

2.2. Yapay Sinir Ağları (YSA)

Sınıflandırma için iki katmanlı bir yapay sinir ağı kullanılmıştır. Giriş katmanında $D = 30$, çıkış katmanında $M = 19$ adet nöron bulunmaktadır. Bu yöntemde, her bir katmanda bulunan nöronlarda, etkinleştirme fonksiyonu $h(x) = (1 + e^{-x})^{-1}$ olarak seçilmiş, eğitime aşamasında ise geriye yayılım algoritması kullanılmıştır. Bu algoritmada amaç, çıkış katmanından alınan çıktılar ve beklenen çıktılar arasındaki farktan doğan toplam kareler hatasını en aza indirmektir [7]. Geriye yayılım algoritmasının parametreleri olan öğrenme ve momentum katsayıları 0.05 alınmıştır.

2.3. Benzeşmezlik Tabanlı Sınıflandırıcı (BTS)

Bu yöntemde, öznelik vektörlerinin benzeşmezlik eşlemesi kullanılarak Fisher doğrusal ayırtaç analizine (FDDA) göre bir sınıflandırıcı oluşturulur. Benzeşmezlik eşleşmesi, X kümesindeki öznelik vektörlerini benzeşmezlik uzayına taşır ve $F(\cdot, R) : X \rightarrow \mathbb{R}^r$ fonksiyonu ile tanımlar. Bu fonksiyonda r elemanlı R kümesi öğrenme aşamasında kullanılacak öznelik vektörlerinden oluşmaktadır. Bu çalışmada, R kümesini oluşturan öznelik vektörleri $r = 100$ alınarak rastgele oluşturulmuştur. Daha sonra, sınıflandırma için FDDA yöntemi ile doğrusal ayırtaç analiz fonksiyonları oluşturulur. FDDA yöntem sonunda, belirlenen bir kıstas fonksiyonunun en büyük değerini almasını sağlayacak şekilde $M - 1$ sınıflandırıcı bulunur [8].

2.4. Karar Ağacı (KA) Yöntemleri

Karar ağacı yöntemleri, ana problemi bu problemin alt problemleri doğrudan çözülebilir hale gelene kadar özyinelemeli olarak alt problemlere bölen *böl ve yönet* algoritmasına dayanır. Karar ağaçları, kök düğümü, karar düğümü ve yaprak düğümlerinden oluşmaktadır.

2.4.1. J48 Karar Ağacı (J48-KA)

J48-KA yöntemi, ID3 algoritmasının iyileştirilmiş bir uyarlaması olan C4.5 algoritmasını kullanır [9]. Bu yöntem, öğrenme aşamasında, normalize edilmiş bilgi kazancı kavramını kullanır. Bu kavram, her bir ağaç düğümüne giren örüntü kümesini en verimli biçimde bölebilecek olan özneliği seçmek için kullanılan bir bölme kıstasıdır. Oluşturulacak tüm düğümler için, o düğümde en yüksek kazancı veren öznelik kullanılarak bir eşik değeri (ξ) bulunur. Bu eşik değeriyle, ilgili düğümü dallara ayıracak kural olan $a_k \leq \xi$ eşitsizliği oluşturulur. Bu eşitsizlikte, a_k , ilgili düğümünden geçen örüntüleri sınıflandırmak için kullanılacak olan özneliktir. Eşitsizliğin doğru veya yanlış olma durumuna göre her bir düğüm iki dala ayrılır. Bu işlem, yaprak düğümlerine ulaşılan kadar devam eder. Her bir yaprak düğümü farklı bir sınıfı temsil etmektedir.

2.4.2. Basit Bayesçi Karar Ağacı (BB-KA)

Bu karar ağacı, basit Bayesçi ve karar ağacı yöntemlerinin karışımı olan melez bir yöntemdir. Bu yöntemi karar ağaçlarının bilindik özyinelemeli çözüm yönteminden ayıran tek özellik, yaprak düğümlerinin her birinin BB sınıflandırıcı kullanarak karara varmasıdır. Bu yöntemin önemli bir özelliği, BB ta-

banlı yöntemlerin temelinde bulunan, özneliklerin birbirinden bağımsız olduğu varsayımdır.

