

EMG işaretlerini dalgacık dönüşümü ve bulanık mantık sınıflayıcı kullanarak sınıflama

Yücel KOÇYİĞİT*, Mehmet KORÜREK

İTÜ Elektrik-Elektronik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü, 34469, Ayazağa, İstanbul

Özet

Deri yüzeyinde algılanan elektromiyografik (EMG) işaretleri, kas liflerinin kasılması sonucu oluşan çok sayıda aksiyon potansiyellerin birleşimidir. Şimdiye kadar biyomedikal mühendisliğinde çeşitli uygulama alanları bulmuştur. Bu uygulamalardan biri de protez kontrolüdür. Bu çalışmanın hedefi, öznelik çıkartma yöntemi olarak zaman-frekans domeni analiz yöntemlerini kullanarak protez koluna ait dört farklı hareket için EMG işaretlerini daha iyi sınıflamayı gerçekleştirmektir. Bunun için boyut azaltma ve bulanık sınıflama yöntemleri de incelenmiştir. Sınıflama problemi öznelik çıkartma, boyut azaltma ve örüntü sınıflama aşamalarına ayrılır. Dalgacık dönüşümü öznelik çıkartma yöntemi olarak büyük üstünlük sağlar. Özneliklerin çıkartma aşamasında yüksek boyuta sahip olmalarından dolayı sınıflama başarısı, Ana Bileşenler Analizi (ABA) ve Bağımsız Bileşenler Analizi (BBA) gibi uygun boyut azaltma yöntemleriyle gerçekleştirilebilir.

Anahtar Kelimeler: Yüzey elektromiyografik işaret, dalgacık dönüşümü, bulanık öbekleştirme, boyut azaltma, işaret sınıflama.

EMG signal classification using wavelet transform and fuzzy logic classifier

Abstract

The electromyographic (EMG) signal observed at the surface of the skin is the sum of thousands of small potentials generated in the muscle fibers. After this signal are processed it can be used as a control source of artificial limbs. The objective of this work is to achieve better classification for four different movement of a prosthetic limb making an analysis of time-frequency domain methods as a feature extraction tools in the problem of the EMG signal while investigating the related dimensionality reduction and fuzzy classification methods. The classification problem may be divided into the stages of feature extraction, dimensionality reduction, and pattern classification. It is shown that wavelet transform (WT) provide a powerful framework for feature extraction. Because of high dimension of features at the extraction stage, the success of classification can be achieved by employing suitable dimensionality reduction methods which are Principal Component Analysis and Independent Component Analysis outperform WT features. The other stage is the pattern classification in which fuzzy clustering methods and artificial neural networks (ANN) are used. The clustering methods are used to obtain membership values of the EMG signals for each class or cluster. The values are necessary during the classification stage. As classifier, Fuzzy K-Nearest Neighbor classifier is used. ANN are used to compare these methods as classifier.

Keywords: Surface electromyographic signal, wavelet transform, fuzzy clustering, dimensionality reduction, signal classification.

*Yazışmaların yapılacağı yazar: Yücel KOÇYİĞİT. yucel@ehb.itu.edu.tr ; Tel: (212) 285 66 35.

Bu makale, birinci yazar tarafından İTÜ Elektrik-Elektronik Fakültesi'nde tamamlanmış olan "Çok fonksiyonlu kol protezleri için EMG işaret işleme" adlı doktora tezinden hazırlanmıştır. Makale metni 15.04.2004 tarihinde dergiye ulaşmış, 09.06.2004 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.10.2005 tarihine kadar dergiye gönderilmelidir.

Giriş

Deri yüzeyinde algılanan EMG işaretleri, kas liflerinin kasılması sonucu oluşan çok sayıda aksiyon potansiyellerin birleşimidir. Biyomedikal mühendisliğinde çeşitli uygulama alanlarında kullanılmıştır. Bu uygulamalardan biri de protez kontrolüdür. Farklı görevleri yapan bir kastan üretilen her EMG işaretinin tek bir örüntüsü vardır. Bu örüntü hareketin yönü ve eylemin hızı hakkında bilgi içerir. Protezleri başarıyla denetleyebilmek için bu örüntülerin doğru sınıflanması esastır.

