

ETİKET-TABANLI KONUMLAMA İLE İNSAN AKTİVİTELERİNİN TANINMASI HUMAN ACTIVITY RECOGNITION USING TAG-BASED LOCALIZATION

Aras Yurtman, Billur Barshan

Elektrik ve Elektronik Mühendisliği Bölümü
Bilkent Üniversitesi
yurtman,billur@ee.bilkent.edu.tr

ÖZETÇE

Bu makalede, etiket tabanlı, radyo frekansına (RF) dayalı bir konumlama sistemi ile insan aktivitesi tanımadaki çeşitli yöntemlerin kullanımı karşılaştırılmı olarak sunulmuştur. Bedendeki etiketlerin konum ölçümlerini içeren farklı aralıklarla örneklenmiş veri, farklı eğri uyarlama algoritmaları kullanılarak eşit aralıklı örneklenmiş veriye dönüştürüldükten sonra bölütlere ayrılmıştır. Son olarak, insan aktivitelerinin tanınması için çeşitli sınıflandırma teknikleri uygulanmıştır. Eğri uyarlama, bölütleme ve sınıflandırma yöntemleri, çapraz bağımsız geçerlilik sınamasıyla karşılaştırılmış ve en iyi başarıyı veren katışım sunulmuştur. Sonuçlar, etiket-tabanlı RF konumlama sistemlerinin fazla hassas olmamakla birlikte kabul edilebilir sonuçlar verdiğini göstermektedir.

ABSTRACT

This paper provides a comparative study on the different techniques of classifying human activities using a tag-based radio-frequency (RF) localization system. Non-uniformly-sampled data containing position measurements of the tags on the body is first converted to a uniformly-sampled one using different curve-fitting algorithms. Then, the data is partitioned into segments. Finally, various classification techniques are applied to classify human activities. Curve-fitting, segmentation, and classification methods are compared using different cross-validation techniques and the combination resulting in the best performance is presented. The results indicate that the system demonstrates acceptable performance despite the fact that tag-based RF localization is not very accurate.

1. GİRİŞ

Hızla gelişen teknolojiyle birlikte, bilgisayarlar, akıllı telefonlar ve tabletler gibi aygıtlar günlük yaşantımıza girmiştir. Bu aygıtların insan davranışlarını tanıyabilmesi ve yorumlayabilmesi gerekli olmaya başlamıştır. Bu tür bağlam-duyarlı sistemlerin bir uygulaması da, yürüme, oturma ve düşme gibi günlük insan aktivitelerinin tanınması ve izlenmesidir.

İnsan aktivitelerinin tanınması için birçok farklı yaklaşım bulunmaktadır. Bunlardan en yaygın olanı, ortama yerleştirilmiş birden fazla video kameradan elde edilen görüntülerin işlendiği görüntüleme-tabanlı sistemlerdir [1, 2, 3, 4]. Ancak, kamera sistemleri, kullanılmayan gereksiz verileri de kaydettiği için bu yaklaşım gizlilik ihlaline yol açmaktadır. Bundan dolayı, sistemin kullanıldığı yerdeki insanlar, özellikle kişisel mekânlarda rahat hareket edememektedirler. Görüntüleme-tabanlı sistemlerin diğer dezavantajları da gölgeleme ve aydınlatmadan dolayı

başarımın çok düşmesi, projeksiyon yapma gereği, yüksek hesaplama karmaşıklığı ve sistemin sadece kameraların kapsadığı sınırlı alanlarda kullanılabilir olmasıdır.

İkinci yaklaşım, son onyılda ucuzlayan ve hassasiyetleri artan minyatür eylemsizlik duyucuları ve (ya) manyetometre sinyallerinin işlenmesine dayanır [5, 6, 7]. Bu yaklaşımda, her biri en fazla bir cep telefonu büyüklüğünde olan ve genellikle 10 ila 100 Hz'de örnekleme yapan iki- ya da üç-eksenli ivmeölçer, dönüölçer ve manyetometre barındıran, beden farklı noktalarına yerleştirilebilen algılayıcı birimleri kullanılmaktadır. Ölçümler, ya cep telefonu gibi pille çalışan taşınabilir bir aygıt tarafından alınıp işlenir, ya da yine pille çalışan bir aktarıcı ile kablosuz olarak yakındaki bir kişisel bilgisayara aktarılır ve işlenir. Her ne kadar bu yöntem genellikle oldukça hassas bir sınıflandırma başarıyı ile sonuçlansa da, bedene takılan algılayıcılar ve pille çalışan birim, kişiyi rahatsız edebilmektedir.

