

## Değişken Kuvvetli EMG Sinyallerinin Çok Değişkenli Görgül Kip Ayrışımı ile Analizi ve Sınıflandırılması

*Analysis and Classification of Variational Force EMG Signals with Multivariate Empirical Mode Decomposition*

Fatih ONAY<sup>1</sup> , Ahmet MERT<sup>2</sup> 

<sup>1</sup> Elektrik Elektronik Mühendisliği, İzmir Yüksek Teknoloji Enstitüsü, Urla, 35430, İzmir

<sup>2</sup> Mekatronik Mühendisliği, Bursa Teknik Üniversitesi, Yıldırım, 16310, Bursa

### Öz

Elektromiyografi (EMG) sinyalleri, insan-makine etkileşimli akıllı el protezlerinin kontrolünde önemli bir rol oynamaktadır. Kas aktivesinin bir sonucu olarak ortaya çıkan EMG sinyalleri, yapılan aktiviteye dair özel bilgileri kendi içerisinde ihtiva etmektedir. Dolayısıyla akıllı el protezlerinin işlevselliğinin artırılması, kas bölgesinden toplanan EMG sinyalinin doğru bir şekilde analiz edilip yorumlanmasına önemli ölçüde bağlıdır. Bu konseptte uygun olarak, akıllı el protezi hareketlerinin karar verme sürecinde, EMG sinyallerinin güvenilir bir şekilde kullanılabilmesi için, var olan yöntemlerin geliştirilmesi ya da bu yöntemlere üstünlük sağlayacak yeni yöntemler önerilmesi gerekmektedir. Bu çalışma kapsamında, çok kanallı EMG sinyallerinin analizinin geliştirilmesi amacıyla, çok değişkenli görgül kip ayrışımı (ÇDGKA) tabanlı öznelik çıkarma yöntemi, geleneksel metotlara alternatif olarak sunulmuştur. Sinyali adaptif olarak salınım modlarına ayıran ÇDGKA yöntemi kullanılarak, EMG sinyalinden daha anlamlı bilgi edinilmesi amaçlanmıştır. ÇDGKA tabanlı özneliklerin farklı el ve parmak hareketlerini ayırt etme performansı ve farklı kuvvet seviyelerine karşı gösterdiği performans incelenmiştir. Bu amaçla ampute katılımcıların artık uzuvlarından toplanan düşük, orta ve yüksek kuvvet seviyelerine ait EMG sinyalleri üzerinde ÇDGKA yöntemi uygulanarak özgül kip fonksiyonları (ÖKF) elde edilmiştir. Elde edilen ÖKF'lerden çıkarılan öznelikler kullanılarak altı farklı el ve parmak hareketi, en yakın komşu ( $k$ -NN), doğrusal ayırım analizi (LDA) ve destek vektör makinesi (SVM) sınıflandırıcıları kullanılarak sınıflandırılmıştır. Aynı kuvvet seviyesinde eğitilip test edilerek (Senaryo 1) ve tüm kuvvet seviyelerinde eğitilip tek bir kuvvet seviyesinde test edilerek (Senaryo 2) gerçekleştirilen sınıflandırmalar neticesinde, önerilen ÇDGKA tabanlı özneliklerin ham sinyal tabanlı özneliklere göre, senaryo 1 için %10 - %15, senaryo 2 için %18'e kadar üstünlük sağladığı belirlenmiştir.

**Anahtar kelimeler:** Elektromiyografi, Çok değişkenli görgül kip ayrışımı, İnsan-Makine Etkileşimi, El protezi, Kontrol.

### Abstract

Electromyography (EMG) signals play an important role in the control of human-machine interfaced smart hand prostheses. The EMG signals emerged as a result of muscle activity contain specific information about the activity. Therefore, enhancing the functionality of intelligent hand prostheses significantly depends on the precise analysis and interpretation of the EMG signals that are collected from the muscle region. In accordance with this concept, in order to use EMG signals reliably in the decision-making process of smart hand prosthesis movements, it is necessary to improve present methods or to propose new methods to be superior to these methods. In this study, multivariate empirical decomposition (MEMD) based feature extraction method is presented as an alternative to traditional methods to improve the analysis of multichannel EMG signals. It is aimed to obtain more meaningful information from EMG signals by using the MEMD method which separates the signal into adaptive oscillation modes. The performance of discriminating hand and finger movements at different force levels of the MEMD based features was investigated. For this purpose, intrinsic mode functions (IMF) were obtained by using the MEMD method on surface EMG signals of low, medium and high force levels collected from the amputated participants. The features which are extracted from IMFs, classified by  $k$  nearest neighbors ( $k$ -NN), linear discriminant analysis (LDA) and support vector machines (SVM) to discriminate six hand and finger movements. Training and testing at same force level (Scheme 1) and training the classifier with all levels of force and testing it with a single level of force (Scheme 2) classification operations were performed. The proposed MEMD based features have outperformed raw signal-based features, 10% -15% for Scheme 1 and up to 18% for Scheme 2.

**Keywords:** Electromyography, Multivariate Empirical Mode Decomposition, Human-Machine Interface, Hand Prosthesis, Control.

## I. GİRİŞ

İnsan vücudunda meydana gelen uzuv kayıpları; doğuştan, sonradan yaşanan kazalar ve hastalıklar sebebiyle meydana gelebilmekte ve bunun sonucu olarak da engelli insan sayısı her geçen gün artmaktadır. Dolayısıyla, engelli insanların yaşam kalitesini arttırmak için araştırmacılar, basit ve doğal insan-makine etkileşimli cihazların gerekliliğini düşünmektedir. İnsan-makine etkileşimi için özel bir dokudan, organdan veya sinir sisteminden elde edilen elektroensefalografi (EEG) [1], elektrookülografi (EOG) [2] veya elektromiyografi (EMG) gibi çeşitli biyolojik sinyaller kullanılabilir. EMG sinyallerinin diğer biyolojik sinyallere göre daha yüksek sinyal-gürültü oranına sahip olması sebebiyle, insan-makine etkileşimli güçlendirilmiş akıllı protezlerin kontrolünde EMG sinyali tercih edilir [3].

