

**T.C.
SİİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GIYİLEBİLİR SENSÖR İŞARETLERİNDEN HAREKET TANIMA İÇİN YENİ
YAKLAŞIMLAR**

DOKTORA TEZİ

**Fatma KUNCAN
(153113003)**

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Yılmaz KAYA

**Haziran-2019
SİİRT**

TEZ KABUL VE ONAYI

Fatma KUNCAN tarafından hazırlanan “Giyilebilir Sensör İşaretlerinden Hareket Tanıma İçin Yeni Yaklaşımlar” adlı tez çalışması 20/06/2019 tarihinde aşağıdaki jüri tarafından oybirliği ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Hüseyin Metin ERTUNÇ



Danışman

Dr. Öğr. Üyesi Yılmaz KAYA



Üye

Doç. Dr. Fevzi HANSU



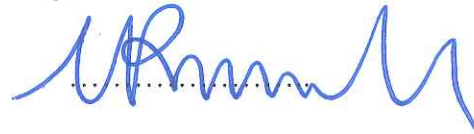
Üye

Doç. Dr. Ömer Faruk ERTUĞRUL



Üye

Dr. Öğr. Üyesi Mehmet Recep MİNAZ



Yukarıdaki sonucu onaylarım.



Doç. Dr. Fevzi HANSU
Fen Bilimleri Enstitüsü Müdürü

Bu tez çalışması, Siirt Üniversitesi BAP Koordinatörlüğü tarafından 2018-SİÜFEB-DR-009 nolu proje ile desteklenmiştir.

ÖNSÖZ

Bu tez çalışmasının hazırlanmasında bana her yönüyle rehberlik eden, bilgi ve tecrübesini aktarmada en küçük ayrıntıyı dahi esirgemeyen, çalışma sürecinin son gününe kadar bana her türlü fedakârlığı gösteren ve ayrıca kıymetli zamanını esirgmeden tezimin yazımı ve düzenlenmesi konularında her yönüyle katkı sunan danışman hocam Sayın Dr. Öğr. Üyesi Yılmaz KAYA' ya sonsuz teşekkürlerimi sunarım.

Ayrıca;

Eğitim hayatım boyunca, benim için en iyi şartları sağlayan, daima fedakâr davranan ve bugünlere gelmeme vesile olan kıymetli anneme ve babama şükranlarımı sunar, tez çalışmasının her aşamasında desteklerini esirgemeyen eşime ve çocuklarıma teşekkürlerimi bir borç bilirim.

Son olarak, bu çalışma Siirt Üniversitesi Rektörlüğü Bilimsel Araştırma Projeleri BAP Koordinasyon Birimi Koordinatörlüğü tarafından 2018-SİÜFEB-DR-009 no'lu proje olarak desteklenmiştir. Bu çalışmanın yazarları, verilen destekten dolayı Siirt Üniversitesi Rektörlüğü'ne teşekkür ederler.


Fatma KUNCAN
SİİRT-2019

İÇİNDEKİLER

Sayfa

ÖNSÖZ	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	ix
KISALTMALAR VE SİMGELER LİSTESİ.....	xiv
ÖZET	xvi
ABSTRACT.....	xvii
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI	5
3. MATERYAL VE METOT.....	21
3.1. Materyal	21
3.2. Metot.....	23
3.2.1. Yerel İkili Örüntüler (YİÖ).....	23
3.2.2. Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ).....	26
3.2.3. Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler (OT-1B-YİÖ).....	29
3.2.4. Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler (MT-1B-YİÖ).....	31
3.2.5. Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler (ÇÖ-1B-YİÖ).....	34
3.2.6. Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-YİÖ) .	37
3.2.7. Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler (KT-1B-YİÖ).....	41
3.2.8. Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler (K-1B-YİÖ).....	44
3.2.9. Üçlü Desenli Bir Boyutlu Yerel İkili Örüntüler (ÜD-1B-YİÖ).....	48
3.2.10. İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler (İ-1B-YİÖ).....	53
3.3. İstatistiksel Öznitelikler	61
3.3.1. Ortalama.....	61
3.3.2. Standart Sapma	62
3.3.3. Enerji.....	62
3.3.4. Entropi	62
3.3.5. Korelasyon	63
3.3.6. Ardışık Mutlak Fark.....	64
3.3.7. Medyan	64
3.3.8. Çarpıklık	65
3.3.9. Basıklık	66
3.3.10. Minimum	67
3.3.11. Maksimum	67
3.3.12. Varyasyon Katsayısı	67
3.3.13. Hareketli Korelasyon	68