Üçüncü yaklaşım ise, radyo frekansına dayalı (RF) konumlama sistemi kullanılarak, bedene takılı aktif (pil içeren) ya da pasif (pil içermeyen) etiketlerin konumlarının algılanmasına dayanır [8]. Bu yöntemde, pasif etiketler kullanıldığında ortama yerleştirilen antenlerin yaydığı radyo dalgalarının etiketlerden yansımaları işlenerek konumları kestirilir ve kaydedilir. Aktif etiketler kullanıldığında ise, etiketlerin yaydığı RF darbeleri, antenler tarafından alınıp işlenerek etiket konumları kestirilir. Hassasiyetleri çok daha yüksek olduğundan konumlama için genellikle aktif etiketler kullanılmaktadır. Ancak, çoğu sistemde hassasiyet, etiketin yönüne, antenlere ve diğer etiketlere uzaklığına, takıldığı nesnenin/kişinin iletkenliğine, örnekleme hızına ve ortamda bulunan diğer nesnelere/kişilere göre değişmektedir ve genellikle 15 cm civarındadır. Fakat bazı anlarda konum hiç saptanamamakta ya da ancak yüksek hata ile saptanabilmektedir [8].

RF konumlama amacıyla geliştirilen sistemlerden biri olan Ubisense platformunda [8] kullanılan aktif etiketler, antenlere en fazla onlarca metre uzaklıktayken, 10 Hz örnekleme hızında, ölçümlerin %95'inde yaklaşık 15 cm hassasiyetle üç boyutlu olarak konumlandırılabilir [8]. Etiketler aktif olduğundan, belirli sıklıkta benzersiz RF darbeleri göndermekte ve bu sayede konumları ve benzersiz numaraları saptanabilmektedir. Fakat etiketler birbirleri ile senkronize olmadığından etiketlerin konumları eş anlı olarak değil, farklı anlarda kaydedilmektedir. Ayrıca, bazı anlarda ortam gürültüsü ya da başka bir cisimle engellenme gibi nedenlerden dolayı bir etiketin konumu tam olarak saptanamadığında, sistem, konum bilgisi verememektedir. Bu nedenle, ölçülen ham veriler, sınıflandırma için doğrudan kullanılamamaktadır.

Bu çalışmada, beden belirli bölgelerinin Ubisense platformu [8] ile elde edilen üç-boyutlu konum verileri kullanılarak, çeşitli yöntemlerle insan aktiviteleri ayırt edilmeye çalışılmış ve yöntemler birbirleriyle karşılaştırılmıştır.

2. VERİ KÜMESİ

UC Irvine Learning Repository'deki "Localization data for Person Activity" veri kümesi [9] kullanılmıştır. Katılımcıların sol ve sağ ayak bileklerine (sırasıyla E1 ve E2), göğüslerine (E3) ve kemerlerine (E4) toplam dört adet RF etiketi takılmıştır. Deneyler sırasında yapılan aktiviteler şunlardır: yürüme (A1), düşme (A2), uzanma hareketi (A3), uzanma konumu (A4), oturma hareketi (A5), oturma (A6), uzanırken ayağa kalkma (A7), dört ayak üstünde durma (A8), yere oturma (A9), otururken kalkma (A10) ve yerde otururken kalkma (A11).

A1 ve A4 gibi aktiviteler bir duruma, A2 ve A10 gibi aktiviteler ise durumlar arasındaki geçişlere karşı gelmektedir. Geçiş aktivitelerinin tanınma başarısı diğerlerine göre düşük olacağından, 11 sınıflı örüntü tanıma problemine ek olarak, yalnızca A1, A4, A6, A8 ve A9 aktivitelerinden oluşan 5 sınıflı indirgenmiş bir örüntü tanıma problemi de ele alınmıştır.