Ampute bireylerin artık uzuvlarından alınan EMG sinyalleri ile protez kontrolü gerçekleştirmek mümkündür. EMG sinyalleri, akıllı protezlerin kullanıcıya sağladığı sezgisel kontrol sayesinde karmaşık görevlerin gerçekleştirilmesine olanak sağlar. Bu karmaşık kontrol sürecinin geliştirilmesi oldukça önemlidir. Bu yüzden ampute bireylerin gündelik hayatta çok fonksiyonlu el ve parmak hareketlerini gerçekleştirebilmeleri için halen pratik protezlerin geliştirilmesine ihtiyaç vardır [4]. EMG sinyali, insan kasları içerisinde bulunan bireysel motor ünitelerinin aktivitesi sonucu ortaya çıkan bir işarettir. Bu işaret kas bölgelerindeki deri üzerine yerleştirilen yüzey elektrotları ya da kas dokusuna batırılan iğne benzeri elektrotlar yardımıyla toplanabilir [5]. Yapılan çalışmalar invaziv yöntemlerle invaziv olmayan yöntemlerin benzer doğrulukta sonuçlar verdiğini göstermiştir [6]. Yüzey EMG (sEMG) yöntemi, invaziv yöntemlere göre daha kolay kullanıma sahip olması nedeniyle güçlendirilmiş protezlerin kontrolünde ihtiyaç olan sinyalin toplanması için tercih edilir.

Deri yüzeyine elektrotlar yerleştirilerek toplanan EMG sinyallerini belirtmek için kullanılan sEMG, birden fazla elektrod kullanılarak da toplanabilir ve çok kanallı sEMG halini alır. sEMG sinyallerinin zaman düzlemindeki analizinde, genlik ve enerji gibi temel sinyal analiz yöntemleri kullanılırken, frekans düzlemi analizinde ise Fourier dönüşümü (FD) ve dalgacık dönüşümü (DD) gibi sinyal işleme yöntemleri kullanılmaktadır. Farklı kas hareketleri ile elde edilen işaretler arasındaki farkları tespit etmek için gelişmiş sinyal işleme teknikleri kullanılmalıdır. Ayrıca, birden fazla kas grubunun aynı anda çalıştığı hareketler için de ayırt edici özelliklerin bulunması gerekmektedir.

Akıllı el protezlerinin kontrolünde, işlem hızı bakımından zaman tabanlı özniteliklerin kullanılması tercih edilir. Fakat farklı kuvvet seviyelerindeki kas hareketlerini ayırt etme performansı bakımından, ham sinyal tabanlı özniteliklerin geliştirilmeye ihtiyacı

olduğu görülmektedir [7]. Kuvvet seviyesi değişimi ile birlikte, yapılan harekete ait kas grubundaki aktif olan motor ünitesi sayısının değişmesi, aynı hareket için farklı işaretlerin ortaya çıkmasına sebep olmaktadır. Bir akıllı protezin, farklı kuvvet seviyelerinde yapılan el hareketlerini doğru bir şekilde taklit edebilmesini sağlayacak gürbüz yöntemler geliştirmek önemli bir ihtiyaçtır.

Bu çalışmada, doğrusal olmayan ve durağan olmayan sinyallerin işlenmesinde taban fonksiyonuna ihtiyaç duyan analitik sinyal işleme yöntemlerine alternatif olarak geliştirilen çok değişkenli görgül kip ayrışımı yöntemi (ÇDGKA) kullanılacaktır. EMG sinyali gibi doğrusal olmayan ve durağan olmayan sinyaller, önceden belirlenen bir taban fonksiyonunun karakteristiğinden farklı bir yapıya sahip olabilir bu da analizin doğru olarak yapılamamasına sebep olabilmektedir. Bu çalışmanın amacı ise, farklı kas gruplarının eş zamanlı çalışması neticesinde oluşan çok kanallı sEMG sinyallerinin ayırt edici analizini, güncel ve gelişmiş sinyal işleme yöntemi olan ÇDGKA ile gerçekleştirmektir. Ampute bireylerden toplanan çok kanallı sEMG sinyallerinin ÇDGKA ile analizi gerçekleştirilerek, sinyalin özgül kip fonksiyonları (ÖKF) elde edilecektir. Farklı bir frekans bantlarını temsil eden ÖKF'lerden çıkarılan zaman tabanlı özniteliklerin kullanılmasıyla sınıflandırma işlemi yapılacaktır. Bunun neticesinde altı farklı el ve parmak hareketini temsil eden sEMG sinyallerinin daha doğru bir şekilde ayırt edilebilmesi amaçlanmıştır. Tüm bu işlemler gerçekleştirilerek ÇDGKA tabanlı özniteliklerin, farklı kuvvet seviyelerinde gerçekleştirilen kas hareketlerini ayırt etme performansı incelenecektir.

## II. MATERYAL ve YÖNTEM

### 2.1. Veri Seti

Bu çalışma için kullanılan veri seti tek taraflı amputasyona sahip dokuz bireyden (7'si travmatik, 2'si doğuştan) elde edilmiştir. Tablo 1'de verilerin toplandığı katılımcılara ait yaş, cinsiyet ve amputasyon türüne ait bilgiler verilmiştir. En az sekiz kanallı, örnekleme frekansı 2000 Hz ve çözünürlüğü 16 bit olan EMG edinim sisteminin (USB-6210, National Instruments) kullanımıyla, toplamda altı farklı kavrama ve parmak hareketine ait işaretleri içeren veri seti oluşturulmuştur. Kazanç faktörü 1000 olan çok kanallı EMG yükseltici ile her bir kanal için elde edilen sinyal yükseltilmiştir. Altı farklı parmak hareketi için her bir katılımcıdan beş ila sekiz adet kayıt alınmıştır.

**Tablo 1.** Çalışmada yer alan katılımcıların bilgisi.

Katılımcı	Yaş	Cinsiyet	Ampute Türü
Ampute 1	25	E	Travmatik
Ampute 2	33	E	Travmatik


Ampute 3	30	E	Travmatik
Ampute 4	27	E	Travmatik
Ampute 5	35	E	Travmatik
Ampute 6	29	E	Travmatik
Ampute 7	57	E	Travmatik
Ampute 8	19	K	Doğuştan
Ampute 9	31	K	Doğuştan

Veri setindeki 6 el hareketi Şekil 1'de gösterildiği gibidir. Sırasıyla; başparmak (BP), işaret parmağı (İP), çimdik (ÇK), tripod kavrama (TK) kanca kavrama (KK) ve küresel kavrama (KÜK) hareketleri için toplam 9 amputeden 54 farklı EMG sinyali örneği içeren veri seti bu çalışmada kullanılmıştır.