3.4. Sınıflandırma	68
3.4.1. RO Algoritmasının Tanımı ve Özellikleri	68
3.4.2. RO Algoritma Yapısı	70
3.4.3. RO Modelinden Elde Edilen Çıkarımlar	71
3.4.4. Avantaj ve Dezavantajları.....	72
3.5. Önerilen Sistem.....	73
3.6. Performans Ölçütleri.....	75
3.6.1. Doğruluk Oranı	76
3.6.2. Hata Oranı.....	76
3.6.3. Kesinlik	76
3.6.4. Duyarlılık	77
3.6.5. F ölçütü	77
4. BULGULAR ve TARTIŞMA	78
4.1. Başarı Oranları	78
4.1.1. 1B-YİÖ Metodunun Uygulanması.....	78
4.1.2. OT-1B-YİÖ Metodunun Uygulanması.....	80
4.1.3. MT-1B-YİÖ Metodunun Uygulanması	83
4.1.4. ÇÖ-1B-YİÖ Metodunun Uygulanması.....	85
4.1.5. A-1B-YİÖ Metodunun Uygulanması	87
4.1.6. KT-1B-YİÖ Metodunun Uygulanması.....	90
4.1.7. K-1B-YİÖ Metodunun Uygulanması	93
4.1.8. ÜD-1B-YİÖ Metodunun Uygulanması	96
4.1.9. İ-1B-YİÖ Metodunun Uygulanması.....	100
4.2. Yöntemlerin Karşılaştırılması.....	104
4.3. En İyi Yöntemin İncelenmesi	105
4.3.1. Sensör Türlerine Göre Başarı Oranları	105
4.3.2. Eksenlerine Göre Başarı Oranları	110
4.3.3. İstatistiksel Özniteliklere Göre Başarı Oranları	114
4.3.4. Sensörlerin Bağlandığı Vücut Bölgelerine Göre Başarı Oranları.....	126
4.4. En İyi Yöntemin Farklı Sınıflandırıcılar ile Sınıflandırılması.....	130
5. SONUÇLAR ve ÖNERİLER.....	131
6. KAYNAKLAR	138
ÖZGEÇMİŞ	149

TABLolar LİSTESİ

Tablo 2.1. Literatürdeki farklı hareket çalışmaları	18
Tablo 3.1. Veri setinde yer alan hareketler	21
Tablo 3.2. Veri setinde bulunan sütunlara ait bilgiler.....	22
Tablo 4.1. 1B-YİÖ Yöntemine göre hareket tanıma başarı oranları (%)	78
Tablo 4.2. 1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi ..	80
Tablo 4.3. 1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları	80
Tablo 4.4. OT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi	82
Tablo 4.5. OT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları	82
Tablo 4.6. MT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi	84
Tablo 4.7. MT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları	84
Tablo 4.8. Farklı komşuluk değerlerine göre ÇÖ-1B-YİÖ metodu ile elde edilen başarı oranları	86
Tablo 4.9. ÇÖ-1B-YİÖ yöntemine göre $P=12$ için RO sınıflandırma metodu karışıklık matrisi	86
Tablo 4.10. ÇÖ-1B-YİÖ yöntemine göre $P=12$ için RO sınıflandırma metodu performans sonuçları.....	87
Tablo 4.11. A-1B-YİÖ yöntemine göre RO sınıflandırma metodu karışıklık matrisi....	89
Tablo 4.12. A-1B-YİÖ yöntemine göre RO sınıflandırma metodu performans sonuçları	89
Tablo 4.13. Farklı α ve β değerleri için KT-1B-YİÖ yöntemine göre elde edilen başarı oranları	91
Tablo 4.14. $\alpha=2$ ve $\beta=1$ alınarak KT-1B-YİÖ yöntemine göre RO sınıflandırma metodu karışıklık matrisi	92
Tablo 4.15. $\alpha=2$ ve $\beta=1$ alınarak KT-1B-YİÖ yöntemine göre RO sınıflandırmada performans sonuçları.....	92
Tablo 4.16. Farklı PL ve PR değerleri alınarak K-1B-YİÖ yöntemine göre başarı oranları	95
Tablo 4.17. $PL=4$ ve $PR=4$ alınarak K-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık	95
Tablo 4.18. $PL=4$ ve $PR=4$ alınarak K-1B-YİÖ yöntemine göre RO sınıflandırmada performans sonuçları.....	96
Tablo 4.19. Farklı β değeri alınarak ÜD-1B-YİÖ yöntemine göre başarı oranları	98
Tablo 4.20. $\beta=2.5 \times SS$ alınarak ÜD-1B-YİÖ yöntemine göre Üst öznitelik grubuna RO sınıflandırma	99
Tablo 4.21. $\beta=2.5 \times SS$ alınarak ÜD-1B-YİÖ yöntemine göre Üst öznitelik grubuna RO sınıflandırma	99
Tablo 4.22. Farklı parametrelere göre İ-1B-YİÖ metodu uygulaması başarı oranları (%)	102
Tablo 4.23. $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ yöntemine göre RO sınıflandırma.....	103
Tablo 4.24. $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ yöntemine göre RO sınıflandırma.....	103