Veri toplanırken, 5 farklı katılımcının her biri aynı deneyi 5 kez tekrarlamıştır. Her deneyde, katılımcı tarafından, geçiş zamanları yaklaşık aynı olan sabit bir aktivite dizisi gerçekleştirilmiştir. Bu aktivite dizisi, A1-A5-A6-A10-A1-A2-A4-A7-A1-A3-A4-A7-A1-A2-A4-A7-A1-A5-A6-A9-A11-A1-A3-A4-A7-A1-A3-A8-A4-A7-A1'dir. Şekil 1'de 1. katılımcının 1. deneyinde E1'in üç-boyutlu uzaydaki konumu, zamana göre rengi açıktan koyuya doğru değişen, kayan ortalama süzgecinden geçirilmiş bir çizgiyle gösterilmiştir.

3. VERİNİN HAZIRLANMASI


3.1. Eğri Uyarlama

Kullanılan veri kümesinde, x , y , z eksenlerindeki konum değerleri her etiket için farklı anlarda ve farklı aralıklarla örneklendiğinden, zaman bölgesindeki işaretlerin doğrudan kullanılması ya da bunlardan öznitelik çıkarılması olası değildir. Bu nedenle, öncelikle işaretlere eğri uyarlanarak işaretler sürekli eğrilere dönüştürülmüş, ardından tüm etiketlerin tüm eksenlerdeki zamana göre konum eğrileri aynı anlarda sabit örnekleme sıklığıyla (düzgün) örneklendirilmiştir. Yeni sabit örnekleme sıklığı, veri kümesindeki ortalama 10 Hz olan değişken örnekleme sıklığından yeteri kadar fazla olduğu sürece, etiketlerin çok hızlı hareket etmeyeceği de göz önüne alındığında dikkate değer bir veri kaybı olmamaktadır.

Bu çalışmada MATLAB[®] Curve Fitting Toolbox[™] kütüphanesinde bulunan üç farklı eğri uyarlama yöntemi kullanılmıştır [11]: (1) *Şekil koruyan aradeğerleme (shape-preserving interpolation)*, uzaktan bakıldığında veri noktalarını doğrusal olarak birleştirmiş gibi görünen, fakat yakından incelendiğinde veri noktalarının yakınlarında kıvrımlı bir biçim alarak türevlenebilir bir eğri oluşturmaktadır. (2) *Kübik kobra aradeğerlemesi (cubic spline interpolation)* yönteminde, uyarlanan eğri önceki yöntemlere göre çok daha pürüzsüz olmasına karşın, yerel minimumlar ve maksimumlar arasında salındığından, özellikle doruk noktalarında veri fazlaca çarpıtılmaktadır. (3) *Pürüzsüzleştirilen kobra (smoothing spline)*, 0 ile 1 arasında ayarlanabilen bir pürüzsüzleştirme parametresine sahiptir. Uyarlanmış eğri, bu parametre 0 iken düz bir çizgiyken, 1'e doğru arttıkça daha karmaşık bir eğriye dönüşmektedir. Parametre 1 olduğunda ise bu yöntem kübik kobra aradeğerlemesi yöntemine yakınsamaktadır. Bu yöntemler, karşılaştırma amacıyla Şekil 2'de rastgele oluşturulmuş veriye uygulanmıştır. Üç yöntemde de uyarlanan eğriler, tüm veri noktalarından geçmektedir.

