), uzunluk, Willison genliği, varyans, sıfır geçiş, eğim işareti değişiklikleri, çarpıklık ve basıklık dahil olmak üzere sekiz özelliği ortaya çıkarmak için çalışılmıştır. Arı vd., altı farklı el hareketi için EMG sinyallerinin sınıflandırılmasını amaçlamışlardır [22]. Bu amaç doğrultusunda EMG sinyallerine kısa zamanlı fourier dönüşümü uygulanıp zaman frekans düzlemine dönüştürülmüştür. Yerel ikili örüntüler ve gri seviye eş-oluşum matrisleri yöntemleri uygulanarak görüntülerden

öznitelik elde edilmiştir. Arı vd., altı el hareketi permütasyon entropi ve bir boyutlu yerel ikili örtüntü yöntemleri kullanılarak öznitelikler çıkarımını sağlamışlardır [23]. Elde edilen öznitelikler destek vektör makinesi ile sınıflandırılmıştır. Alçın, EMG sinyallerini sınıflandırmayı hedeflemiştir [24]. Bu hedef doğrultusunda fraktal eğimden arındırılmış dalgalanma analizi ve örtüşmeyen pencereci kök ortalama karesinden öznitelik çıkarmak için yararlanılmıştır. Elde edilen öznitelikler destek vektör makinesi, karar ağacı, k-En yakın komşu, ve doğrusal diskriminant analizi yöntemleri ile sınıflandırılmıştır. Aslan, temel el hareketlerinin belirlenmesini amaçlamıştır [25]. Bu amaçla dağılım entropisi ve normal kümülatif dağılım fonksiyonu öznitelik çıkarma için kullanılmıştır. Elde edilen öznitelikler destek vektör makinesi ile sınıflandırılmıştır. Tablo 5 incelendiğinde araştırmacıların EMG veri seti için %75 ile %98 arasında başarıya ulaştıkları görülmektedir. Önerilen yöntem literatürdeki yöntemlerden daha yüksek bir doğruluğa sahiptir.

4. Tartışma

EMG sinyallerinin sınıflandırılması, beyin bilgisayar ara yüzü ve protez aygıt kontrolü gibi uygulamalarda öneme sahiptir. Bu çalışmada EMG sinyallerinin sınıflandırılması için derin öğrenme tabanlı bir yaklaşım önerilmiştir. EMG sinyalleri çok seviyeli DPD ile ZF görüntüleri elde edilmiştir. Veri tabanı derin öğrenme için görece az bir sayıya sahip olduğu için eğitim aşamasında veri setinde üç kanal birleştirilmiştir. Böylece derin öğrenme yöntemine daha fazla görüntü girdi olarak sağlanmıştır. GoogLeNet mimarisi ile transfer öğrenme gerçekleştirilmiştir. Eğitilmiş GoogLeNet mimarisi ile her bir kanala ait derin öznitelikler elde edilmiştir. Bu derin öznitelikler birleştirilerek hareket sınıflama doğruluğu %16 artırılmıştır. Önerilen yaklaşımın veri setini kullanan diğer yöntemler ile karşılaştırılması yapılmıştır. Karşılaştırma sonuçları, önerilen yöntemin EMG sınıflamada kullanılabilecek verimli bir yöntem olduğunu göstermektedir. Görüntü sayısı öğrenme için az olduğundan, daha sonraki çalışmalarda, görüntü artırma yöntemleri ile görüntü sayısının çoğaltılması planlanmaktadır.