2.4.3. Rastgele Orman Karar Ağacı (RO-KA)

RO-KA yöntemi, sınıflandırma için $\{H(\mathbf{x}, \Theta_q), q = 1, \dots, I\}$ yapısına sahip çok sayıda karar ağacı kullanır. Burada $\{\Theta_q\}$ bağımsız ve özdeş dağılımlı rastgele bir vektördür. Rastgele orman oluştururken, *torbalama* yöntemi kullanılır ve her bir ağaç düğümünde rastgele öznelik seçimi yapılır. Öncelikle, öğrenme kümesi X, X_1, X_2, \dots, X_I kümeleri ile gösterilen özyüklem kümelerine rastgele bölünür. Daha sonra öğrenme sırasında kullanılacak olan ve rastgele seçilen özneliklerin sayısını gösteren d' belirlenir. Bu işlemde *torbalama*, her bir özyüklem öğrenim kümesinin torba-içi ve torba-dışı olarak adlandırılan iki kısma bölünmesi anlamına gelmektedir. X_q kümesinin çanta-içi kısmının d' tane rastgele seçilmiş öznelik vektöründen, en yüksek normalize edilmiş bilgi kazancıma sahip olan öznelik kullanılarak q . ağacın herhangi bir düğümündeki kural belirlenir. Burada $\Theta_q = (X_q, d')$ olarak alınır.

2.5. Gauss Karışım Modeli (GKM)

Bu yöntemde, eğitim kümesindeki her bir öznelik vektörünün, modelin m bileşeninden biri ile ilişkili olduğu varsayılır. Her bir bileşen ortalama değer vektörü μ_t ve kovaryans matrisi Σ_t olan çokbileşenli normal dağılıma sahiptir. Bu dağılım $p_t(\mathbf{x}_i | \mu_t, \Sigma_t)$ ile ifade edildiğinde, karışım modelinin olasılık dağılım fonksiyonu aşağıdaki gibi gösterilir:

$$p(\mathbf{x}_i | \Upsilon) = \sum_{t=1}^m \alpha_t p_t(\mathbf{x}_i | \mu_t, \Sigma_t) \quad (1)$$

Bu denklemde $\Upsilon = (\alpha_1, \dots, \alpha_m; \mu_1, \dots, \mu_m; \Sigma_1, \dots, \Sigma_m)$ karışım parametrelerini ifade eder; α_t ise, t bileşeninin karışım katsayısı olup bu katsayı için $\alpha_t \geq 0$ ve $\sum_{t=1}^m \alpha_t = 1$ kuralları geçerlidir.

Model bileşenleri için öngörülen varsayıma göre μ_t ve Σ_t için beş farklı ifade kullanılabilir. Bu ifadelerden sınıflandırma için uygun olan seçildiğinde, eğitime aşamasına geçilir ve Beklenti-Enbüyüklem algoritması uygulanarak, Υ vektörünün içerdiği model parametreleri bulunur. Bu çalışmada, m 1 ile 4 arasında değişmektedir. Bileşen dağılımları için ise isteğe bağlı kovaryans matrisi seçilmiş ve karşılık gelen ifadeler kullanılmıştır.

2.6. Destek Vektör Makinaları (DVM)

Bu yöntemde [10], $M = 19$ sınıflı problem, sınıfların olası tüm ikili kombinasyonları düşünülerek $\frac{M(M-1)}{2}$ adet iki sınıflı problemler olarak ele alınır. Her bir problemde sınıflar -1 ve $+1$ sayıları ile etiketlenir. Sınıfların istenildiği gibi doğrusal olarak ayrılabilir olmaması nedeniyle çok terimli çekirdek fonksiyon, $K(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x} \cdot \mathbf{x}_i)^p$ kullanılmıştır. Bu denklemde $p = 1$ alınmıştır.

3. DENEYSEL ÇALIŞMALAR

3.1. Veri Toplama

Bu çalışmada ayırıldıkları sırasıyla şunlardır: Oturma (A1), ayakta durma (A2), sırt üstü ve sağ taraf üzerine uzanma

(A3 ve A4), merdiven inme ve çıkma (A5 ve A6), asansörde hareketsiz ayakta durma ve gezinme (A7 ve A8), otoparkta yürüme (A9), koşu bandında 4 km/saat hızda yürüme (yatay olarak ve yere 15° açıyla) (A10 ve A11), koşu bandında 8 km/saat hızda koşma (A12), step yapma (A13), çapraz egzersiz cihazı kullanma (A14), egzersiz bisikletinde yatay ve açılı konumda pedal çevirme (A15 ve A16), kürek çekme (A17), zıplama (A18) ve basketbol oynama (A19).