Verinin ölçüm sıklığının fazla olmadığı ve veride fazla mik-

1. katılımcının 1. deneyinde E1 etiketinin düzleştirilmiş bağıl konumu




Şekil 1: 1. katılımcının 1. deneyinde E1 etiketinin üç-boyutlu uzaydaki süzgeçlenmiş konumu.

tarda gürültü olduğu dikkate alındığında, kullanılan eğri uyarlama yönteminin veriyi fazla pürüzsüzleştirmemesi gereklidir. Şekil koruyan aradeğerleme yönteminde, veri noktalarının yerel maksimum ve minimumları, uyarlanan eğrininkiyile aynı olduğundan ve orijinal veri çarpıtılmadığından, bu yöntemle elde edilen sonucun toplanan veriyi daha iyi yansıttığı sonucuna varılmış ve şekil koruyan aradeğerleme yöntemi, varsayılan olarak seçilmiştir. Ancak, üç eğri uyarlama yöntemi de aşağıda sınıflandırma başarımı açısından karşılaştırılacaktır.

3.2. Bölütleme

Eğri uyarlama yöntemleriyle sürekli biçime getirilip düzgün örneklenen veri, sınıflandırma için zaman ekseninde sabit süreli bölütlere ayrılmıştır. Her deney, bir aktivite dizisinden oluştuğundan, her bölütün yalnız bir aktivitenin verisini içermesini sağlamak için şu bölütleme kuralı uygulanmıştır: Her deneyin düzgün örneklendirilmiş işaretleri, zamana göre baştan başlanarak taranır ve izin verilen maksimum bölüt süresine ulaşıldığında ya da yeni bir aktiviteye geçildiği anda yeni bir bölüte geçilir. Bunun sonucunda, bölüt uzunlukları, izin verilen maksimum bölüt süresine eşit ya da ondan daha küçük olabilir. Her ne kadar bu yöntem, aktivite geçişlerinden önce, yapılan aktivite ile ilgili yeterince bilgi içermeyen, kısa süreli bölütlere yol açsa da, düşme ve otururken kalkma gibi kısa süren aktivitelerin sınıflandırılabilmesi için gereklidir. Eğer kısa bölütler çıkarılsaydı, uzun bölüt süresi seçildiğinde bu aktivitelere ait hiç veri kalmazdı ve aktivite geçişlerindeki tanıma başarımı ölçülemezdi. Değişik bölüt sürelerinin sınıflandırma başarımını nasıl etkilediği gösterilecektir.



Şekil 2: Üç farklı eğri uyarlama yönteminin 7 noktadan oluşan rastgele veriye uygulanması.

Sınıflandırma esnasında her bölüt bağımsız olarak sınıflandırılacaktır. Fakat, sınıflandırıcı başarımlarını sınama aşamasında kullanılan sınama verisinde doğru aktivite bilgisi kullanılmadığından, bölütleme sonucunda bir aktiviteden başka bir aktiviteye geçiş anlamı içeren bir bölüt, iki aktivitenin verilerini de barındıracaktı. Bu durumda, o bölütün doğru (olması gereken) aktivitesi, bölütün en uzun süreli içerdiği aktivite olarak kabul edilseydi, sınıflandırıcı o bölütün içerdiği diğer aktiviteyi seçtiğinde bu seçim yanlış sınıflandırma sayılacaktı ve bu durum sınıflandırıcı başarımlarını olumsuz etkileyecekti. Bu nedenle, gerçek yaşamda uygulanabilir olmasa da, sınama verisi bölütlenirken, eğitim verisindeki gibi doğru aktivite bilgisi kullanılmış ve her bölütün yalnız tek bir tip aktiviteye ait verilerden oluşması sağlanmıştır.

4. ÖZNETELİK ÇIKARMA VE İNDİRGEME

Elde edilen bölütlerden tüm etiketlerin tüm eksenleri için ayrı ayrı öznetelikler çıkarılmıştır. Bu öznetelikler, her eksen için şunlardır: en büyük ve en küçük değerler, ortalama, değişinti, yamukluk, sivrilik, özilinti (bölüt uzunluğunun yarısı kadar kat-sayı) ve en büyük 10 ayrı Fourier dönüşümü değerlerinin mutlak değerleri ile bunlara karşılık gelen sıklık değerleri. Böylece, 12 eksen için toplam $192 + 6 \times$ (bölüt süresi) öznetelik değeri elde edilmektedir. Öznetelik sayısı oldukça büyük olduğundan, öznetelikler ana bileşenler çözümlemesi (ABÇ) ve doğrusal ayırtaç çözümlemesi (DAÇ) ile indirgendikten sonra eğitim için kullanılmıştır.