Şekil 1. Altı sınıflı veri seti el hareketleri (1: BP, 2: İP, 3: ÇK, 4:TK, 5: KK, 6:KÜK).

Elektrodlar yerleştirilmeden önce katılımcıların derileri alkol ve aşındırıcı cilt hazırlama jeli ile temizlenmiştir. Sonrasında 8 çift Ag/AgCl yüzey elektrodu SENIAM (Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles) tarafından belirlenen kıstaslara göre katılımcıların artik uzuvları üzerine tek ya da iki sıra halinde yerleştirilmiştir. Ampute 2 katılımcısına ait elektrodların yerleşimi Şekil 2'de gösterilmiştir.



Şekil 2. Ampute 2 katılımcısına ait örnek elektrod yereleşimi

Veri toplama işlemi sırasında, katılımcılar amputasyona uğramış uzuvlarını kullanarak istenilen hareketi yapabilmek için, bir yandan zarar görmemiş olan sağlam elleriyle de hareketleri gerçekleştirmişlerdir. Bunun yanında PC ekranında EMG kanallarını gözlemleyebilmelerini sağlayacak görseller kullanılmıştır. Böylelikle, katılımcıların istenilen kuvvet seviyesindeki hareketleri

yapabilmeleri desteklenmiştir. Bu veri setinde düşük, orta ve yüksek kuvvet seviyelerine ait sinyallerin her biri için kayıtlar bulunmaktadır. Her bir el ve parmak hareketlerinin, tüm kuvvet seviyelerine ait işaretleri bu çalışma kapsamında kullanılacaktır.


## 2.2. Görgül Kip Ayırışımı

GKA Huang ve arkadaşları [8] tarafından geliştirilmiş olup doğrusal olmayan ve durağan olmayan sinyallerin işlenmesinde başarılı sonuçlar veren bir sinyal ayırışırma algoritmasıdır. Sinyali, kendi içinde barındırdığı sonlu sayıda genlik ve frekans modüleri özgül kip fonksiyonlarına (ÖKF) ayırıştıran ve doğal salınım kiplerini gösteren bir eleme sürecidir. Fourier analizinde sinüs ve kosinüs dalgalarıyla temsil edilen salınım kipleri, GKA algoritmasında özgül kip fonksiyonları ile temsil edilmektedir. GKA ile eleme süreci neticesinde elde edilen fonksiyonların özgül kip fonksiyonu olması için gerek ve yeter iki şart şu şekildedir;

1. Tüm zaman serisi boyunca mevcut olan yerel maksimum ve yerel minimum nokta sayısı sıfır geçiş sayısına eşit olmalı ya da aralarında en fazla bir fark olmalıdır.
2. Yerel maksimum noktalarının oluşturduğu üst zarf ile yerel minimum noktalarının oluşturduğu alt zarfın ortalaması sıfıra eşit olmalıdır.

Yukarıda verilen şartlar ampirik olarak elde edilir bu yüzden elde edilecek ÖKF'lerin bant aralığı ve sayısı önceden kestirilemez. İkinci şartta ifade edilen yerel maksimum ve yerel minimum noktalarının ortalaması, zarf boyunca noktasal olarak hesaplanan yerel ortalamayı belirtmektedir. ÖKF'ler orijinal sinyalin farklı frekans bantlarını ve zaman ölçeklerini gösteren fonksiyonlardır. ÖKF'ler sinyalin yerel ortalamalarının hesaplanmasıyla bulunur ve böylelikle yerel ölçekte sinyalin analizi gerçekleştirilebilir. GKA algoritmasını örnek bir  $x(t)$  sinyaline etkili bir şekilde uygulamak için, eleme süreci olarak adlandırılan işlem yerine getirilmelidir. İzlenmesi gereken adımlar şu şekildedir;

- i. Örnek bir  $x(t)$  sinyalinin tüm yerel maksimum noktaları  $M(k)$ ,  $k=1,2,3...$  ve tüm yerel minimum noktaları  $M(i)$ ,  $i = 1,2,3...$  sırasıyla tespit edilir.
- ii. Kübik spline interpolasyonu uygulanarak yerel maksimum ve yerel minimum noktaları birleştirilir ve sinyalin üst ve alt zarfları  $e_{\max}(t)$  ve  $e_{\min}(t)$  bulunur.
- iii. Bulunan üst ve alt zarfların ortalaması  $m t = e_{\min} t + e_{\max} t / 2$  hesaplanır.



Şekil 3. GKA Algoritması Akış Diyagramı

- iv.  $m(t)$  değeri ÖKF şartlarını sağlıyorsa  $c(t) = m(t)$  ÖKF olarak saklanır. (Akış diyagramında  $m(t)$ 'nin ÖKF şartlarını sağlamadığı varsayılmıştır)
- v. ÖKF şartlarını sağlamaması durumunda  $m(t)$  fonksiyonu sinyalin kendisinden çıkarılır.  $h_1(t) = x(t) - m_1(t)$  elde edilir.
- vi. Bulunan  $h_1(t)$  ÖKF olma şartlarını yerine getirmese,  $h_k(t) = h_{k-1}(t) - m_k(t)$  işlemi yapılarak ilk adıma dönülür ( $k=1$  için  $h_{k-1}(t) = x(t)$ ) ve  $h_1(t)$  üzerinde ÖKF şartları sağlanıncaya kadar eleme süreci devam eder. Böylece  $h_1(t)$  yeni veri olarak kabul edilir.

Eleme sürecinden ÖKF elde etme işlemi monotonik bir fonksiyon olan  $r(t)$  ifadesi elde edilinceye dek sürdürülür. Eleme sürecinin tamamlanmasıyla birlikte orijinal sinyal şu formda yazılabilir;

$$x(t) = \sum_{k=1}^L c_k(t) + r(t) \quad (1)$$

GKA algoritması, tek-kanal tabanlı bir analiz işlemi gerçekleştirmek için elverişlidir. Fakat çok kanallı sinyaller üzerinde uygulanması durumunda, kanallar arasındaki ilişkiyi dikkate almaz ve bu sebeple çok kanallı sinyallerin tutarlı bir analizini gerçekleştirmek mümkün olmayabilir. Çok kanallı sinyaller üzerinde uygulanabilecek daha kapsamlı ve tutarlı sonuçlar verebilecek bir algoritma olan ÇDGKA yöntemi bu sebeple geliştirilmiştir. Bu yöntem, n-boyutlu bir

uzayda eleme sürecinin gerçekleştirilmesiyle bulunan ÖKF bileşenlerinin kullanılmasını esas almıştır.