Aktivite her biri, dördü bayan dördü erkek olmak üzere 20–30 yaşları arasında sekiz denek tarafından beş dakika süresince yapılmıştır. Deneklerin aktiviteleri yapış biçimlerine karıştırılmamıştır. 25 Hz örnekleme hızı ile 5 dk boyunca alınan veriler beş saniyelik parçalara bölünmüştür. Bu durumda tüm deneklerden her bir aktivite için 480 (= 60 × 8) sinyal elde edilmiştir.

3.2. Öznitelik Çıkarma

Veriler yukarıda anlatıldığı gibi elde edildiğinde $N_s \times 1$ boyutlarında bir vektör olan $s = [s_1, s_2, \dots, s_{N_s}]^T$ ile temsil edilebilen bir ayrık zaman dizisi elde edilmektedir. Sinyal segmanlarının uzunluğu 5 sn ve örnekleme hızı 25 Hz ise $N_s = 125$ olmaktadır. Başlangıçta bu dizilerin her biri için 26 adet öznitelik değeri bulunmuştur. Bu öznitelikler, s dizisinin en küçük ve en büyük değerleri, ortalama değeri, 1., 3. ve 4. momentleri, özilinti işlevi üzerinde eşit aralıklarla seçilmiş 10 tane örnek nokta, ayrık Fourier dönüşüm sinyalinin en büyük beş değeri ve bunlara karşılık gelen frekans değerleridir.

Çalışmada kullanılan beş duyucu ünitesinin her birinde üç-eksenli üç adet duyucunun her bir ekseninden ayrı ayrı veri elde edildiği düşünüldüğünde, 5 sn uzunluğundaki segmanlardan her bir öznitelik için 45 (= 9 eksen × 5 ünite) ayrı değer elde edilmektedir. Bu hesaplama tüm öznitelikler için yapılırsa, 1,170 (= 26 öznitelik × 45 değer) öznitelik değeri elde edilmektedir. Oluşan 1,170 × 1 boyutlu öznitelik vektörü normalize edilerek tüm öznitelikler [0,1] aralığına taşınmıştır. 5 dk uzunluğundaki aktivite verisinden 60 tane 5 sn uzunluğunda birim elde edildiğine göre, toplamda 1,170 × 1 boyutundaki öznitelik vektörlerinden 9,120 tane (= 60 öznitelik vektörü × 19 aktivite × 8 denek) oluşturulmaktadır.

Yukarıdaki hesaplamalar sonucunda ortaya çıkan 1,170 × 9,120 öznitelik matrisi, eğitim için çok büyük olduğundan ve öznitelik değerlerinin hepsinin bilgi içeriği aynı olmadığından, asal bileşenler analizi yöntemi ile sınıflandırmada kullanılan öznitelik sayısı azaltılmıştır. Bu işlem ile öznitelik matrisi 30 × 9,120 boyutlarında bir matrise dönüştürülmüştür.

3.3. Sonuçlar

Bu aşamada, çapraz sağlama için tekrarlanan rastgele altörnekleme (TRA), P -bölme ve birini dışarıda bırakma (BDB) yöntemleri kullanılmıştır. TRA yöntemi için her bir aktiviteden elde edilen 480 öznitelik vektörü rastgele bir biçimde biri 320 (her bir denekten 40 adet) ve diğeri 160 (her bir denekten 20 adet) öznitelik vektörü bulunduracak biçimde iki bölmeye ayrılmıştır. Bu durumda toplamda öğrenme için 6,080 ve deneme için 3,040 öznitelik vektörü kullanılmıştır. P -bölme yönteminde, 9,120 öznitelik vektörü $P = 10$ gruba rastgele ayrılmış, bu gruplardan $P - 1$ tanesi eğitime ve kalan bir tanesi ise deneme için kullanılmıştır. BDB yöntemi

ise denek tabanlı bir sınamadır. Deneklerin yedi tanesinden elde edilen öznitelik vektörleri (7,980 adet) öğrenme için, kalan bir denekten elde edilenler (1,140 adet) ise deneme için kullanılmıştır. Bu işlem, deneklerin her birinin öznitelik vektörleri deneme vektörü olarak kullanılana kadar (yani sekiz defa) tekrarlanmıştır. Tablo 1'de verilen başarı oranları, TRA yöntemi için 10, P -bölme yöntemi için 10 ve BDB yöntemi için 8 eğitime ve deneme döngüsünün ortalamasıdır.