Örüntü tanıma sistem tasarımı birçok aşamalardan oluşur: veri toplama, örüntü sınıflarının formasyonu, öznitelik seçimi, sınıflama algoritmasının belirlenmesi ve sınıflama hatasının kestirimi. Önemli adımlar öznitelik seçimi ve sınıflayıcı tasarımıdır. İyi sınıflayıcının özelliği, örneklerden öğrenilebilir ve güncellenebilir ve tüm bilgiyi kapsayabilir olması gerekir. Sınıflayıcı tasarımı için sezgisel yaklaşım, deterministik yaklaşım, istatistiksel yaklaşım, yapay sinir ağları yaklaşımı ve bulanık yaklaşım gibi pek çok yöntem vardır. Sezgisel yaklaşım ve deterministik yaklaşım deneysel olarak sınırlı uygulamalara sahiptir. İstatistiksel yaklaşım, konunun matematiksel modeline gereksinim duyar. Yapay sinir ağları (YSA), sınıflar arası karmaşık ama katı sınırlar üretmek için örneklerden öğrenir ve bu yüzden bazı problemlere neden olurlar. Bulanık mantık insan akıl yürütmesine benzemeye çalışır.

EMG işaretlerini sınıflamak için bugüne kadar değişik çalışmalarda farklı öznitelikler kullanıldı: Zaman domeni öznitelikleri (Hudgins vd., 1993), özbağlanım (AR) katsayıları (Doerschuk vd., 1983; Graupe vd., 1985; Karlık vd., 1994; Asres vd., 1996), cepstral katsayılar (Kang vd., 1995), dalgacık dönüşümü katsayıları (Englehart vd., 2001). Ayrıca, bu alanda, farklı sınıflama yöntemleri kullanıldı: Yapay sinir ağları (Kelly vd., 1990; Hudgins vd. 1993; Karlık vd, 1994), bulanık mantık (Chan vd., 2000). EMG işareti durağan olmayan bir işarettir. Yani, bu işaretler Fourier Dönüşümü gibi klasik yöntemlerle analiz edilemez. Kısa-zaman Fourier Dönüşümü, durağan olmayan işaretlerde durağanlık koşulunu sağlamasına rağmen işaret için uygun segment

uzunluğunun seçilmesi, performansı oldukça etkiler. Dalgacık Dönüşümü, bu sorunun üstesinden gelmek için bir öznitelik çıkartma yöntemi olarak kullanılır (Englehart vd., 2001).

Biyolojik işaretlerin her zaman tekrarlanabilir olmaması ve bazen beklenenin dışında da özellikler göstermesi nedenleriyle bulanık mantık sistemleri biyomedikal işaret işleme ve sınıflama da kullanılır. Ayrıca, eğitilebilir bulanık sistemini kullanarak verideki, kolaylıkla saptanamayan, örüntüleri keşfetme olanağı vardır (Chan vd., 2000). Medikal verileri ifade etmek bulanık öbekleştirme için faydalı bir alandır. Çünkü biyolojik sistemler son derece karmaşıktır ve sınıflar arası sınırlar keskin değildir. Özniteliklerin sınıflara göre üyelikten üye olmaya geçişi ani değil derecelidir (Del Boca vd.,1994).

Bu çalışmada, kola ait dirsek açma, dirsek kapama, ön kolu içe döndürme ve ön kolu dışa döndürme hareketlerinden oluşan dört sınıf kullanıldı. Dört sınıfın EMG işaretleri, kolun biceps ve triceps kaslarından iki kanallı olarak elde edilmiş ve her kanal 1000 Hz de örneklenmiş 256 örnekten oluşmuştur.