### 2.3. Çok Değişkenli Görgül Kip Ayırımı

GKA algoritması, tek-kanal tabanlı bir analiz yöntemi olup, çok kanallı EMG sinyallerini işlemek için doğrudan uygulanamaz. Ayrıca GKA algoritması, çok kanallı sinyaller için ayrıştırılmış ÖKF'lerin sayısının eşitliğini garanti etmez ve bu da çok kanallı EMG sinyal analizlerinin fiziksel olarak anlamsız olmasına neden olabilir.

Çok kanallı sinyallerin analizinde yetersiz kalan GKA yöntemine alternatif olarak Rehman ve Mandic tarafından [9] geliştirilen çok değişkenli görgül kip ayrışımı yöntemi (ÇDGKA), tüm kanallardaki sinyallerden aynı sayıda ÖKF elde edilmesine olanak sağlar. ÇDGKA yöntemi, çok boyutlu sinyallerin salınım modlarının ortak analizini yaparak mod-hizalama sorununu çözmeye yardımcı olur. Bu da farklı kanallardaki aynı indeksli ÖKF'ler arasındaki frekans bantlarının tutarlılığının sağlanmasıyla gerçekleştirilir. Ayrıca frekans bantlarının birbiriyle tutarlı olması aynı sayıda ÖKF elde edilmesine katkı sağlayarak çok boyutlu sinyalin genel analizini yapmayı kolaylaştırır ve daha doğru bilgi elde edilmesini sağlar.

GKA algoritması, yerel ekstremum noktalarının interpolasyonu ile elde edilen üst ve alt zarfların ortalamasını alarak, yerel ortalama değerini kolaylıkla hesaplayabilir. Fakat çok değişkenli sinyallerin direkt olarak yerel ekstremum noktalarını bulmak kolay bir işlem değildir. Bu işlemin üstesinden gelebilmek amacıyla, ÇDGKA yöntemi, çok kanallı sinyallerin n-boyutlu bir uzayda farklı doğrultulardaki gerçek değerli iz düşümlerini kullanır. Çok kanallı sinyalin farklı doğrultulardaki bu iz düşümleri genliği temsil

eder. Bu iz düşümler kullanılarak sinyalin her bir kanalındaki zarfları elde edilir.

Farklı doğrultular boyunca uzanan bu zarfların, n-boyutlu uzaydaki integralinin hesaplanmasıyla yerel ortalama bulunabilir. Bu şekilde bulunan yerel ortalamalar kullanılarak daha gürbüz bir eliminasyon işlemi yapılmış olur.

#### 2.4. Öznitelik Çıkarma ve Sınıflandırma

EMG sinyalleri aracılığıyla, farklı el hareketlerinin ayrıştırılması için yapılması gereken önemli işlemlerden birisi de uygun öznitelikleri çıkarmaktır. Sınıflandırma işleminin sonucu, sınıflandırıcının kendisinden çok, kullanılan özniteliklerin etkisine bağlıdır. Öznitelik çıkarma işlemi, verinin içerisinde barındırdığı faydalı bilgileri elde etmek için kullanılan bir yöntemdir. Sinyalin kendisinden daha küçük boyutlu öznitelik vektörü elde etmek sınıflandırıcının hızını artırarak, gerçek zamanlı uygulamaların daha iyi bir performans sergilemesini sağlayacaktır. sEMG sinyalinden çıkarılacak öznitelikler zaman tabanına, frekans tabanına ve zaman-frekans tabanına dayanan öznitelikler olmak üzere üç ana gruba ayrılabilir [10]. Zaman tabanlı öznitelikler herhangi bir transformasyon gerektirmeksizin ham EMG sinyalinden direkt olarak elde edilir. Bu özniteliklerin uygulanması kolaydır ve düşük hesaplama yükü gerektirir. Öte yandan, frekans tabanlı öznitelikle ise genellikle EMG sinyalinin güç spektral yoğunluğunun istatistiksel özelliklerini yansıtmaktadır ve kompleks işlem yükü fazladır. Protez uygulamalarında zaman tabanlı özniteliklerin iyi sonuçlar verdiği literatürde geçmiş çalışmalarda gözlemlenmiştir. [11]

Öznitelikler doğrudan EMG sinyalinin kendisinden elde edilebileceği gibi, sinyalin ayrıştırılması sonucu ortaya çıkan bileşenler kullanılarak da elde edilebilir. Fakat el hareketleri sonucunda ortaya çıkan EMG işaretleri doğrusal olmayan ve durağan olmayan bir zaman serisi olarak kabul edildiğinden, doğrusallığı ve durağanlığı varsayan ayrıştırma algoritmaları yanlıcı sonuçlar verebilmektedir [12]. Bu yüzden ayırt edilmesi kolay öznitelikleri kullanabilmek için, EMG sinyalinin karakteristik özelliklerini dikkate alan teknikler kullanarak öznitelikler elde edilmelidir. ÇDGKA, EMG sinyallerine uygulanabilecek potansiyel bir yöntemdir. Sinyali adaptif olarak bileşenlerine ayıran ÇDGKA yöntemi, sinyalden ilgili özniteliklerin çıkarılmasına olanak sağlar ve aynı zamanda arkaplan gürültüsünün bastırılmasında ve motor ünitelerinin tespit edilmesinde de işlevsel bir rol oynar [12, 13].

Sonuç olarak ÇDGKA yönteminin kullanılması neticesinde elde edilen özgül kip fonksiyonlarından çıkarılan özniteliklerin performansı bu çalışma kapsamında incelenecektir.

Bu çalışmada kullanılan özniteliklere ait kısa tanımlamalar aşağıda verilmiştir.