Kaynaklar

- [1] Şenli K. EMG (Elektromiyografi) kontrollü protez kol tasarımı. (Master Tezi), Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 2011.
- [2] Subasi A, Yaman E, Somaily Y, Alynabawi H A, Alobaidi F, Altheibani S. Automated EMG signal classification for diagnosis of neuromuscular disorders using DWT and bagging. *Procedia Computer Science* 2018; 140: 230-237.
- [3] Sapsanis C, Georgoulas G, Tzes A, Lymberopoulos D. Improving EMG based classification of basic hand movements using EMD, 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 3-7 July 2013; Osaka, Japan: IEEE. pp. 5754-5757.
- [4] Sapsanis C, Georgoulas G, Tzes A. EMG based classification of basic hand movements based on time-frequency features. In: 2013 21st Mediterranean Conference on Control & Automation (MED).
- [5] Kakoty NM, Hazarika SM. Recognition of grasp types through principal components of dwt based emg features. In: 2011 IEEE International Conference on Rehabilitation Robotics (ICORR), pp 1–6.
- [6] Nazemi A, Maleki A. Artificial neural network classifier in comparison with LDA and LS-SVM classifiers to recognize 52 hand postures and movements. In: 2014 4th International eConference on Computer and Knowledge Engineering (ICCKE), pp 18–22.
- [7] Nishad A, Upadhyay A, Pachori RB, Acharya UR. Automated classification of hand movements using tunable-Q wavelet transform based filter-bank with surface electromyogram signals. *Future Gener Comp Syst* 2019; 93:96–110.
- [8] Belkhou A, Achmamad A, Jbari A. Classification and Diagnosis of Myopathy EMG Signals Using the Continuous Wavelet Transform. 2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT); 24-26 April 2019; Istanbul, Turkey: IEEE. pp. 1-4.
- [9] Benazzouz A, Guilal R, Amirouche F, Slimane, Z E H. EMG Feature Selection for Diagnosis of Neuromuscular Disorders. 2019 International Conference on Networking and Advanced Systems (ICNAS); 26-27 June 2019; Annaba, Algeria: IEEE. pp. 1-5.
- [10] Babita, P. Kumari, Y. Narayan, and L. Mathew, "Binary movement classification of sEMG signal using linear SVM and Wavelet Packet Transform," 1st IEEE Int. Conf. Power Electron. Intell. Control Energy Syst. ICPEICES 2016, pp. 30–33, 2017, doi: 10.1109/ICPEICES.2016.7853640.
- [11] Arozi M, Putri, FT, Ariyanto M, Caesarendra W, Widyotriatmo A, Setiawan, JD. Electromyography (EMG) signal recognition using combined discrete wavelet transform based on artificial neural network (ANN). 2016 2nd International Conference of Industrial, Mechanical, Electrical, and Chemical Engineering (ICIMECE); 6-7 Oct. 2016; Yogyakarta, Indonesia: IEEE. pp. 95-99.
- [12] Sapsanis, C. , Recognition of basic hand movements using Electromyography, Diploma Thesis, University of Patras, Patras, Greece, 2013.
- [13] Szegedy, C. , W. Liu, Y. Q. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich (2015). "Going Deeper with Convolutions." 2015 Ieee Conference on Computer Vision and Pattern Recognition (Cvpr): 1-9.

- [14] Vapnik VN. An overview of statistical learning theory. *IEEE transactions on neural networks* 1999; 10(5): 988-999.
- [15] Suthaharan S. *Machine Learning Models and Algorithms for Big Data Classification: Thinking with Examples for Effective Learning*. Boston, MA: Springer US, 2016.
- [16] Lu, Q. ve Zhu, J. L. Wavelet packet based de-noising algorithm for UWB GPR data. *14th International Conference on Microwave Radar and Wireless Communications*;2010; Sf. 1-3.
- [17] Wu, Jian-Da & Liu, Chiu-Hong. An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network. *Expert Syst. Appl* 2009; 36. 4278-4286.
- [18] R. N. Khushaba, A. Al-Jumaily, and A. Al-Ani, "Novel Feature Extraction Method based on Fuzzy Entropy and Wavelet Packet Transform for Myoelectric Control", *7th International Symposium on Communications and Information Technologies ISCIT2007, Sydney, Australia*, pp. 352 – 357.
- [19] R. N. Khushaba, S. Kodagoo, S. Lal, and G. Dissanayake, "Driver Drowsiness Classification Using Fuzzy Wavelet Packet Based Feature Extraction Algorithm", *IEEE Transaction on Biomedical Engineering*, vol. 58, no. 1, pp. 121-131, 2011.
- [20] S. Siuly and Y. Li, "A novel statistical algorithm for multiclass EEG signal classification," *Eng. Appl. Artif. Intell Sep.* 2014; vol. 34, pp. 154–167.
- [21] Siuly, X. Yin, S. Hadjiloucas, and Y. Zhang, "Classification of THz pulse signals using two-dimensional cross-correlation feature extraction and non-linear classifiers," *Comput. Methods Programs Biomed Apr.* 2016; vol. 127, pp. 64–82,
- [22] Arı A, Ayaz F, Hanbay D. EMG Sinyallerinin Kısa Zamanlı Fourier Dönüşüm Özellikleri Kullanılarak Yapay Sinir Ağları ile Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2019; 31(2): 443-451.
- [23] Arı, A, Arı B, Alçin ÖF. Elektromiyografi Sinyallerinin Permütasyon Entropi ve Bir Boyutlu Yerel İkili Özellikler Kullanılarak Sınıflandırılması. *İzmir Tepecik Eğitim ve Araştırma Hastanesi Dergisi* 2020; 30: 46-49.
- [24] ALÇİN, Ö. F. Fraktal Eğimden Arındırılmış Dalgalık Analizi ve Pencereleli Kare Ortalamanın Karekökü Tabanlı EMG Sınıflandırma. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 32(2), 359-368.
- [25] Aslan, M. (2020). Normal Cumulative Distribution Function and Dispersion Entropy Based EMG Classification. *Sakarya University Journal of Computer and Information Sciences*, 3(3), 325-333.