Ayrık dalgacık dönüşümü kullanılarak öznitelik çıkartma işlemi gerçekleştirildi. Öznitelik çıkartma için kullanılan zaman-frekans yöntemleri bazen orijinal işaretin veri sayısından bile çok büyük sayıda katsayılar üretmektedir. Bu durumda boyut azaltma yöntemlerine gereksinim vardır; bundan dolayı literatürde sıkça kullanılan Ana Bileşenler Analizi (ABA) ve son yıllarda öne çıkan Bağımsız Bileşenler Analizi boyut azaltma yöntemi olarak denendi. Sınıflamak için ise Bulanık C-Ortalama (BCO) Yöntemi, Gustafson-Kessel (GK) Yöntemi, Bulanık Olabilirlik C-Ortalama (BOCO) Yöntemi ve Bulanık K-En Yakın Komşu Sınıflayıcısı (BKEYK) kullanıldı (Şeker, 1995). BCO, GK ve BOCO öznitelikleri eğitmek üyelik değerlerini bulmak için kullanılırken BKEYK ile yeni öznitelikler test edildi.

Ayrık dalgacık dönüşümü

Dalgacık Dönüşümü, işaretleri analiz etmek için kullanılan tekniklerden birisidir. Kısa-Zaman

Fourier Dönüşümünün (KZFD) frekans ve zaman çözünürlüğündeki sorununun üstesinden gelmek için alternatif bir teknik olarak geliştirildi. Daha açıkçası, KZFD'nin tüm frekanslardaki uniform zaman çözünürlüğüne karşılık, Ayrık Dalgacık Dönüşümü (ADD), yüksek frekanslarda yüksek zaman çözünürlüğü ve düşük frekans çözünürlüğü, alçak frekanslarda ise yüksek frekans çözünürlüğü ve düşük zaman çözünürlüğünü sağlar.

ADD, Dalgacık Dönüşümünün özel bir durumudur ve işaretin, zaman ve frekans domeninde verimli olarak işlenmesini sağlar. ADD aşağıdaki denklemle ifade edilir:

$$W(j, k) = \sum_j \sum_k x(k) 2^{-j/2} \psi(2^{-j} n - k) \quad (1)$$

Burada $x(n)$, işaret ve $\psi(t)$, ana dalgacıktır. ADD analizi, çok frekanslı süzgeç bankalarıyla ilişkili hızlı, piramidal algoritmalar kullanılarak yapılabilir.

ADD işareti, kaba bir yaklaşıklık (approximate) ve ayrıntı (detail) katsayılarına ayrıştırarak işareti farklı frekans bantlarında farklı çözünürlüklerde analiz eder.

İşareti farklı frekans bantlarına ayrıştırmak, zaman domeni işaretini ard arda yüksek ve alçak geçiren süzgeçlerden geçirerek sağlanır. Bu bir seviyeli ayrıştırma işlemidir ve matematiksel olarak şöyle ifade edilebilir:

$$\begin{aligned} y_{yüksek}[k] &= \sum_n x[n]g[2k - n] \\ y_{alçak}[k] &= \sum_n x[n]h[2k - n] \end{aligned} \quad (2)$$

Burada $y_{yüksek}(k)$ ve $y_{alçak}(k)$, 2 ile alt-örnekleme ardından sırasıyla yüksek geçiren(g) ve alçak geçiren (h) süzgeç çıkışlarıdır.

Bir seviyeli ayrıştırma işlemi sonrasında, tüm işaret yarı sayıda örnek ile temsil edildiğinden zamanda çözünürlük de yarıya iner. Buna rağmen frekansta çözünürlük artar, çünkü elde

edilen işaretin kapsadığı frekans bandı bir üst seviyedeki işaretin frekans bandının yarısıdır. Böylece frekanstaki belirsizlik yarı yarıya azalmış olur. Yüksek frekanslarda iyi zaman çözünürlüğü, alçak frekanslarda ise iyi bir frekans çözünürlüğü elde edilir. Altbant kodlama olarak da bilinen bu işlemler arzu edildiğinde işarete art arda uygulanabilir. Literatürde farklı dalgacık tipleri önerilmiştir. Bu çalışmada, Daubechies, Symlet, Coiflet, Biortogonal dalgacık tipleri kullanılarak dalgacık dönüşümü katsayıları MATLAB ile elde edilmiştir.