**Varyans ( $\sigma^2$ )** : Sinyalin ortalamadan ne kadar uzaklaştığının bir ölçüsü olan standart sapmanın karesidir. Varyans, bu dalgalanmanın gücünü temsil eder. N elemanlı bir dizinin varyans hesabı;

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N |x_i - \mu|^2 \quad (2)$$

**Dalga Formu Uzunluğu (WL)**: EMG sinyalinin her bir segmentindeki karmaşıklık ölçüsünü ifade eden bir özniteliktir. Sinyalin ardışık genlikleri  $x_n$  ve  $x_{n-1}$  arasındaki mutlak farkların toplamına eşittir.

$$WL = \sum_{n=1}^N |x_n - x_{n-1}| \quad (3)$$


**Etkin Değer (RMS)** : Kasılma esnasında motor ünitelerdeki fizyolojik aktivitelerin seviyesini yansıttığı için sık seçilen bir parametredir.

$$RMS = \sqrt{\frac{1}{N} \sum_{n=1}^N |x_n|^2} \quad (4)$$

Yukarıda verilen zaman tabanlı öznitelikler sEMG sinyallerinin analizinde sıkça kullanılmaktadır. Bu özniteliklerin ham sinyalden elde edilmiş halleri ve ÇDGKA analizi neticesinde ÖKF'lerden elde edilmiş halleri k-NN, SVM ve LDA sınıflandırıcıları kullanılarak sınıflandırılıp ÇDGKA tabanlı özniteliklerin sınıflandırma başarısına olan etkileri gözlemlenecektir.


ÇDGKA yöntemi sinyali frekans bantlarına ayırırken, ortaya çıkacak frekans bantlarının sayısı analiz edilen sinyalin uzunluğuna bağlıdır. Bu sebeple ilk olarak sinyalin içerdiği mümkün olan tüm frekans bantlarının elde edilmesi için N adet örnek uzunluğunda sEMG sinyalleri kullanılmıştır. Bu işlem sonucunda elde edilen K adet ÖKF bileşeninin herbirine ait ortalama frekans değerleri hesaplanır. Düşük frekans bandındaki hareket artefaktlarını bastırmak adına literatürde 10 Hz veya 20 Hz altındaki frekans bileşenlerinin filtrelenmesi önerilmiştir [14,15,16]. Bu yüzden ortalama frekans değeri 20 Hz altında olan 'e' adet ÖKF bileşeni öznitelik çıkarma sürecine dahil edilmemiştir. Böylelikle tek bir harekete ait öznitelik vektörünün uzunluğu, **kanal sayısı × ÖKF sayısı × öznitelik sayısı** olarak bulunur. Şekil 4'te pencereleyen sinyalden elde edilen ÖKF'lere ait örnek gösterilmiştir.

Veri setinde yer alan toplamda altı el ve parmak hareketine ait sinyallere pencereleme işleminin uygulanmasıyla birlikte uygun uzunluktaki sinyaller ÇDGKA yöntemi ile salınım modlarına ayrıştırılır.



Şekil 4. Sinyale uygulanan pencereleme işlemi.

Tüm ÖKF'lerden öznelik çıkarılmasıyla öznelik vektörü elde edilir. Şekil 5'te BP hareketine ait pencerelenmiş çok kanallı sEMG sinyalinin birinci kanalına ait öznelik çıkarma süreci gösterilmiştir. Örnek sinyal, ÇDGKA ile ÖKF'lerine ayrıştırılır ve her bir ÖKF'nin varyans, RMS, WL öznelikleri çıkarılarak tek bir hareket örneğine ait öznelik vektörü elde edilir.



Şekil 5. Tek bir kanal için öznelik vektörünün elde edilmesi.


### III. DENEYSEL SONUÇLAR

#### 3.1. ÇDGKA ile ÖKF'lerin Bulunması ve Eliminasyonu


Öznelik çıkarma ve sınıflandırma algoritmaları sEMG sinyallerinden elde edilen ÖKF'lere uygulanarak sonuçlar elde edilmiştir. Bu çalışmada etkin değer, varyans ve dalga formu uzunluğu olmak üzere üç adet zaman tabanlı öznelik kullanılmıştır. Sınıflandırma işlemi için k-en yakın komşu ( $k$ -NN), destek vektör makineleri (SVM) ve doğrusal ayırt etme analizi (LDA) algoritmaları uygulanıp test edilmiş ve doğruluk sonuçları karşılaştırılmıştır.

Şekil 6 ve Şekil 7'de ÇDGKA ile analiz edilmiş örnek bir sEMG işaretinin tek bir kanalına ait ÖKF'ler yer almaktadır. İlk ÖKF'den son ÖKF'ye doğru gidildikçe bileşenlerin periyotlarındaki değişimin artma eğiliminde olduğu görülmektedir. Her ÖKF, orijinal

sinyalin farklı frekans bantlarındaki salınımlarını temsil etmektedir.




Şekil 6. İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, birinci kanal sEMG sinyaline ait ilk 7 ÖKF bileşeni.



Şekil 7. İlk amputeden alınan orta kuvvet seviyesindeki BP hareketinin, ilk kanal sEMG sinyaline ait son 6 ÖKF bileşeni ve artık.


Şekil 8'de orta kuvvet seviyesine ait tüm hareketlerin bütün kanalları için hesaplanan her bir ÖKF'nin ortalama frekans değerleri verilmiştir. sEMG sinyalinin ediniminde kullanılan sekiz kanallı her birinden toplam 13 ÖKF bileşeni ve bir de artık elde edilmiştir. Her ÖKF bileşenin farklı bir salınım modunu temsil

ettiği verilen şekilde açıkça görülmektedir. Ayrıca ÇDGKA yöntemi kanalların tümünden aynı sayıda ÖKF bileşeni çıkararak, tüm kanalların salınım modlarının aynı ölçekte hizalanmasını da sağlamaktadır. ÇDGKA algoritmasının kanallar arasındaki mod hizalama ve ÖKF'ler arasındaki mod karışımı ölçütlerini uygun bir şekilde yerine getirdiği görülmektedir.



**Şekil 8.** Orta kuvvet seviyesindeki tüm hareketlere ait 8 kanallı sEMG sinyalinin ÇDGKA kullanılarak elde edilen ÖKF'lerinin ortalama frekans değerleri.

