

Jiroskop Sinyallerinin İşlenmesiyle Bacak Hareketlerinin Sınıflandırılması

Classification of Leg Motions by Processing Gyroscope Signals

Orkun Tunçel, Kerem Altun, Billur Barshan
Elektrik ve Elektronik Mühendisliği Bölümü
Bilkent Üniversitesi 06800, Bilkent, Ankara
{orkun,kaltun,billur}@ee.bilkent.edu.tr

Özetçe

Bu çalışmada bir deneğin bacağına takılan tek eksenli jiroskop sinyallerinin işlenmesiyle birbirinden farklı sekiz bacak hareketi, örüntü tanıma yöntemleriyle ayırılmıştır. Ayırma işlemi için en küçük kareler, Bayesçi karar verme, k-en yakın komşuluk, dinamik zaman bükmesi, yapay sınır ağları ve destek vektör makinesi yöntemleri kullanılarak bu yöntemlerin başarımları birbirleriyle karşılaştırılmıştır. Yapılan çalışma, ileride daha karmaşık algılayıcılarla gerçekleştirilmesi öngörülen daha kapsamlı hareket ayırma çalışmaları için bir hazırlık niteliği taşımaktadır.

Abstract

In this study, eight different leg motions are classified using two single-axis gyroscopes mounted on the right leg of a subject with the help of several pattern recognition techniques. The methods of least squares, Bayesian decision, k-nearest neighbor, dynamic time warping, artificial neural networks and support vector machines are used for classification and their performances are compared. This study comprises the preliminary work for our future studies on motion recognition with a much wider scope.

1. Giriş

İnsan hareketlerinin tanınması, izlenmesi ve ayırılması alanında son yıllarda birçok araştırma yapılmaktadır. Özellikle yalnız yaşayan ve bakıma muhtaç insanların kendi evlerinde izlenmesinde, geçirdikleri ameliyatlardan sonrasında fiziksel rehabilitasyon gören hastaların iyileşme süreçlerinin takibinde ve fizyoterapi seanslarının hastanın hastaneye gitmesine gerek kalmadan evden yapılmasında hareket tanıma ve ayırma yöntemleri kullanılmaktadır. Bunun dışında sporcu ve dansçıların eğitimleri, ergonomi, animasyon filmlerinin yapımı ve oyun konsolları gibi diğer uygulama alanları da bulunmaktadır.

Son yıllarda mikro-elektromekanik sistemler (MEMS) alanındaki gelişmeler insan hareketlerinin ayırılmasında eylemsizlik duyucularının kullanılmasını yaygınlaştırmıştır. Bu duyucular, düşük donanım ve yazılım maliyetleri ile görüntü işlemeye dayalı hareket tanıma sistemlerine [1] alternatif oluşturmaktadır. Eylemsizlik duyucularının biyomekanik uygulamalarda kullanılması yalnızca hareket tanıma ve ayırma ile sınırlı değildir. Bunun dışında insan bedeninde harcanan enerji seviyesinin ölçülmesi, düşmelerin saptanması,

yürüme analizi gibi yaşam standardını yükseltmeye yönelik uygulamalarda da kullanılabilir. Bu uygulamalar ile ilgili olarak [2, 3, 4] makalelerinde geniş literatür taramalarına ulaşılabilir. Ancak [3], ağırlıklı olarak hareket ayırma yöntemlerinden söz etmektedir.

Hareket ayırma ve diğer biyomekanik uygulamalarda genellikle ivmeölçerler kullanılmaktadır. Birden fazla çeşit duyucu ile (ivmeölçer, mikrofon, pusula, EKG, termometre vb.) yapılan bir çalışmada, hareket tanıma için ivmeölçerlerin en uygun duyucular olduğu gösterilmiştir [5]. İvmeölçerlerle yapılmış çalışmalar ile ilgili bir literatür taraması Kaynak [6]'da bulunabilir. Önceden yapılmış olan çalışmalarda, ivmeölçerler kullanılarak ayakta durma, oturma, yatma, yürüme, merdiven inip çıkma, asansörle inip çıkma, yemek yeme vb. gibi hareketlerin ayırma çalışmaları gösterilmiştir [7]. Literatürde yalnızca jiroskopların kullanıldığı çalışmalar da bulunmasına rağmen [8], jiroskopların hareket ayırma kullanımını ivmeölçerler kadar yaygın değildir.