Boyut azaltma

Çıkartma aşamasında özniteliklerin yüksek boyuta sahip olmalarından dolayı sınıflama başarısı, Ana Bileşenler Analizi (ABA) ve Bağımsız Bileşenler Analizi (BBA) gibi uygun boyut azaltma yöntemleriyle gerçekleştirilebilir.

Öznitelik izdüşümünü göstermek için kullanılacak yöntem Ana Bileşenler Analizi ('Principal Component Analysis, PCA') dir. Karhunen Loeve Dönüşümü olarak da adlandırılan bu yöntem veride bulunan varyansları en iyi gösteren sistemleri araştırır. Zaman-frekans sunumu, yüksek boyutlu öznitelik uzayında dağılmış bilgi verir. Bu durumda ABA'nın, zaman-frekans sunumuna dayalı öznitelik vektörleri açısından boyut azaltma yöntemi olarak üst seviyede etkili bir teknik olduğu gösterilebilir (Englehart,1998).

Bağımsız Bileşenler Analizi ('Independent Component Analysis, ICA'), herhangi çok değişkenli veride doğrusal olan ancak ortogonal olmayan koordinat sistemini bulmaya çalışır ve giriş verisinin eksenler üzerine izdüşümleri arasındaki karşılıklı bilgiyi minimize eder (Hyvärinen vd., 2000). Bu koordinat sistemindeki eksenlerin yönü, orijinal verideki hem ikinci dereceden hem de daha yüksek dereceden istatistiklerle belirlenir. BBA'nın hedefi, öyle bir doğrusal dönüşüm yapmaktır ki kaynak çıkışları mümkün olduğu kadar birbiri ile istatistiksel olarak bağımsız olsun. BBA için kullanılan değişik algoritmalar vardır. Burada FastICA algoritması kullanıldı (FastICA).

Bulanık algoritmalar

Bir elemanın bir kümeye veya bir sınıfa ait olması klasik küme kavramında ya aittir (üyelik=1) veya ait değildir (üyelik=0) şeklinde karşımıza çıkar. Gerçekte bir eleman bir kümeye ne tam aittir ne de değildir. Yani bu elemanın o küme veya sınıf için bir aittik derecesi (üyelik değeri) olmalıdır. Bu da Bulanık tabanlı algoritmalarla mümkün olmaktadır. Bu üyelik değeri 0 ile 1 arasında sonsuz değer alabilmektedir. Bulanık algoritmalarda, bir işaret öbekleştirilirken veya sınıflandırırken işaretin sınıfını belirlemenin yanında o sınıfa ne kadar ait olduğuna dair bir bilgi de verilmektedir. Bu bilgi, işaretin o sınıfa olan üyelik değeri olmaktadır. Buradan, bulanık algoritmaların, klasik algoritmalarından daha fazla bilgi içerdiği sonucuna varılabilir.

Öbekleştirme eğitimsiz bir yöntemdir. Eğitimsiz yaklaşımlar, verinin yapısını kendisi düzenler ve öznitelik uzayının öbekleşmesini, eğitimcinin eğitim bölgelerini belirlemesinden bağımsız yapar. Öbekleştirme yöntemlerini yarı-durağan koşullarda sürekli örneklenen ölçümlere uygulamak, örüntülerle ilişkili ayrı ayrı gruplar ve yeni öbek oluşturmak için faydalıdır. Giriş örüntüleri zaman serileri olduğu için aynı sonuçları verecek olayların benzer serileri birlikte öbekleşecektir. Özel bir zaman noktasına odaklanmayan ve genellikle belirsiz bir durağan durumdan diğerine geçişler, doğal olarak bulanık öbekleştirme anlamında davranır. Bu gibi durumlarda öbek sayısının adaptif seçimi, biyomedikal işaretlerin genel durağan olmayan yapısının üstesinden gelebilir.