	Sınıflandırma Yöntemleri	Çapraz Sağlama		
		TRA	P -bölme	BDB
WEKA	BB	93.87±0.49	93.70±0.08	89.20± 5.60
	YSA	99.00±0.09	99.09±0.08	90.34± 5.97
	DVM	98.09±0.11	98.90±0.03	90.73± 4.83
	BB-KA	94.60±0.68	94.93±0.16	67.68± 6.35
	J48-KA	93.84±0.73	94.50±0.17	76.97± 7.06
	RO-KA	98.29±0.24	98.60±0.05	86.81± 5.71
PRTools	BB	96.46±0.46	96.63±0.07	83.84± 0.63
	YSA	92.64±3.10	91.07±3.02	84.65± 3.85
	BTS	94.67±0.60	94.64±0.33	88.97± 4.50
	GKM ₁	99.05±0.20	99.12±0.02	76.37± 8.71
	GKM ₂	98.78±0.17	98.95±0.04	48.09± 8.47
	GKM ₃	98.18±0.30	98.95±0.06	37.64±10.25
	GKM ₄	97.32±0.37	98.80±0.08	37.01± 9.21

Tablo 1: Tüm duyuculardan elde edilen verilerden çıkarılan öznitelik vektörleri kullanılarak elde edilen başarı oranları.

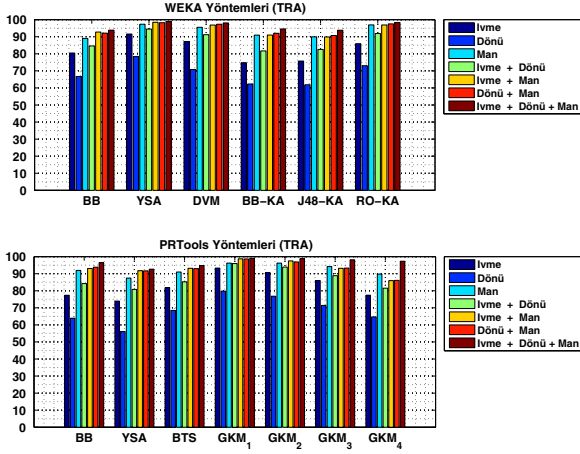
Denemeler her bir duyucu çeşidi kombinasyonu ve tüm çapraz sağlama yöntemleri için ayrı ayrı yapılmıştır. Tablo 1, tüm duyucu verilerinin kullanıldığı durum için başarı oranlarını ve standart sapma değerlerini vermekte, Şekil 1–3 ise başarı oranlarını çizgesel olarak göstermektedir.

Tüm ayırtma yöntemleri arasında en yüksek başarı oranını %99.12 ile GKM₁ yöntemi, P -bölme çapraz sağlama uygulandığında vermiştir (Tablo 1). Ancak diğer sınam yöntemleri, özellikle BDB çapraz sağlama yöntemi kullanıldığında ve GKM bileşenleri arttıkça (1, 2, 3 ve 4) bu yöntem ile elde edilen başarı oranlarının hızla düştüğü görülmüştür. Bu durumda denekler arası farklılara daha az duyarlı olan YSA veya DVM tercih edilebilir. Ayrıca YSA ve DVM, P -bölme ile sınılandığında sırasıyla, %99.09 ve %98.90 başarı oranları elde edilmiştir. Bu durumda da GKM ile aralarında başarı oranı açısından büyük bir fark yoktur.


Başarı oranları çapraz sınam yöntemlerine göre karşılaştırıldığında P -bölme yönteminin en yüksek oranları verdiği görülmüştür. Bu oranları az bir farkla TRA yöntemi kullanılarak elde edilen sonuçlar izlemiştir. En düşük başarı oranlarını ise BDB yöntemi kullanıldığında alınan sonuçlar vermiştir. Bu beklenen bir durumdur çünkü öğrenme aşamasında en fazla öznitelik vektörü P -bölme yönteminde kullanılmıştır. Ayrıca BDB yönteminde öğrenme aşamasında dışarıda bırakılan denek ve diğer denekler arasındaki farklar bu yöntem için başarı oranlarını düşürmektedir.

Karşılaştırma, her bir duyucu çeşidi kombinasyonuna göre yapıldığında ortaya çıkan sonuçlara göre, yalnızca dönüölçerin kullanıldığı durumda en düşük, manyetometre kullanıldığı durumda ise en yüksek başarı oranları elde edilmiştir. Dönüölçer içeren ikili kombinasyonlarda da başarı oranının düşük olduğu görülmektedir. Denemelere göre en başarılı duyucular sırasıyla manyetometre, ivmeölçer ve dönüölçerdir. Ancak manyetometrelerin elektromanyetik dalgalardan ve metal yüzeylerden