Bu çalışmada, iki adet tek eksenli jiroskoptan (Murata Gyrostar ENV-05A) [9] elde edilen veriler kullanılarak sekiz farklı bacak hareketi çeşitli örüntü tanıma yöntemleri ile ayırma çalışması yapılmış ve yöntemler birbirleriyle karşılaştırılmıştır.

2. Veri Toplama

Veri toplama aşamasında bir deneğin bacağına biri dizin 17 cm üstünde, diğeri ise 15 cm altında olmak üzere iki adet tek eksenli jiroskop bağlanmıştır. Bu iki jiroskoptan elde edilen açısal dönme hızı sinyalleri paralel port bağlantısı kullanılarak masaüstü bir bilgisayara aktarılmış ve sinyal işleme aşamasında MATLAB kullanılmıştır. Sınıflandırmasını yaptığımız sekiz farklı bacak hareketi şunlardır:

1. dizi mümkün olduğunca hareketsiz tutarak ayakta bekleme (H1)
2. dizi mümkün olduğunca hareketsiz tutarak, bacağın sadece diz kapağının altında kalan kısmını önce arkaya daha sonra da öne doğru hareket ettirme (H2)
3. sağ bacağı dizi kırarak karına doğru çekme (H3)
4. dizi kırmadan sağ bacağı öne doğru kaldırma (H4)
5. dizi kırmadan sağ bacağı geriye doğru atma (H5)
6. sağ bacağı dizi kırmadan yana doğru kaldırma (H6)

7. çömelme (H7)

8. oturur pozisyonunda iken sağ bacağı kaldırma (bacağın sadece diz altında kalan kısmı hareket etmektedir) (H8)

Denek, her bir hareketi farklı zamanlarda 8'er kez yaklaşık 72'er saniye boyunca tekrarlı olarak yapmıştır. Her iki jiroskoptan alınan sinyaller (yaklaşık 12 s) 6 eşit parçaya bölünerek, her bir hareket için, her iki jiroskoptan da 48'er olmak üzere toplam 96 adet sinyal elde edilmiştir.


3. Hareket Ayırdetme

Her bir hareket için elde edilen sinyallerden 48 adet öznitelik vektörü oluşturulmuştur. Önceki çalışmalarda bakıldığında, sınıflandırma ve ayırdetme için kullanılan özniteliklerde herhangi bir standart bulunmadığı görülmektedir. Bazı çalışmalarda ortalama değer, değişinti, gradyan, bant genişliği vb. özniteliklerin kullanılması önerilmekle birlikte [5], 160 adet öznitelik arasından deneme-yanılma yoluyla özniteliklerin seçildiği çalışmalar da mevcuttur [10]. Bu çalışmada, sinyallerin 1., 3. ve 4. momentleri, en küçük ve en büyük değerleri, özilinti sinyalinin sıfır noktasındaki değeri (değişinti), özilinti sinyali üzerinde belirli ve eşit aralıklarla seçilmiş 10 tane örnek nokta olmak üzere 16 adet öznitelik kullanılmıştır. Bu değerler her iki jiroskop için hesaplandığından, her bir öznitelik vektörü 32 adet bileşenden oluşmaktadır. Her bileşenin değeri, aşağıdaki şekilde normalize edilerek $[0, 1]$ aralığına taşınmıştır:

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Bu denklemde x'_i taşınmış öznitelik değerini, x_i orjinal öznitelik değerini, x_{max} ve x_{min} ise sırasıyla en büyük ve en küçük öznitelik değerlerini belirtmektedir.

Daha sonra asal bileşenler analizi yöntemi ile sınıflandırmada kullanılan öznitelikler azaltılmıştır. Asal bileşenler analizi yöntemi, sınıflar arasındaki ayrımı dikkate almadan, öznitelik vektörlerini, yayılımın daha rahat gözlemlenebildiği bir alt uzaya taşımaktadır. Bunun için öznitelik vektörlerinin kovaryans matrisinin özdeğerleri ve özvektörleri kullanılmaktadır. Bu özdeğerlerin büyükten küçüğe sıralandıktan sonraki grafiği Şekil 1'de verilmiştir. Bu şekilden de gözlemlenebildiği gibi, matrisin ilk birkaç özdeğerini ve karşılık gelen özvektörleri kullanarak öznitelikleri daha düşük boyutlu bir uzaya fazla veri kaybı olmadan indirgemek mümkündür. Bu çalışmada en büyük 9 özdeğer seçilerek özniteliklerin sayısı 9'a indirilmiştir.