Şekil 9'da ÇDGKA analizi neticesinde sEMG sinyallerinden elde edilen ÖKF adetlerinin sayılarının dağılımı verilmiştir. Katılımcılardan toplanan tüm sinyaller aynı uzunlukta olmasına rağmen ÖKF sayıları aynı değildir ve 12 ile 16 arasında bir değişim göstermiştir.



**Şekil 9.** Sinyallerden elde edilen ÖKF sayılarının dağılımı.


Tablo 2'de, bulunan tüm ÖKF'lerin ortalama frekans değerleri verilmiştir. Ortalama frekans değerleri ÖKF'lerin hangi bant aralığında salınım yaptığına dair bilgi vermektedir. ÇDGKA yöntemi sinyalin ayrıştırılmasında kullanılırken bununla birlikte her ÖKF'nin farklı frekans bandında salınım yapması sebebiyle sinyalin gürültüden temizlenmesi için de kullanılabilir. Özellikle kayıt esnasında ve elektromyetik girişim sebebiyle ortaya çıkan düşük frekans bandındaki gürültülerin temizlenmesi için 20 Hz frekans değeri altında kalan ÖKF'ler sınıflandırma performansını arttırmak için kullanılmamıştır. sEMG sinyali kontrollü bir protez elin pratik olarak uygulamalarda kontrolünü gerçekleştirmek için, kısa örneklili sEMG sinyallerinin analizinin yapılması gerekmektedir. Bu kısımda ÇDGKA yönteminin bu amaca yönelik uygulanması ve performansı

incelenecektir. Bir önceki kısımda sEMG sinyali üzerinde uygulanan ÇDGKA yöntemi ile bulunan ÖKF'lerin ortalama frekans değerleri incelenmiştir.

**Tablo 2.** Bütün kuvvet seviyelerinden elde edilen ÖKF'lerin ortalama frekans değerleri.


Toplam ÖKF Sayısı	Düşük Kuvvet (Hz)	Orta Kuvvet (Hz)	Yüksek Kuvvet (Hz)
1	348,96	345,85	345,26
2	199,55	198,36	198,37
3	116,56	115,82	115,90
4	66,60	66,38	66,33
5	40,57	40,44	40,36
6	23,29	23,60	23,63
7	14,02	14,24	14,21
8	8,75	8,76	8,65
9	5,32	5,34	5,32
10	3,37	3,34	3,35
11	2,17	2,16	2,15
12	1,51	1,52	1,47
13	1,02	1,01	0,98

Elde edilen sonuçlara göre ilk 6 ÖKF'nin sınıflandırma performansında en iyi sonucu almak için yeterli olduğu gözlemlenmiştir. Bu sebeple en az 6 ÖKF elde etmeyi sağlayacak uzunluktaki sinyali kullanmak hem hesaplama yükünü azaltmaktadır hem de ÇDGKA tabanlı örnekleme tanıma modelinin gerçek zamanlı olarak uygulanabilmesine yönelik performansı arttırmaktadır. Ampirik olarak gerçekleştirilen çalışmalar sonucunda 256 ms uzunluğundaki sinyalin en az 6 ÖKF bileşeni çıkarmayı temin ettiği görülmüştür. Pencereleme bitişik olarak değil birbirleriyle 128 ms'lik bir kısımda örtüşecek biçimde ilerletilmiştir. Bu işleme ait süreç Şekil 10'da gösterilmiştir.



**Şekil 10.** Yüksek kuvvet sEMG işaretine uygulanan pencereleme işlemi.

Pencerelenen sinyaller ÇDGKA ile ÖKF bileşenlerine ayrıştırılmıştır. Şekil 11'de tek bir kanalın, bir penceresinden çıkarılan ÖKF bileşenleri gösterilmiştir. Elde edilen ÖKF'ler kanalın içerdiği salınım modlarını sırasıyla, en yüksekten başlayarak en düşük olana doğru sıralanmıştır. Böylelikle sinyalin farklı salınım modları üzerinde doğrudan işlem yapabilme imkânı elde edilmiştir. Bu işlem her bir kanal için tekrarlanarak, her bir kanalın salınım modları ayrı ayrı bulunmuştur.



**Şekil 11.** Tek bir pencereden elde edilen ÖKF bileşenleri.

Ayrıca bu sinyale ait ÖKF'lerin her birine ait ortalama frekans ( $Fr_m$ ) değerleri Tablo 3'te yer almaktadır. Buna göre, ilk 6 ÖKF'nin 20 Hz üzerindeki frekans bileşenlerini temsil ettiği açıkça görülmektedir.

**Tablo 3.** ÖKF'lerin ortalama frekans değerleri.


ÖKF	1. ÖKF	2. ÖKF	3. ÖKF	4. ÖKF	5. ÖKF	6. ÖKF	7. ÖKF	8. ÖKF
$Fr_m$ (Hz)	374.8	216.5	126.8	78.2	44.6	24	15.1	7.51

Sinyal uzunluğu kısılmasına rağmen ÇDGKA yöntemi sEMG sinyalinden halen ihtiyaç duyulan frekans bantlarını çıkarabilmektedir. Sinyalin kısılması sadece düşük frekans bantlarındaki bileşenlerin elde edilememesine sebep olmuştur fakat bu bantlar sEMG sinyali analizi için gereken bileşenler değildir. Çalışmalar neticesinde pencerelerden en az 7 en fazla 11 ÖKF bileşeni elde edilmiştir ve bu da öznelik çıkarma işlemi için uygun olan bantları kullanmak için elverişli bir imkân sunmaktadır.

### 3.2. Sınıflandırma Sonuçları

Bu kısımda pencerelenen sinyallerden elde edilen ÖKF'ler ve bu ÖKF'lerden elde edilen özneliklerin, aynı kuvvet seviyesinde eğitilip test edilerek (Senaryo 1) ve tüm kuvvet seviyelerinde eğitilip tek bir kuvvet seviyesinde test edilerek (Senaryo 2) sınıflandırma işlemleri gerçekleştirilmiştir. Her bir hareket için katılımcılardan beş ile dokuz arasında farklı oturumda kayıt toplanmıştır. Sınıflandırma işleminde ise bu oturumlardan ikisi test için kullanılırken geri kalanlar ise eğitim verisi olarak kullanılmıştır.

Şekil 12'de ÇDGKA tabanlı ve ham sinyal tabanlı özneliklerin Senaryo 1 için sınıflandırma sonuçları k-NN, LDA ve SVM için üç farklı kuvvet seviyesine göre gösterilmiştir.