Bulanık c-ortalama yöntemi

C, sınıf sayısı; n, veri sayısı; k, veri indisi; i, sınıf indisi; m, bulanıklığı artırıcı kontrol parametresi [$m \in (1, \infty)$]; D_{ki} , k. eleman vektörünün i. sınıfa olan Euclidean uzaklığı; v_i , sınıf merkezi olmak üzere sınıflara olan üyelikler:

$$v_i = \frac{\sum_{k=1}^n (u_{ki})^m x_k}{\sum_{k=1}^n (u_{ki})^m} \quad (3)$$

$$D_{ki}^2 = (x_k - v_i)^T (x_k - v_i) \quad (4)$$

$$u_{ki} = \frac{1}{\sum_{j=1}^C \left[\frac{D_{ki}}{D_{kj}} \right]^{\frac{2}{m-1}}} \quad \begin{cases} k = 1, 2, \dots, n \\ i = 1, 2, \dots, C \end{cases} \quad (5)$$

BCO öbekleştirme yönteminin algoritması şu şekildedir:

- 1.Adım: Başlangıç değerlerini belirle (u üyelik değerleri, c sınıf-grup sayısı, ε hata değeri, i iterasyon sayısı).
- 2.Adım: Bulanık grup merkezlerini her grup için (3) hesapla
- 3.Adım: (4) ifadesini kullanarak herbir öznitelik vektörü için Euclidean Uzaklığını hesapla.
- 4.Adım: Yeni üyelik değerlerini (5) ifadesi ile hesapla.
- 5.Adım: Yeni üyelik değerleri ile eski üyelik değerlerini karşılaştır. Eğer $\|u_{\text{yeni}} - u_{\text{eski}}\| \leq \varepsilon$ ise dur. Aksi halde yeni üyelik değerleri ile 2.Adıma git ($i=i+1$).

Gustafson-Kessel yöntemi

Bulanık c-Ortalama algoritmasında Euclidean uzaklığı yerine sadece dairesel değil elipsoidal öbekleri de tanımlayan Mahalanobis uzaklığı koyularak elde edilir.

Kf_i , Bulanık Kovaryans Matrisi ve D_{ki} , k. eleman vektörünün i. sınıfa olan Mahalanobis uzaklığı şöyle ifade edilir:

$$Kf_i = \frac{\sum_{k=1}^n (u_{ki})^m (x_k - v_i)(x_k - v_i)^T}{\sum_{k=1}^n (u_{ki})^m} \quad (6)$$

$$D_{ki}^2 = (x_k - v_i)^T Kf_i^{-1} (x_k - v_i) \quad (7)$$

Algoritma şu şekildedir:

- 1.Adım: Başlangıç değerlerini belirle (u üyelik değerleri, c sınıf-grup sayısı, ε hata değeri, i iterasyon sayısı).
- 2.Adım: Bulanık grup merkezlerini her grup için (3) hesapla

3.Adım: Bulanık kovaryans matrisini her grup için (6) hesapla.

4.Adım: (7) ifadesini kullanarak herbir öznitelik vektörü için Bulanık Mahalanobis Uzaklığını hesapla.

5.Adım: Yeni üyelik değerlerini (5) ifadesi ile hesapla.

6.Adım: Yeni üyelik değerleri ile eski üyelik değerlerini karşılaştır. Eğer $\|u_{\text{yeni}}-u_{\text{eski}}\| \leq \varepsilon$ ise dur. Aksi halde yeni üyelik değerleri ile 2.Adıma git ($i=i+1$).