5. SINIFLANDIRMA

Sınıflandırma için kullanılan, PRTools araç kutusunda [10] bulunan, yanlarında PRTools'taki fonksiyon isimleri yer alan 11 farklı sınıflandırıcı şunlardır: (1), (2) ve (3) her sınıf için sırasıyla aynı/farklı/farklı köşegen ortak değişinti matrisi kullanılan Gauss sınıflandırıcı (ldc, qdc ve udc), (4) ikili Gauss karışımı sınıflandırıcısı (mogc), (5) saf Bayes sınıflandırıcısı (naivebc), (6) k en yakın komşu sınıflandırıcısı (knnc), (7) ayrılık-tabanlı sınıflandırıcı (kernelc), (8) minimum en küçük kareler doğrusal sınıflandırıcısı (fisherc), (9) en yakın ortalama sınıflandırıcısı (nmc) ve (10) ölçekli en yakın ortalama sınıflandırıcısı (mnscc).

P -bölme bağımsız geçerlilik sınaması (P -BBGS) ve denek-tabanlı birini dışarıda bırakma (DT-BDB) yöntemleri ile sınıflandırıcıların başarımları sınanmıştır. İlk yöntem, katılımcı ayırt etmeksizin veriyi rastgele böldüğü için katılımcılar arası farklılıkları ortaya çıkarmamakta, öte yandan ikinci yöntemde, eğitimde kullanılan kişiler sınamada kullanılmadığından katılımcılar arası farklılıklar başarımları düşürmektedir. Her iki yöntemde de, sınama işlemi 5 kez tekrarlanmış ve ortalama hesaplanmıştır. Elde edilen sonuçlar Tablo 1'de gösterilmiştir.

6. SONUÇLAR

Kullanılan sınıflandırıcının ve parametrelerin seçimi, başarımları etkilemektedir. Bu parametreler şunlardır: oh (örnekleme hızı, Hz), bs (bölüt süresi, saniye), eu (eğri uyarlama yöntemi), ind (öznetelik indirgeme) (0: öznetelik indirgeme yok, $+ |n|$: n -boyutlu ABÇ, $- |n|$: n -boyutlu DAÇ). Varsayılan (ve çoğu durumda en iyi sonucu veren) değerler, sırasıyla 10, 0.5, 1 ve 0 olarak alınmıştır.

Bütün sınıflandırıcılar, yukarıda verilen parametrelerin farklı katışımlarıyla 5-BBGS ve DT-BDB yöntemleri kullanılarak

Tablo 1: Her sınıflandırıcının en düşük hata yüzdesi ve buna karşılık gelen parametre değerleri.