Tablo 4.25. Geliştirilen yöntemlerin RO sınıflandırma metoduna göre karşılaştırılması	104
Tablo 4.26. Hareket türüne göre yöntemlerin başarı oranları (%).....	105
Tablo 4.27. İvme sensörleri için RO ile elde edilen karışıklık matrisi	106
Tablo 4.28. İvme sensörleri için RO ile elde edilen performans oranları.....	106
Tablo 4.29. Jireskop(Gyro) sensörleri için RO ile elde edilen karışıklık matrisi	107
Tablo 4.30. Jireskop(Gyro) sensörleri için RO ile elde edilen performans oranları.....	107
Tablo 4.31. Manyetometre (Magnetometer) sensörleri için RO ile elde edilen karışıklık matrisi	108
Tablo 4.32. Manyetometre (Magnetometer) sensörleri için RO ile elde edilen performans oranları	108
Tablo 4.33. EKG İşaretleri için RO ile elde edilen karışıklık matrisi	109
Tablo 4.34. EKG İşaretleri için RO ile elde edilen performans oranları	109
Tablo 4.35. Sensör türlerine göre başarı oranları.....	110
Tablo 4.36. X Ekseni için RO ile elde edilen karışıklık matrisi	110
Tablo 4.37. X Ekseni için RO ile elde edilen performans oranları.....	111
Tablo 4.38. Y Ekseni için RO ile elde edilen karışıklık matrisi	111
Tablo 4.39. Y Ekseni için RO ile elde edilen performans oranları.....	112
Tablo 4.40. Z Ekseni için RO ile elde edilen karışıklık matrisi.....	112
Tablo 4.41. Z Ekseni için RO ile elde edilen performans oranları	113
Tablo 4.42. Eksen türlerine göre başarı oranları.....	113
Tablo 4.43. Ortalama öznitelikleri için RO ile elde edilen karışıklık matrisi.....	114
Tablo 4.44. Ortalama öznitelikleri için RO ile elde edilen performans oranları	114
Tablo 4.45. Standart Sapma için RO ile elde edilen karışıklık matrisi.....	115
Tablo 4.46. Standart Sapma için RO ile elde edilen performans oranları	115
Tablo 4.47. Enerji için RO ile elde edilen karışıklık matrisi	116
Tablo 4.48. Enerji için RO ile elde edilen performans oranları.....	116
Tablo 4.49. Entropi için RO ile elde edilen karışıklık matrisi	117
Tablo 4.50. Entropi için RO ile elde edilen performans oranları	117
Tablo 4.51. Korelasyon için RO ile elde edilen karışıklık matrisi	118
Tablo 4.52. Korelasyon için RO ile elde edilen performans oranları	118
Tablo 4.53. Ardışık mutlak fark için RO ile elde edilen karışıklık matrisi	119
Tablo 4.54. Ardışık mutlak fark için RO ile elde edilen performans oranları	119
Tablo 4.55. Medyan için RO ile elde edilen karışıklık matrisi.....	120
Tablo 4.56. Medyan için RO ile elde edilen performans oranları	120
Tablo 4.57. Çarpıklık için RO ile elde edilen karışıklık matrisi.....	121
Tablo 4.58. Çarpıklık için RO ile elde edilen performans oranları	121
Tablo 4.59. Basıklık için RO ile elde edilen karışıklık matrisi.....	122
Tablo 4.60. Basıklık için RO ile elde edilen performans oranları	122
Tablo 4.61. Minimum için RO ile elde edilen karışıklık matrisi.....	123
Tablo 4.62. Minimum için RO ile elde edilen performans oranları	123
Tablo 4.63. Maksimum için RO ile elde edilen karışıklık matrisi.....	124
Tablo 4.64. Maksimum için RO ile elde edilen performans oranları	124
Tablo 4.65. Varyasyon katsayısı için RO ile elde edilen karışıklık matrisi.....	125
Tablo 4.66. Varyasyon katsayısı için RO ile elde edilen performans oranları	125
Tablo 4.67. İstatistiksel Özniteliklere Göre Başarı Oranları	126
Tablo 4.68. Göğüs bölgesinden elde edilen öznitelikler için RO ile elde edilen karışıklık matrisi	127
Tablo 4.69. Göğüs bölgesinden elde edilen öznitelikler için RO ile elde edilen performans oranları	127