Şekil 1: Kovaryans matrisinin özdeğerleri.

Bu hareketlerin ayırıldı ve sınıflandırılmasında en küçük kareler, Bayeşçi karar verme, k -en yakın komşuluk, dinamik zaman bükmesi, yapay sinir ağları ve destek vektör makinesi

yöntemleri kullanılmıştır. Bu yöntemlerle elde edilen sonuçlar aşağıda sunulmaktadır. Verilen karışıklık matrislerinde satırlar yapılan hareketleri, sütunlar ise ayırıldı hareketleri göstermektedir.

3.1 En Küçük Kareler Yöntemi

Her bir hareket için ayrı ayrı ve rasgele seçilmiş olan 24'er tane öznitelik vektörünün ortalaması alınarak 8 farklı hareket için birer tane eğitim vektörü elde edilmiştir. Bir sonraki adım olan deneme aşamasında, her bir deneme vektörü, 8 eğitim vektörüyle Denklem (2) kullanılarak karşılaştırılmıştır. Bu denklemde $x = [x_1, x_2, \dots, x_N]$ eğitim vektörünü, $y = [y_1, y_2, \dots, y_N]$ de deneme vektörünü belirtmektedir. En küçük hatayı (\mathcal{E}) veren eğitim vektörünün sınıfı (hareket) deneme vektörünün sınıfı olarak atanmıştır. Bu yöntem kullanılarak elde edilen doğru hareket ayırdetme yüzdesi % 92.3'tür (Tablo 1).

$$\mathcal{E} = \sum_{n=1}^N (x_n - y_n)^2 = (x_1 - y_1)^2 + \dots + (x_N - y_N)^2 \quad (2)$$

Tablo 1: En küçük kareler yöntemi karışıklık matrisi.

	H1	H2	H3	H4	H5	H6	H7	H8
H1	23	0	0	0	0	1	0	0
H2	0	22	0	0	0	0	0	2
H3	0	0	23	0	0	0	1	0
H4	0	0	0	21	1	0	2	0
H5	0	0	0	1	21	0	2	0
H6	0	0	0	0	0	24	0	0
H7	0	0	1	0	3	0	20	0
H8	0	1	0	0	0	0	0	23

3.2 Bayeşçi Karar Verme Yöntemi

Bu yöntemde, her hareket için elde edilmiş olan 48 öznitelik vektöründen rasgele 24'ü eğitim vektörü olarak seçilmiştir. Daha sonra bu öznitelik vektörleri normal dağılımlı bir rastlantısal vektörün aldığı farklı değerler olarak varsayılmış, dağılımın ortalama değer vektörü ve kovaryans matrisi en büyük olabirlik kestirim yöntemi kullanılarak bulunmuştur. Bu şekilde her hareket için ayrı bir normal dağılım fonksiyonu elde edilmiştir. Daha sonra herhangi bir öznitelik vektörü verildiğinde, vektörün bu fonksiyonlar için değerleri bulunup, vektör en büyük değeri veren fonksiyonun sınıfına ait olacak şekilde sınıflandırılmıştır. Bu sınıflandırma hem her hareket için seçilmiş olan eğitim vektörleri için, hem de geri kalan deneme vektörleri için yapılmıştır. Bu yöntemle eğitim vektörleri için başarı oranı % 100, deneme vektörleri için ise % 96.9 olarak elde edilmiştir (Tablo 2).


3.3 k -En Yakın Komşuluk Yöntemi

Her bir deneme vektörünün, Öklit uzaklığı kullanılarak daha önceden rasgele seçilmiş olan toplam $24 \times 8 = 192$ tane eğitim vektörüne uzaklığı hesaplanmıştır. Sonrasında, bu deneme vektörünün k en yakın komşusunun ait oldukları sınıflara bakılmış ve hangi sınıftan en çok sayıda vektör varsa deneme vektörünün sınıfı bu sınıf olarak atanmıştır. Bu yöntemin başarı sağlayabilmesi için seçilecek olan k değeri önem taşımaktadır. k parametresinin seçimi şu örnekle açıklanabilir:

Şekil 2'de kare ile gösterilen vektörün elmas ile mi yoksa yıldız ile mi gösterilen sınıfa ait olduğuna karar verilmesi istenmektedir. İlk etapta k parametresi 4 olarak seçilirse, karenin

Tablo 2: Bayeşçi karar verme yöntemi deneme vektörleri için karışıklık matrisi.