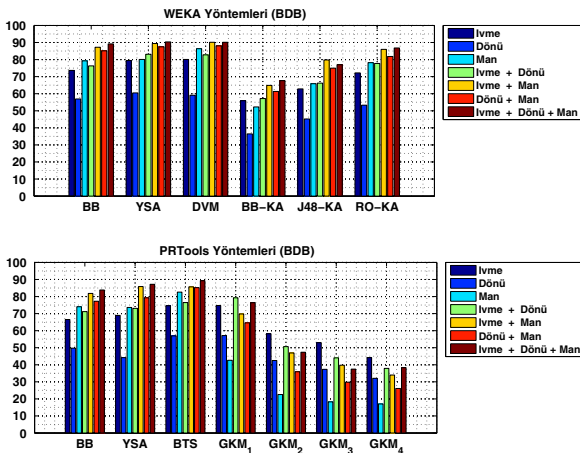
etkilendiği düşünüldüğünde veri elde etmek için sadece bu algılayıcı tipinin kullanılması istenmeyen sonuçlara yol açabilir.



Şekil 1: TRA çapraz sağlamasına göre başarı oranları.



Şekil 2: P-bölme çapraz sağlamasına göre başarı oranları.



Şekil 3: BDB çapraz sağlamasına göre başarı oranları.

Kullanılan yazılımlar açısından bakıldığında WEKA'nın kullanılan parametrelerdeki değişimlere daha az duyarlı olduğu görülmüştür. Gerçek zamanlı uygulamalar için WEKA'da bulunan algoritmaların kullanımı düşünülebilir.

4. KAPANIŞ

Bu çalışmada vücut üzerinde, göğüse, kollara ve bacaklara takılan her biri üç-eksenli ivmeölçer, dönüölçer ve manyetometre ile elde edilen veri üzerinde çeşitli örüntü tanıma yöntemleri kullanılarak 19 farklı aktivitenin ayırılması gerçekleştirilmiş ve üç farklı çapraz sınamaya yöntemi kullanılarak başarı oranları karşılaştırılmıştır. Çalışmanın devamında vücudun belirtilen bölgelerinden hangisindeki duyu-cuların daha verimli sonuçlar verdiği araştırılacaktır. Bunun yanı sıra sınıflandırma ile eş zamanlı olarak konum belirleme çalışmaları yapılacaktır.

5. TEŞEKKÜR

Bu çalışma, TÜBİTAK 109E059 projesi tarafından desteklenmiştir. Veri toplama aşamasındaki katkılarından dolayı Orkun Tunçel ile Kerem Altun'a ve kendilerinden veri elde ettiğimiz gönüllü deneklere teşekkür ederiz.

6. KAYNAKÇA

- [1] Wang L., Hu W., Tan T., "Recent developments in human motion analysis," *Pattern Recogn.*, 36(3): 585–601, 2003.
- [2] Moeslund T. B., Hilton A., Krüger V., "A survey of advances in vision-based human motion capture and analysis," *Comput. Vis. Image Und.*, 104(3): 90–126, 2006.
- [3] Bao L., Intille S. S., "Activity recognition from user-annotated acceleration data," in *Proc. Pervasive Computing*, 3001: 1–17, 2004.
- [4] Altun K., Barshan B., Tunçel O., "Comparative study on classifying human activities with miniature inertial and magnetic sensors," *Pattern Recogn.*, 43(10): 3605–3620, 2010.
- [5] Hall M., Frank E., Holmes G., Pfahringer B., Reutemann P., Witten I. H., "The WEKA data mining software: an update," *ACM SIGKDD Explorations Newsletter*, 11: 10–18, 2009 (<http://www.cs.waikato.ac.nz/ml/weka>).
- [6] Duin R. P. W., Juszczak P., Paclik P., Pekalska E., Ridder D. de, Tax D. M. J., Verzakov S., *PRTools4.1 A Matlab Toolbox for Pattern Recognition*, Delft Teknoloji Üniversitesi, Delft, Hollanda, Ağustos 2007 (<http://www.prtools.org/download.html>).
- [7] Haykin S., *Neural Networks*, New York: Macmillan Publishing, 1994.
- [8] Duda R. O., Hart P. E., Stork D. G., *Pattern Classification*, New York: John Wiley & Sons Inc., 2001 (2nd ed.).
- [9] Quinlan J. R., *C4.5: Programs for Machine Learning*, San Mateo, CA, USA: Morgan Kaufmann, 1993.
- [10] Schölkopf B., Burges C. J. C., *Introduction to Support Vector Learning*, Cambridge, MA, USA: MIT Press, 1999.