**Şekil 3.** Aynı kuvvet eğitim ve test kümesi kullanılarak elde edilen sınıflandırma sonuçları.

Tablo 4'te pencereleme yöntemiyle elde edilen örnekler kullanılarak yapılan sınıflandırma sonuçlarının sayısal değerleri verilmiştir. Tüm kuvvet seviyeleri için, ÇDGKA tabanlı öznelik çıkarma yönteminin, ham veriden doğrudan öznelik çıkarma yöntemine göre LDA ve SVM sınıflandırıcısı için ortalama %12 daha başarılı olduğu görülmektedir. Düşük kuvvet seviyesinde k-NN sınıflandırıcısının ÇDGKA tabanlı öznelikleri ayırt etme performansı önde olsa da orta ve yüksek kuvvetlerin ayrıştırılmasında ÇDGKA tabanlı öznelikler daha kötü bir performans göstermiştir.

Farklı kuvvet seviyelerinde ortaya çıkan sEMG işaretinin ayrıştırılmasına yönelik yapılan sınıflandırma işlemlerinde kullanılan özneliklerin performansı, Senaryo 2 için de ayrıca test edilmiştir. Tüm kuvvet seviyelerine ait öznelikler kullanılarak eğitim işlemi yapılmış ve tek bir kuvvet seviyesine ait öznelikler ile test edilerek sınıflandırma işlemi gerçekleştirilmiştir.

Şekil 13'te ÇDGKA tabanlı ve ham sinyal tabanlı özneliklerin Senaryo 2 için sınıflandırma sonuçları k-NN, LDA ve SVM için üç farklı kuvvet seviyesine göre gösterilmiştir.



**Şekil 13.** Tüm kuvvet eğitim ve tek kuvvet test kümesi kullanılarak elde edilen sınıflandırma sonuçları.

Tablo 5'te ham sinyal tabanlı özneliklerin ve ÇDGKA tabanlı özneliklerin sınıflandırılması neticesinde bulunan sonuçlar üç farklı kuvvet seviyesi için verilmiştir. İlk senaryoya benzer bir şekilde tüm kuvvet seviyelerinde geçerli olmak üzere ÇDGKA tabanlı öznelikler, ham tabanlı özneliklere göre LDA sınıflandırıcısı için ortalama %12 ve SVM sınıflandırıcısı için ortalama %11 daha başarılı bir performans göstermiştir. Düşük kuvvet seviyesinde k-NN ile



yapılan ayırt etme işleminde ÇDGKA tabanlı öznelikler, ham tabanlı özneliklere üstünlük sağlamış olsa da orta ve yüksek kuvvet seviyelerinde geride kalmıştır.

**Tablo 5.** Tüm kuvvet seviyeleri ile eğitim ve tek bir kuvvet seviyesi ile test için sınıflandırma sonuçları.

Kuvvet	Yöntem	k-NN	LDA	SVM
Düşük Kuvvet	ÇDGKA	<b>66,46</b>	<b>47,69</b>	<b>52,78</b>
	Ham	64,04	30,86	40,17
Orta Kuvvet	ÇDGKA	<b>62,45</b>	<b>48,46</b>	<b>57,77</b>
	Ham	67,54	39,09	45,73
Yüksek Kuvvet	ÇDGKA	<b>68,06</b>	<b>48,41</b>	<b>59,41</b>
	Ham	69,75	40,95	49,28

Şekil 14'te ise sırasıyla LDA ve SVM sınıflandırıcılarına ait düşük, orta ve yüksek kuvvetlerin genel sınıflandırma sonuçları verilmiştir. Her bir el hareketinin, ÇDGKA tabanlı ve ham tabanlı özneliklere göre sınıflandırma sonuçları karışıklık matrislerinde yer almaktadır.

		Karışıklık Matrisi						
Tahmin		BP	İP	ÇK	TK	KK	KÜK	
		BP	535 488	18 78	271 319	19 54	32 117	142 199
İP	25 63	555 423	52 104	204 248	196 297	142 135	47.3% 33.3%	
ÇK	223 160	55 61	487 300	15 37	50 54	74 115	53.9% 41.3%	
TK	27 107	112 146	8 37	469 419	75 84	25 83	65.5% 47.8%	
KK	35 45	132 237	42 65	159 140	438 361	263 275	41.0% 32.1%	
KÜK	127 109	100 27	112 147	106 74	181 59	326 165	34.2% 28.4%	
		55.0% 50.2%	57.1% 43.5%	50.1% 30.9%	48.3% 43.1%	45.1% 37.1%	33.5% 17.0%	48.2% 37.0%
		BP	İP	ÇK	TK	KK	KÜK	
		Gerçek						

(a) LDA sınıflandırma

		Karışıklık Matrisi						
Tahmin		BP	İP	ÇK	TK	KK	KÜK	
		BP	590 499	31 55	237 284	12 31	42 45	83 135
İP	9 54	575 495	53 64	109 145	182 198	123 201	54.7% 42.8%	
ÇK	233 217	38 70	549 456	34 59	52 108	87 142	55.3% 43.3%	
TK	27 84	137 147	25 45	673 569	116 168	42 88	66.0% 51.7%	
KK	43 45	128 145	35 50	87 111	449 363	169 160	49.3% 41.5%	
KÜK	70 73	63 60	73 73	57 57	131 90	468 246	54.3% 41.1%	
		60.7% 51.3%	59.2% 50.9%	56.5% 46.9%	69.2% 58.5%	46.2% 37.3%	48.1% 25.3%	56.7% 45.1%
		BP	İP	ÇK	TK	KK	KÜK	
		Gerçek						

(b) SVM sınıflandırma

**Şekil 14.** Üç Kuvvet için ortalama sınıflandırma sonuçları

#### IV. SONUÇ VE TARTIŞMA

Bu çalışma kapsamında, EMG sinyallerini işlemek ve özelliklerini tespit etmek için kullanılan ÇDGKA yöntemi ile elde edilen öznelikler, el ve parmak hareketlerini ayırt etme performansı bakımından ham sinyal tabanlı öznelikler ile karşılaştırılmıştır. Bu karşılaştırmanın sonucunda elde edilen sonuçlar, protez ellerin kontrolüne yönelik EMG sinyallerini ayırtmak ve analiz etmek için yeni bir yöntemin geliştirilmesine olanak sağlamıştır.