	H1	H2	H3	H4	H5	H6	H7	H8
H1	23	0	0	0	0	1	0	0
H2	0	24	0	0	0	0	0	0
H3	0	0	24	0	0	0	0	0
H4	0	0	0	23	1	0	0	0
H5	0	0	0	1	23	0	0	0
H6	0	0	0	0	0	24	0	0
H7	0	0	1	0	0	0	23	0
H8	0	2	0	0	0	0	0	22



Şekil 2: k -en yakın komşuluk yöntemi.

en yakınındaki 4 tane vektörün ait oldukları sınıflar gözönünde bulundurulacak ve bu vektörlerden 3 tanesi yıldız ile gösterildiği için de kare ile gösterilen vektörün sınıfı yıldız ile gösterilen vektörlerin sınıfı olarak atanacaktır. k parametresi değiştirilip de 12 olarak alınırsa en yakın 12 komşudan 7'si elmas 5'i de yıldız ile gösterilen vektörler olacaktır. Bu durumda kare ile gösterilen vektörün sınıfı elmas ile simgelemiş olan vektörlerin sınıfıyla aynı olacaktır.

Bu çalışmada $k = 1, 2, \dots, 24$ değerleri için k -en yakın komşuluk yöntemi denenmiş ve başarı yüzdelerinin grafiği Şekil 3'te verilmiştir. Şekilden de gözlemlenebileceği gibi, $k = 1, \dots, 4$ değerleri için başarı oranı % 95'in üzerindedir. $k = 1$ için karışıklık matrisi de Tablo 3'de bulunabilir.



Şekil 3: Değişik k değerleri için elde edilen başarı yüzdeleri.

3.4 Dinamik Zaman Bükmesi Yöntemi

Herhangi bir hareket için elde tutulan $1 \times N$ boyutundaki eğitim vektörünün bütün elemanları ile $1 \times M$ boyutundaki deneme vektörünün bütün elemanları arasındaki Öklit uzaklığı hesaplanmış, bu uzaklıklar $N \times M$ büyüklüğündeki bir D matrisine yerleştirilmiştir. Bu çalışmada öznelik vektörleri 9 bileşenli olduğundan, $N = M = 9$ alınmıştır. Daha sonra bu mat-

risin $D(1, 1)$ elemanından başlayarak satır satır belirli bir kurala bağlı olarak bu matristeki elemanlar toplanmış ve en sonda $D(N, M)$ elemanı elde edilmiştir. $D(N, M)$ 'de bulunan sayı, eğitime ve deneme vektörleri arasındaki en az uzunluktaki büküm yolunun değeridir [11]. Vektörler arasındaki en az uzunluktaki büküm yollarının değerleri hesaplandıktan sonra bu değerleri karşılaştırarak hareketler ayırdedilmiştir.

Tablo 3: k -en yakın komşuluk yönteminde $k = 1$ için elde edilen karışıklık matrisi.

	H1	H2	H3	H4	H5	H6	H7	H8
H1	24	0	0	0	0	0	0	0
H2	0	23	0	0	0	0	0	1
H3	0	0	24	0	0	0	0	0
H4	0	0	0	23	0	0	1	0
H5	0	0	0	1	22	0	1	0
H6	0	0	0	0	0	24	0	0
H7	0	0	1	0	1	0	22	0
H8	0	1	0	0	0	0	0	23

Dinamik zaman bükmesi yöntemi için eğitime vektörleri iki farklı şekilde kullanılmıştır. İlk olarak her bir hareket için her harekete ait olan 24 tane eğitime vektörünün ortalaması alınmış, bu ortalama değerlerle deneme vektörleri arasındaki en az uzunluktaki büküm yollarının değerine bakılarak sınıflandırma yapılmış ve % 87.6 başarı sağlanmıştır. İkinci durumda her bir deneme vektörünün $24 \times 8 = 192$ tane eğitime vektörü ile arasındaki olası büküm yollarının uzunluğuna bakılarak, bu değerlerden en küçüğüne sahip olan eğitime vektörünün sınıfı deneme vektörünün sınıfı olarak atanmıştır. Bu durum için hareketleri ayırdetme yüzdesi de % 95.2 olarak bulunmuştur. Dinamik zaman bükmesi yöntemi kullanılarak sınıflandırma yapılan bu iki durum için karışıklık matrisleri sırasıyla Tablo 4 ve 5'te verilmiştir.