Tablo 4.70. Sol ayak bileğinden elde edilen öznelilikler için RO ile elde edilen karışıklık matrisi	128
Tablo 4.71. Sol ayak bileğinden elde edilen öznelilikler için RO ile elde edilen performans oranları	128
Tablo 4.72. Sağ el bileğinden elde edilen öznelilikler için RO ile elde edilen karışıklık matrisi	129
Tablo 4.73. Sağ el bileğinden elde edilen öznelilikler için RO ile elde edilen performans oranları	129
Tablo 4.74. Sensörlerin bağlandığı vücut bölgelerine göre başarı oranları	130
Tablo 4.75. En iyi yöntemin farklı metotlarda hareket tanıma başarı oranları (%)	130



ŞEKİLLER LİSTESİ

Sayfa

Şekil 3.1. Tüm hareketlere ait örnek işaretler (A) L1 (hareketsiz durma) hareketi, (B) L2 (oturma ve rahatlama) hareketi, (C) L3 (uzanma) hareketi, (D) L4 (yürüme) hareketi, (E) L5 (merdiven çıkma) hareketi, (F) L6 (öne eğilme) hareketi, (G) L7 (kolları yukarı kaldırma) hareketi, (H) L8 (dizleri bükme) hareketi, (I) L9 (bisiklet sürme) hareketi, (J) L10 (tempolu yürüyüş yapma) hareketi, (K) L11 (koşma) hareketi, (L) L12 (öne ve arkaya zıplama) hareketi	23
Şekil 3.2. Farklı YİÖ uygulamaları	25
Şekil 3.3. YİÖ etiketinin oluşturulması	26
Şekil 3.4. 1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	27
Şekil 3.5. 1B-YİÖ metoduna göre merkez değer ve komşu değerler	27
Şekil 3.6. 1B-YİÖ metoduna göre ikili dizge	28
Şekil 3.7. 1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	28
Şekil 3.8. OT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	29
Şekil 3.9. OT-1B-YİÖ metoduna göre merkez değer ve komşu değerler	30
Şekil 3.10. OT-1B-YİÖ metoduna göre ikili dizge	30
Şekil 3.11. OT-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	31
Şekil 3.12. MT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	32
Şekil 3.13. MT-1B-YİÖ metoduna göre merkez değer ve komşu değerler.....	32
Şekil 3.14. Ortanca değer.....	33
Şekil 3.15. MT-1B-YİÖ metoduna göre ikili dizge.....	33
Şekil 3.16. MT-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket	33
Şekil 3.17. $P=6$ alınarak ÇÖ-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	35
Şekil 3.18. $P=12$ alınarak ÇÖ-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	35
Şekil 3.19. $P=12$ alınarak ÇÖ-1B-YİÖ metoduna göre merkez değer ve komşu değerler	36
Şekil 3.20. $P=12$ alınarak ÇÖ-1B-YİÖ metoduna göre ikili dizge.....	36
Şekil 3.21. ÇÖ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	37
Şekil 3.22. A-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	38
Şekil 3.23. A-1B-YİÖ metoduna göre merkez değer ve komşu değerler.....	38
Şekil 3.24. A-1B-YİÖ metoduna göre ikili dizge	40
Şekil 3.25. A-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	40
Şekil 3.26. $\alpha=1$ ve $\beta=2$ alınarak KT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm.....	41
Şekil 3.27. $\alpha=2$ ve $\beta=2$ alınarak KT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm.....	42
Şekil 3.28. $\alpha=2$ ve $\beta=2$ alınarak KT-1B-YİÖ metoduna göre merkez değer ve komşu değerler	42