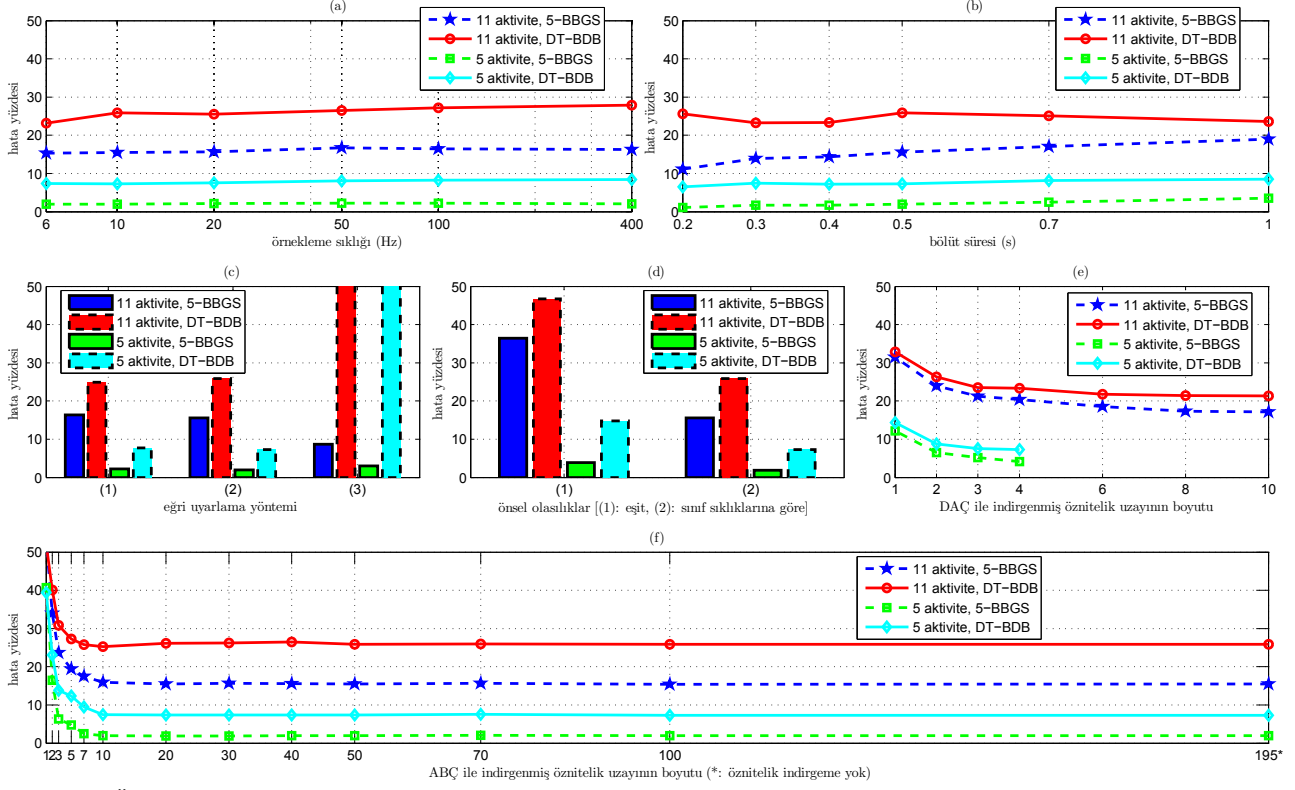
Sınıflandırıcı		Hata Yüzdesi \pm Standart Sapma (parametreler: $\text{oh}, \text{bs}, \text{eu}, \text{ind}$) ¹			
		11 Sınıflı Veri Kümesi		5 Sınıflı Veri Kümesi	
		5-BBGS	DT-BDB	5-BBGS	DT-BDB
1	ldc	20.89 \pm 0.02 (10, 0.5, 2, -8)	23.52 (10, 0.5, 1, -8)	6.06 \pm 0.01 (10, 0.5, 2, -4)	7.63 (10, 0.5, 2, -4)
2	qdc	20.76 \pm 0.04 (10, 0.5, 2, -6)	23.69 (10, 0.5, 1, -8)	5.48 \pm 0.02 (10, 0.5, 2, -4)	7.73 (10, 0.5, 2, -4)
3	udc	21.65 \pm 0.05 (10, 0.5, 2, -6)	24.11 (10, 0.5, 1, -3)	6.02 \pm 0.02 (10, 0.5, 2, -4)	7.92 (10, 0.5, 2, -4)
4	mogc	20.75 \pm 0.07 (10, 0.5, 2, -6)	23.70 (10, 0.5, 1, -8)	5.19 \pm 0.03 (10, 0.5, 2, -4)	7.63 (10, 0.5, 2, -4)
5	naivebc	22.84 \pm 0.16 (10, 0.5, 2, -8)	24.46 (10, 0.5, 1, -6)	7.24 \pm 0.16 (10, 0.5, 2, -4)	9.49 (10, 0.5, 2, -4)
6	knncc	8.67 \pm 0.10 (10, 0.5, 1, 0)	21.30 (10, 0.5, 1, -10)	1.12 \pm 0.04 (10, 0.2, 2, 0)	6.52 (10, 0.2, 2, 0)
7	kernelc	19.41 \pm 0.16 (10, 0.5, 2, -8)	22.10 \pm 0.04 (10, 0.5, 1, -10)	4.66 \pm 0.16 (10, 0.5, 2, -4)	7.33 \pm 0.03 (10, 0.5, 2, -4)
8	fisherc	25.26 \pm 0.52 (10, 0.5, 1, -10)	26.83 (10, 1, 1, 0)	7.37 \pm 0.17 (10, 0.5, 2, -4)	9.30 (10, 1, 2, 0)
9	nmc	23.60 \pm 0.06 (10, 0.5, 1, -10)	27.02 (10, 0.5, 1, -10)	6.07 \pm 0.02 (10, 0.5, 2, -4)	8.21 (10, 0.5, 2, -4)
10	mnscc	20.94 \pm 0.04 (10, 0.5, 1, -8)	23.59 (10, 0.5, 1, -8)	6.04 \pm 0.03 (10, 0.5, 2, -4)	7.58 (10, 0.5, 2, -4)