Bulanık olabilirlik c-ortalama yöntemi

Üyelik değerlerinin toplamının *bir* olduğu BCO algoritmasında öyle bazı öznitelik vektörleri çıkmaktadır ki bunların her bir sınıfa olan uzaklıkları eşittir. Uzaklıkları eşit olması, bu öznitelik vektörlerinin her birinin üyelik değerlerinin eşit olmasına neden olmaktadır. Bu yöntem işaret sınıflamada kısıtlayıcı bir durum olan üyelik değerlerinin 1'e eşit olması halini gidermekte ve daha esnek, daha iyi bir çözüm getirmektedir. Ayrıca bu yöntem uzaklıkların eşit olması, yani üyelik değerlerinin eşit olması gibi kararsızlığa neden olan bir durumda işaret sınıfını karakterize eden η_i değeri ile sonuca gitmeye imkan tanımaktadır.

GK yönteminden tek farkı üyelik hesabıdır. Algoritmada farklı olarak (8), (9) ifadeleri kullanılacaktır.

$$u_{ki} = \frac{1}{1 + \left(\frac{d_{ik}^2}{\eta_i}\right)^{\frac{1}{m-1}}} \quad (8)$$

$$\eta_i = \frac{\sum_{k=1}^n (u_{ki})^m D_{ki}^2}{\sum_{k=1}^n (u_{ki})^m} \quad \left| \begin{array}{l} h_i > 0 \\ m > 1 \text{ (m=2)} \end{array} \right. \quad \left. \begin{array}{l} \sum_{i=1}^c u_{ki} \neq 1 \\ u_{ki} \leq 1 \end{array} \right. \quad (9)$$

Bulanık K-en yakın komşu sınıflayıcısı

Bulanık K-En Yakın Komşu sınıflayıcısında, etiketlenmemiş bir x öznitelik vektörünün, etiketlenmiş x_{ji} öznitelik vektörlerinden her birine olan Euclidean uzaklıkları ifadesi;

$$d_{ji}^2 = (x - x_{ji})^T (x - x_{ji}) \quad \begin{array}{l} i=1,2,\dots,c \\ j=1,2,\dots,n \end{array} \quad (10)$$

ile gösterilir.

Keskin kümelerde, öznitelik vektörü uzaklıkları küçükten büyüğe doğru sıralanır; bunlardan K adedi seçilir ve etiketlerine bakılır. Etiketler en çok hangi sınıfa ait ise x işareti o sınıfa sınıflanır.

Bulanık kümelerde ise sınıflama işlemi, bilinmeyen bir işareti sınıflamaktan çok işaretin o sınıfa ne kadar ait olduğu sorusuna cevap verir.

x işaretinin i . sınıfa üyeliği; u_{ki} , K adet etiketlenmiş işaretin i . sınıfa üyeliği olmak üzere;

$$u_{xi} = \sum_{k=1}^K \frac{u_{ki}}{K} \quad ; \quad i = 1,2,\dots,C \quad (11)$$


ile ifade edilir.

Sonuçlar


Çalışmada farklı bulanık yöntemler kullanılarak elektromiyografik işaretlerin sınıflandırılması yapılmaya çalışılmıştır. BK-EYK sınıflayıcısının $K=5$ komşuluğu için BCO, GK ve BOCO yöntemlerinin başarı yüzdeleri Şekil 1'de verilmiştir. Şekildeki başarı yüzdeleri, üç ayrı denekten elde edilen EMG işaretlerinin her biri için bulunan başarı yüzdelerinin ortalamasıdır.

Dalgacıkların sadece kendileri üstün başarı göstermedikleri boyut azaltma ve izdüşüm yöntemlerinin de sınıflama başarısına büyük katkısı olduğu görülmektedir. BBA, ABA'dan genelde en az %2-3 oranında daha başarılı çıkmıştır.


Yöntemler içinde BCO yönteminin dalgacık tiplerinin genelinde daha başarılı olduğu görülmektedir ve en büyük ortalama başarı yüzdesi BBA boyut azaltma yönteminin katkısıyla **Daubechies** 5,7,8 dalgacık tiplerine (%98.2) aittir.