Şekil 3.29. KT-1B-YİÖ metoduna göre ikili dizge	43
Şekil 3.30. KT-1B-YİÖmetodu ile elde edilen onlu tabanlı etiket	43
Şekil 3.31. $PL=6$ ve $PR=2$ alınarak K-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	45
Şekil 3.32. $PL=3$ ve $PR=5$ alınarak K-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	46
Şekil 3.33. $PL=3$ alınarak K-1B-YİÖ metoduna göre seçilen merkez değer ve komşu değerler	46
Şekil 3.34. $PL=3$ alınarak K-1B-YİÖ metoduna göre ikili dizge	47
Şekil 3.35. K-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	47
Şekil 3.36. Farklı β değerlerine göre filtreleme (A) $\beta=0.050$ için filtreleme, (B) $\beta=0.0875$ için filtreleme, (C) $\beta=0.125$ için filtreleme	49
Şekil 3.37. $\beta=0.0875$ alınarak ÜD-1B-YİÖ metodu ile öznitelik çıkarımı L3(uzanma) hareketi işaretine ait bir bölüm	50
Şekil 3.38. ÜD-1B-YİÖ metoduna göre seçilen merkez değer ve komşu değerler.....	50
Şekil 3.39. Komşu değerlerin $\beta=0.0875$ değerine göre merkez değer ile karşılaştırılarak ikili dizgenin oluşturulması.....	51
Şekil 3.40. Üst özellik grubuna ait ikili dizge.....	51
Şekil 3.41. ÜD-1B-YİÖ _{ÜST} metodu ile elde edilen onlu tabanlı etiket.....	52
Şekil 3.42. Alt özellik grubuna ait ikili dizge	52
Şekil 3.43. ÜD-1B-YİÖ _{ALT} metodu ile elde edilen onlu tabanlı etiket.....	52
Şekil 3.44. İ-1B-YİÖ metodunun uygulanması (A) orijinal işaret, (B)1. seviye indirgeme, (C) 2. seviye indirgeme	54
Şekil 3.45. İ-1B-YİÖ metodunun $PB=4$, Özellik= EK , $n=3$ parametreleri ile uygulanması (A) orijinal işaret, (B)1. seviye indirgeme, (C)2. seviye indirgeme	55
Şekil 3.46. İ-1B-YİÖ metodu ile öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm	56
Şekil 3.47. İ-1B-YİÖ metoduna göre $n=1$ grubu için örnek seçilen merkez değer ve komşu değerler	56
Şekil 3.48. $n=1$ grubu için İ-1B-YİÖmetoduna göre ikili dizge	57
Şekil 3.49. $n=1$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	57
Şekil 3.50. İ-1B-YİÖ metodu ile öznitelik çıkarımı için indirgenmiş işarete ait bir bölüm	58
Şekil 3.51. İ-1B-YİÖ metoduna göre $n=2$ grubu için örnek seçilen merkez değer ve komşu değerler	58
Şekil 3.52. $n=2$ grubu için İ-1B-YİÖ metoduna göre ikili dizge	59
Şekil 3.53. $n=2$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	59
Şekil 3.54. İ-1B-YİÖ metodu ile öznitelik çıkarımı için ikinci defa indirgenmiş sensör işaretine ait bir.....	59
Şekil 3.55. İ-1B-YİÖ metoduna göre $n=3$ grubu için örnek seçilen merkez değer ve komşu değerler	60
Şekil 3.56. $n=3$ grubu için İ-1B-YİÖmetoduna göre ikili dizge	60
Şekil 3.57. $n=3$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket.....	60
Şekil 3.58. Korelasyon durumları (A) Değişkenler arası aynı yönlü ilişki, (B) Değişkenler arası zıt yönlü ilişki, (C) Değişkenler arası ilişki yok.....	64
Şekil 3.59. Çarpıklık durumları (A) Çarpıklık olmayan durum, (B) Pozitif çarpıklık durumu, (C) Negatif çarpıklık durumu	65
Şekil 3.60. Basıklık durumları (A) $BK>0$ durumunda basıklık, (B) $BK=0$ durumunda normal dağılım, (C) $BK<0$ durumunda basıklık	66
Şekil 3.61. RO algoritmasına ait ağaç ormanı	69