sınanmış, en iyi sonucu veren parametreler ve bunlar kullanıldığında elde edilen hata yüzdeleri Tablo 1'de verilmiştir. Hem 11 sınıflı, hem de 5 sınıflı örüntü tanıma gerçekleştirilmiştir. 11 sınıflandırıcı içinde 6 numaralı sınıflandırıcı olan knncc sınıflandırıcısının en düşük hata yüzdesine sahip olduğu tabloda görülmektedir. En iyi parametre katışımında knncc sınıflandırıcısının 5-BBGS'ye göre hata oranı, 11 aktivite için %8.67, 5 aktivite için %1.12'dir. Bu yüzdeler, kişiler arası farklılıkları cezalandıran DT-BDB sınama yöntemine göre ise sırasıyla %21.30 ve %6.52'dir.

Yukarıda belirtilen parametrelerin en yüksek başarımla sahip olan knncc sınıflandırıcısının başarımına etkileri, her parametre için (diğer parametreler varsayılan değerlerinde tutularak) Şekil 3'te gösterilmiştir. Örnekleme sıklığı arttığında hata yüzdesi az da olsa artmaktadır. Bunun nedeni, etiketlerin konumlarının hızlı değişmemesi ve ölçümlerde önemli miktarda gürültü bulunduğu için örnekleme sıklığı arttığında veri miktarının gereksiz yere artmasıdır. Bölüt süresi seçiminin de hata yüzdesini az miktarda etkilediği gözlenmiştir. Bölütler çok kısa tutulduğunda sınıflandırıcılar daha kısa süredeki veri ile karar verdiğinden başarımları düşmektedir. Şekle göre, eğri uyarlama yöntemleri arasında en iyisi, 11 aktivite ve 5-BBGS için (3) iken, diğer tüm durumlarda (1)'dir.

Öznetelik indirgemesi de sınıflandırıcıların hata yüzdelerini önemli ölçüde etkilemektedir. DT-BDB ile sınanıldığında, DAÇ yöntemi ile indirgenmiş 10-boyutlu uzayda yapılan sınıflandırmaya özgün 195-boyutlu öznetelik uzayında yapılan sınıflandırmaya çok yakın sonuçlar vermiştir. DAÇ ile boyutun bu denli indirgenmesi, hesaplama karmaşıklığını oldukça düşürdüğünden, başarımları düşüşüne rağmen tercih edilebilir. Öte yandan, 5 sınıflı durumda, ABÇ yöntemi ile yapılan indirgemede, boyutun sınıf sayısının bir eksiği ile sınırlı olmaması sayesinde 10-boyutlu ABÇ uzayında yapılan sınıflandırma, 4-boyutlu DAÇ uzayında yapılan sınıflandırmaya göre daha iyi sonuçlar vermiştir. İndirgenmiş uzayda yapılan sınıflandırmaların bazılarının özgün öznetelik uzayında yapılanlara göre daha başarılı olması, özgün uzayın gereğinden fazla karmaşık olduğunu ve bu yüzden sınıflandırıcıları yanıltabildiğini göstermektedir.

¹Önsel olasılıklar tablo boyunca sınıf sıklıklarına göre hesaplanmıştır.