Tablo 4: Dinamik zaman bükmesi-1. yaklaşım karışıklık matrisi.

	H1	H2	H3	H4	H5	H6	H7	H8
H1	22	0	0	0	0	2	0	0
H2	0	20	0	0	0	0	0	4
H3	0	0	23	0	0	0	1	0
H4	0	0	0	18	1	0	5	0
H5	0	0	0	1	21	0	2	0
H6	1	0	0	0	0	23	0	0
H7	0	0	0	1	3	0	20	0
H8	0	2	0	0	0	0	0	22

3.5 Yapay Sinir Ağları Yöntemi

Bu yöntemde sınıflandırma için üç katmanlı bir yapay sinir ağı oluşturulmuş ve eğitime aşamasında geriye yayılım algoritması kullanılmıştır. İlk katmanda, özneliklerin girdi olarak verileceği 9 adet nöron, orta katmanda da 9 adet nöron ve son katmanda ise 8 adet hareketi ikili sistemde kodlayarak çıktı veren 3 adet nöron bulunmaktadır. Orta katmanın ve son katmanın çıktısında sigmoid fonksiyonu olarak bilinen $f(x) = (1 + e^{-x})^{-1}$ fonksiyonu kullanılmıştır. Diğer yöntemlerde olduğu gibi bu yöntemde de her hareket için elde bulunan 48 adet vektörün 24'ü eğitime için, geri kalanı ise deneme için kullanılmıştır. Katmanlar arasındaki bağlantıların ağırlıkları $[0, 1]$ aralığından rasgele olarak seçilmiştir. Eğitime

vektörleri için başarı yüzdesi ortalama % 87.5, deneme vektörleri için ise % 79.7 olarak bulunmuştur.

Tablo 5: Dinamik zaman bükmesi-2. yaklaşım karışıklık matrisi.

	H1	H2	H3	H4	H5	H6	H7	H8
H1	23	0	0	0	0	1	0	0
H2	0	22	0	0	0	0	0	2
H3	0	0	24	0	0	0	0	0
H4	0	0	0	22	1	0	1	0
H5	0	0	0	1	22	0	1	0
H6	0	0	0	0	0	24	0	0
H7	0	0	1	0	1	0	22	0
H8	0	1	0	0	0	0	0	23

3.6 Destek Vektör Makineleri Yöntemi

Bu iki sınıflı bir sınıflandırma yöntemidir [12]. Bu iki sınıf +1 ve -1 olarak etiketlenir. Elimizdeki sekiz farklı sınıfı ayırtmak için her defasında sınıflardan sadece biri +1 olarak etiketlenip diğer yedi sınıf -1 ile işaretlenerek sınıflandırma yapılmıştır. Çekirdek fonksiyon olarak üstel bir fonksiyon kullanılmıştır [13]:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad \gamma > 0 \quad (3)$$

Hesaplamalarımızda γ parametresi 4 olarak seçilmiştir. Bu yöntemin başarısı % 94.8 olarak bulunmuştur (Tablo 6).

Tablo 6: Destek vektör makineleri yönteminde doğru sınıflandırılan hareketlerin sayısal dağılımı.

H1	H2	H3	H4	H5	H6	H7	H8
23	22	23	22	23	24	22	23

Yukarıda sonuçları verilen bu yöntemlerin başarı yüzdeleri ve işlem süreleri Tablo 7’de karşılaştırılmıştır. İşlem süreleri 1.60 GHz hızında bir işlemciye ve 1 GB belleğe sahip bir bilgisayarda elde edilmiştir. Tablodan da görülebileceği gibi dinamik zaman bükmesi (birinci yaklaşım) ve yapay sinir ağları yöntemleri diğer yöntemlere göre daha kötü sonuç vermiştir. Dinamik zaman bükmesi yönteminde birinci ve ikinci yaklaşım arasındaki fark, birinci yaklaşımda eğitime vektörlerinin ortalamalarının alınmasından kaynaklanmaktadır. Bu yaklaşımlar arasındaki fark işlem süresine de yansımıştır. Eğitime vektörlerinin sayısının yapay sinir ağları yöntemi için yetersiz olduğu, Tablo 7’de hem başarı yüzdesi hem de işlem süresi açısından gözlenmektedir. En iyi sonuçlar ise Bayesçi karar verme ve k -en yakın komşuluk yöntemleri ile elde edilmiş olsa da diğer yöntemlerle aralarında çok önemli bir fark gözlenmemiştir.