(a)



(b)



(c)

Şekil 1. $K=5$ için tüm dalgacık tiplerine göre (a) BCO algoritmasının, (b) GK algoritmasının, (c) BOCO algoritmasının BK-EYK sınıflayıcısı ile ortalama başarı yüzdeleri

Sonuçların ışığı altında, elimizdeki EMG işaretleri için en uygun bulanık algoritmanın, öbikleştirme yaparken Euclidean uzaklığını kullanan Bulanık c-Ortalamlar algoritması olduğu sonucuna varılmıştır. Bulanık öbikleştirme yöntemleri eğitimsiz yöntemler oldukları için öbeklerin tespit edilmesi eğitimcinin eğitim bölgelerini belirlemesinden bağımsız yapar. Üyelik değerlerini tespit etmek için algoritmaların koşturulması farklı denemelerle tekrarlanırsa sınıflama başarısının değiştiği görülür. Öbeklerin değişme olasılığından dolayı her koşturulma da farklı sonuçların bulunması tabiidir.

Kaynaklar

- Asres, A., Dou, H., Zhou, Z., Zhang, Y. ve Zhu, S. (1996). A combination of AR and neural network technique for EMG pattern identification, *18th Annual International Conference of the IEEE Engineering in Medicine And Biology Society*, 1464-1465, Amsterdam.
- Chan, F.H.Y., Yang, Y.S., Lam, F.K., Zhang, Y.T. and Parker, P.A., (2000). Fuzzy EMG classification for prosthesis control, *IEEE Transactions on Rehabilitation Engineering*, **8**, 305-311.
- Del Boca A. Park, D.C., (1994). Myoelectric signal recognition using fuzzy clustering and artificial neural networks in real time, *IEEE World Congress on Computational Intelligence*, **5**, 3098-3103.
- Doerschuk, P.C., Gustafson, D.E. and Willisky, A.S., (1983). Upper extremity limb function discrimination using EMG signal analysis, *IEEE Transactions on Biomedical Engineering*, **30**, 1, 18-29.
- Englehart, K., (1998). Signal representation for classification of the transient myoelectric signal, *Ph. D. Dissertation*, University of New Brunswick, Fredericton, N.B., Canada.
- Englehart, K., Hudgins, B., Parker, P.A., (2001). A Wavelet-based continuous classification scheme for multifunction myoelectric control, *IEEE Transactions on Biomedical Engineering*, **48**, 302-311.
- Geva, A. B., (1997). Dynamic unsupervised fuzzy clustering in forecasting events from biomedical signals, *Ministry of Science, International Conference on Fuzzy Logic and Applications*, Zichron Yaakov, Israel.
- Graupe, D., Salahi, J. ve Zhang, D., (1985). Stochastic analysis of myoelectric temporal signatures for multifunction single-site activation of prostheses and orthoses, *Journal of Biomedical Engineering*, **7**, 1, 18-29.
- Hudgins, B., Parker, P.A. ve Scott, R.N., (1993). A new strategy for multifunction myoelectric control, *IEEE Transactions on Biomedical Engineering*, **40**, 1, 82-94.
- Hyvärinen, A. ve Oja, E., (2000). Independent Component Analysis: Algorithms and Applications, *Neural Networks*, **13**, 411-430.
- Kang, W., Shiu, J., Cheng, C., Lai, L., Tsao, H. ve Kuo, T., (1995). The application of cepstral coefficients and maximum likelihood method in EMG pattern recognition [movements classification], *IEEE Transactions on Biomedical Engineering*, **42**, 777-785.
- Karlık, B., Pastacı, H. ve Korürek, M., (1994). Myoelectric neural networks signal analysis, *Proc. 7th Mediterranean Electrotechnical Conference*, **1**, 262-264, Antalya, Turkey.
- Kelly, M., Parker, P.A. ve Scott, R.N., (1990). The application of neural networks to myoelectric signal analysis: A preliminary study, *IEEE Transactions on Biomedical Engineering*, **37**, 3, 221-227.
- Şeker, H., (1995). Elektromiyografik işaretlerin bulanık sınıflayıcılarla sınıflandırılması, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, İstanbul.

The FastICA MATLAB package.
<http://www.cis.hut.fi/projects/ica/fastica>