Şekil 3: (a) Örneklem sıklığının, (b) bölüt süresinin, (c) eğri uyarlama yönteminin, (d) önsel olasılıkların, (e) DAÇ ve (f) ABC öznelilik indirgeme yöntemlerinde indirgenmiş öznelilik uzayının boyutunun k_{nnc} hata yüzdesine etkisi. Her grafikte, değişen parametre dışındaki tüm parametreler varsayılan değerlerinde tutulmuştur.

7. KAPANIŞ

Bu çalışmada, insan bedenine takılan 4 RF etiketinin düzensiz bir şekilde ölçülen konum verileri kullanılarak insan aktiviteleri tanınmaya çalışılmıştır. Etiket konumları eşit aralıklarla örneklemediğinden ve her etiket için farklı aralarda ölçüldüğünden, konum işaretleri eğri uyarlama yöntemleriyle sürekli ve düzgün örnekleme hâle getirilmiştir. Veriler zaman ekseninde bölütlenmiş ve her bölütten öznelilikler çıkarılmıştır. Her bölüt için, bu öznelilikler ve indirgenmiş öznelilikler kullanılarak farklı sınıflandırma yöntemleriyle aktivite tanınmaya çalışılmış ve her sınıflandırıcı için başarı yüzdesi hesaplanmıştır. Ayrıca, örnekleme sıklığının, bölüt süresinin, eğri uyarlama yöntemlerinin, önsel olasılıkların ve farklı yöntemlerle öznelilik indirgeme yönteminin sınıflandırıcı başarımına etkisi gösterilmiştir.

8. TEŞEKKÜR

Bu çalışma, COST-MOVE IC0903 aksiyonuna dahil olan TÜBİTAK 109E059 projesi ile Erciyes Üniversitesi FBA-11-3579 projesi tarafından desteklenmiştir.

9. KAYNAKÇA

- [1] T. B. Moeslund, E. Granum, "A survey of computer vision-based human motion capture," *Comput. Vis. Image Und.*, 81(3): 231–268, 2001.
- [2] T. B. Moeslund, A. Hilton, V. Krüger, "A survey of advances in vision-based human motion capture and analysis," *Comput. Vis. Image Und.*, 104(2–3):90–126, 2006.
- [3] L. Wang, W. Hu, T. Tan, "Recent developments in human motion analysis," *Pattern Recogn.*, 36(3):585–601, 2003.

- [4] J. K. Aggarwal, Q. Cai, "Human motion analysis: a review," *Comput. Vis. Image Und.*, 73(3):428–440, 1999.
- [5] B. Ayralu-Erdem, B. Barshan, "Leg motion classification with artificial neural networks using wavelet-based features of gyroscope signals," *Sensors*, 11(2):1721–1743, 28 January 2011.
- [6] K. Altun, B. Barshan, "Human activity recognition using inertial/magnetic sensor units," *Int. Workshop Human Behaviour Understanding*, 22 August 2010, Istanbul, Turkey. A. A. Salah et al. (Eds.): HBU 2010, LNCS 6219:38–51. Springer-Verlag, Berlin, Heidelberg, 2010.
- [7] K. Altun, B. Barshan, O. Tunçel, "Comparative study on classifying human activities with miniature inertial and magnetic sensors," *Pattern Recogn.*, 43(10):3605–3620, October 2010.
- [8] Y. Zhang, M. G. Amin, S. Kaushik, "Localization and tracking of passive RFID tags based on direction estimation," *Int. J. Antenn. Propag.*, vol. 2007, pp. 1–9, 2007.
- [9] "Localization data for person activity data set," *UC Irvine Machine Learning Repository*. <http://archive.ics.uci.edu/ml/datasets/Localization+Data+for+Person+Activity>.
- [10] R. P. W. Duin, P. Juszczak, P. Paclik, E. Pekalska, D. de Ridder, D. M. J. Tax, S. Verzakov, PRTTools 4.1, A MATLAB Toolbox for Pattern Recognition, Delft Univ. of Technology, 2007.
- [11] MATLAB version 7.10.0. Natick, Massachusetts: The MathWorks Inc., 2010.