Tablo 7: Çalışmada kullanılan yöntemlerin karşılaştırılması.

ayrıt etme yöntemi	başarı yüzdesi (%)	işlem süresi (s)
en küçük kareler	92.3	< 0.1
Bayesçi karar verme	96.9	0.6
k -en yakın komşuluk	96.5	< 0.1
dinamik zaman bükmesi 1	87.6	4.6
dinamik zaman bükmesi 2	95.2	109.2
yapay sinir ağları	79.7	470.3
destek vektör makineleri	94.8	0.3

4. Sonuç

Bu çalışmada iki adet tek eksenli jiroskoptan elde edilen sinyaller üzerinde örüntü tanıma teknikleri kullanılarak sekiz

farklı bacak hareketinin tanınması ve ayırdedilmesi gerçekleştirilmiştir. Elde edilen doğru tanıma yüzdelерinin yüksek olması, hareket tanıma ve ayırtma sistemlerinde jiroskopların da kullanılabilir bir alternatif olduğunu göstermektedir. Bu çalışmada kullanılan yöntemler, daha çok sayıda ve tipteki duyucularla daha karmaşık hareketlerin tanınmasında ve ayırdedilmesinde de kullanılabilir. İlerideki çalışmalarımızda yöntemlerin zenginleştirilmesi ile birlikte, hareketler arası geçişlerin de ayırdedilmesinin mümkün olacağı düşünülmektedir.

5. Kaynakça

- [1] T. B. Moeslund, A. Hilton, V. Krüger, “A survey of advances in vision-based human motion capture and analysis,” *Comput. Vis. Image Und.*, 104: 90–126, Kasım 2006.
- [2] W. Zijlstra, K. Aminian, “Mobility assessment in older people: new possibilities and challenges,” *Eur. J. Ageing*, 4: 3–12, Mart 2007.
- [3] A. M. Sabatini, “Inertial sensing in biomechanics: a survey of computational techniques bridging motion analysis and personal navigation,” *Computational Intelligence for Movement Sciences: Neural Networks and Other Emerging Techniques* (R. Begg ve M. Palaniswami, ed.), s. 70–100, Idea Group Publishing, 2006.
- [4] W. Y. Wong, M. S. Wong, K. H. Lo, “Clinical applications of sensors for human posture and movement analysis: A review,” *Prosthet. Orthot. Int.*, 31: 62–75, Mart 2007.
- [5] J. Pärkkä, M. Ermes, P. Korpipää, J. Mäntyjärvi, J. Peltola, I. Korhonen, “Activity classification using realistic data from wearable sensors,” *IEEE Trans. Inf. Technol. B.*, 10: 119–128, Ocak 2006.
- [6] M. J. Mathie, A. C. F. Coster, N. H. Lovell, B. G. Celler, “Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement,” *Physiol. Meas.*, 25: R1–R20, Nisan 2004.
- [7] L. Bao, S. S. Intille, “Activity recognition from user-annotated acceleration data,” *Proc. Pervas. Comput., LNCS*, 3001: 1–17, 2004.
- [8] B. Najafi, K. Aminian, F. Loew, Y. Blanc, P. Robert, “Measurement of stand-sit and sit-stand transitions using a miniature gyroscope and its application in fall risk evaluation in the elderly,” *IEEE Trans. Bio-med. Eng.*, 49: 843–851, Ağustos 2002.
- [9] Murata Manufacturing Co., Ltd., *Murata Gyrostar ENV-05A Piezoelectric Vibratory Gyroscope Datasheet*.
- [10] K. Kiani, C. J. Snijders, E. S. Gelsema, “Computerized analysis of daily life motor activity for ambulatory monitoring,” *Technol. Health Care*, 5: 307–318, Ekim 1997.
- [11] S. Salvador, P. Chan, “FastDTW: Toward accurate dynamic time warping in linear time and space,” *KDD Workshop on Mining Temporal and Sequential Data*, 2004.
- [12] I. Aydın, M. Karaköse, E. Akın, “Zaman serisi veri madenciliği ve destek vektör makineleri kullanan yeni bir akıllı arıza sınıflandırma yöntemi,” *Gazi Üniv. Müh. Fak. Dergisi*, 23(2):431–440, 2008.
- [13] A. U. Özkaya, M. E. Kaya, F. Gürgen, “Destek vektör makineleri kullanılarak aritmi sınıflandırması,” *Biyomedikal Müh. Ulusal Toplantısı*, İstanbul, 2005.