EMG sinyallerinin çok kanallı olarak analizini gerçekleştirmek ve farklı kuvvet seviyelerindeki el hareketlerine ait sinyalleri de kullanarak altı farklı hareketi ayırt edebilmek için, özneliklerin geliştirilmesi amaçlanmıştır. Bu sebeple sinyaller ÇDGKA yöntemi ile özgül kip fonksiyonlarına ayrıştırılarak, sinyalin yerel ölçekte her bir salınım modunun analizini yapmak mümkün kılınmıştır. Sinyale ait tüm salınım modları ayrı ayrı öznelik çıkarmak için kullanılmıştır. Ayrıca farklı salınım modları arasında meydana gelebilecek mod karışımından kaçınıldığı ve kanallar arası mod hizalamasının düzgün bir şekilde gerçekleştirildiği gözlemlenmiştir.

ÇDGKA yönteminin, sinyalin uzunluğuna göre farklı sayıda ÖKF çıkarması sebebiyle, sinyalin lokal bilgilerini kaybetmeden uygun uzunluktaki sinyali seçmek için EMG gerekli minimum ÖKF sayısı tespit edilerek işlem hızlandırılmıştır. ÖKF'lerin her birinden öznelikler çıkarılmıştır. Bu şekilde genel bir şablon oluşturularak, ÇDGKA yönteminin gerçek zamanlı uygulamalarda, her işleme aşamasında sinyale ait en uygun ÖKF'lerin belirlenmesine yönelik işlem yoğunluğundan kaçınılması amaçlanmıştır. ÇDGKA tabanlı öznelikler ile sınıflandırılan farklı kuvvet seviyelerindeki çok kanallı sEMG sinyalleri, ham sinyal tabanlı özneliklere göre senaryo 1 için %10-%15, senaryo 2 için %18'e kadar üstünlük sağlamıştır.

Sonuç olarak ÇDGKA yöntemi tabanlı özneliklerin işlevselliği sınıflandırma performansı açısından gösterilmiştir.

Bu özneliklerin, ham sinyal tabanlı özneliklere sağladığı üstünlük açıkça gösterilmiştir. Fakat bu üstünlüğe rağmen ÇDGKA yöntemi tabanlı öznelik çıkarma yönteminin, halen geliştirilmeye ihtiyacı olduğu görülmektedir. Bunun yanında gerçek zamanlı uygulamalara yönelik hesaplama yükünün azaltılması için de çalışmalara ihtiyaç vardır. Böylelikle akıllı el protezlerinin güvenilirliğinin artırılması ve geleceğe yönelik olarak bu protezlerin, ampute bireyler için uzuv kayıplarının eksikliğini temin etmesi umulmaktadır.

#### V. TEŞEKKÜR

Bu çalışma Bursa Teknik Üniversitesi Bilimsel Araştırma Projeleri 182L21 numaralı yüksek lisans tez

projesi ile desteklenmiştir.

## KAYNAKLAR

- [1] Bright, D., Nair, A., Salvekar, D., & Bhisikar, S. (2016). EEG-based brain controlled prosthetic arm. In *Conference on Advances in Signal Processing, CASP 2016*.
- [2] Barea, R., Boquete, L., Mazo, M., Lopez, E., & Bergasa, L. M. (2000). EOG guidance of a wheelchair using neural networks. *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*.
- [3] Hakonen, M., Piitulainen, H., & Visala, A. (2015). Current state of digital signal processing in myoelectric interfaces and related applications. *Biomedical Signal Processing and Control, 18*, 334–359.
- [4] Bock, O. (2006). Myoelectric Control Of Powered Upper- Limb Prostheses.
- [5] Stashuk, D. (2001). EMG signal decomposition: How can it be accomplished and used. *Journal of Electromyography and Kinesiology, 11*(3), 151–173.
- [6] Hargrove, L. J., Englehart, K., & Hudgins, B. (2007). A comparison of surface and intramuscular myoelectric signal classification. *IEEE Transactions on Biomedical Engineering, 54*(5), 847-853
- [7] Al-Timemy, A. H., Khushaba, R. N., Bugmann, G., & Escudero, J. (2016). Improving the Performance Against Force Variation of EMG Controlled Multifunctional Upper-Limb Prostheses for Transradial Amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering, 24*(6), 650–661.
- [8] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, Zheng. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 454*(1971), 903–995.
- [9] Rehman, N., & Mandic, D. P. (2010a). Multivariate empirical mode decomposition. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 466*(2117), 1291–1302.
- [10] Altamirano, A. A. (2017). EMG Pattern Prediction for Upper Limb Movements Based on Wavelet and Hilbert-Huang Transform. (Doctoral dissertation, Université de Lorraine; Instituto Politécnico Nacional (México)).
- [11] Phinyomark, A., Quaine, F., Charbonnier, S., Serviere, C., Tarpin-Bernard, F., & Laurillau, Y. (2013). EMG feature evaluation for improving myoelectric pattern recognition robustness. *Expert Systems with applications, 40*(12), 4832-4840.
- [12] Sapsanis, C., Georgoulas, G., Tzes, A., & Member, S. (2013). A. EMG Data Collection, 716–722
- [13] Ruiz-Olaya, A. F., & Lopez-Delis, A. (2013). Surface EMG signal analysis based on the empirical mode decomposition for human-robot interaction. In *Symposium of Signals, Images and Artificial Vision - 2013, STSIVA 2013*.
- [14] Sapsanis, C., Georgoulas, G., Tzes, A., & Lymberopoulos, D. (2013). Improving EMG based Classification of basic hand movements using EMD. *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 5754–5757*.
- [15] De Luca, C. J., Donald Gilmore, L., Kuznetsov, M., & Roy, S. H. (2010). Filtering the surface EMG signal: Movement artifact and baseline noise contamination. *Journal of Biomechanics, 43*(8), 1573–1579.
- [16] Myers, L. J., Lowery, M., O'Malley, M., Vaughan, C. L., Heneghan, C., St. Clair Gibson, A., Sreenivasan, R. (2003). Rectification and non-linear pre-processing of EMG signals for cortico-muscular analysis. *Journal of Neuroscience Methods, 124*(2), 157–165.