- Şekil 3.62. Önerilen metotların uygulanmasına ait blok diyagramı 74
- Şekil 4.1. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait 1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketi işaretine ait 1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram..... 79
- Şekil 4.2. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait OT-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait OT-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram..... 81
- Şekil 4.3. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait MT-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait MT-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram..... 83
- Şekil 4.4. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve ÇÖ-1B-YİÖ metodunun uygulanması (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait P=8 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (C) P=8 alınarak L1 (hareketsiz durma) hareketine ait histogram, (D) L1 (hareketsiz durma) hareketine ait P=10 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (E) P=10 alınarak L1 (hareketsiz durma) hareketi işaretine ait histogram, (F) L1 (hareketsiz durma) hareketine ait P=12 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (G) P=12 alınarak L1 (hareketsiz durma) hareketi işaretine ait histogram 85
- Şekil 4.5. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait A-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait A-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram..... 88
- Şekil 4.6. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve farklı α ve β değerleri kullanılarak KT-1B-YİÖ metodunun uygulanması (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) $\alpha=1; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (C) $\alpha=1; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (D) $\alpha=1; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (E) $\alpha=2; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (F) $\alpha=2; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (G) $\alpha=2; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (H) $\alpha=3; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (I) $\alpha=3; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (J) $\alpha=3; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret 90

- Şekil 4.7. (A) $\alpha=1; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (B) $\alpha=1; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (C) $\alpha=1; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (D) $\alpha=2; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (E) $\alpha=2; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (F) $\alpha=2; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (G) $\alpha=3; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (H) $\alpha=3; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı (I) $\alpha=3; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı..... 91
- Şekil 4.8. Çalışmada kullanılan L1(hareketsiz durma) hareketine ait örnek işaret ve farklı PL değerleri kullanılarak K-1B-YİÖ metodunun uygulanması (A) L1(hareketsiz durma) hareketine ait örnek işaret, (B) $PL=0; PR=8$ değerleri örneği, (C) $PL=1; PR=7$ değerleri örneği, (D) $PL=2; PR=6$ değerleri örneği, (E) $PL=3; PR=5$ değerleri örneği, (F) $PL=4; PR=4$ değerleri örneği, (G) $PL=5; PR=3$ değerleri örneği, (H) $PL=6; PR=2$ değerleri örneği, (I) $PL=7; PR=1$ değerleri örneği 93
- Şekil 4.9. (A) $PL=0; PR=8$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (B) $PL=1; PR=7$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (C) $PL=2; PR=6$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (D) $PL=3; PR=5$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (E) $PL=4; PR=4$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (F) $PL=5; PR=3$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (G) $PL=6; PR=2$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (H) $PL=7; PR=1$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı (I) $PL=8; PR=0$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı 94
- Şekil 4.10. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve farklı β değerleri kullanılarak ÜD-1B-YİÖ metodunun uygulanması (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) $\beta=0.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (C) $\beta=1.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (D) $\beta=1.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (E) $\beta=2.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (F) $\beta=2.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (G) $\beta=3.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler 97
- Şekil 4.11. (A) $\beta=0.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (B) $\beta=1.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (C) $\beta=1.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (D) $\beta=2.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (E) $\beta=2.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (F) $\beta=3.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar..... 98
- Şekil 4.12. Çalışmada kullanılan L1(hareketsiz durma) hareketine ait örnek işaret ve bu işarete $PB=4$ ve ortalama özelliğine göre İ-1B-YİÖ metodunun uygulanması (A) L1(hareketsiz durma) hareketine ait örnek işaret, (B) Birinci aşamada elde edilen işaret ve bu işarete ait histogram, (C) İkinci aşamada elde edilen işaret ve bu işarete ait histogram, (D) Üçüncü aşamada elde edilen işaret ve bu işarete ait histogram 100

Şekil 4.13. Çalışmada kullanılan L2(oturma ve rahatlama) hareketine ait örnek işaret ve bu işarete $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ metodunun uygulanması (A) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (B) Birinci aşamada elde edilen işaret ve bu işarete ait histogram, (C) İkinci aşamada elde edilen işaret ve bu işarete ait histogram, (D) Üçüncü aşamada elde edilen işaret ve bu işarete ait histogram 101



KISALTMALAR VE SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
AAR	: İvmeye Dayalı Hızlanma Yöntemi
AB-1D-LBP	: Average Based One-Dimensional Local Binary Patterns
AHN	: Yapay Hidrokarbon Ağı
ALS	: Amyotrofik Lateral Skleroz
AMF	: Ardışık Mutlak Fark
ANN	: Artifical Neural Network
AR	: Activity Recognition
AQ	: Kuaterniyon Hızlanma Yöntemi
A-1B-YİÖ	: Ağırlıklandırılmış Bir Boyutlu Yerel İkili Örüntüler
BK	: Basıklık Katsayısı
BN	: Bayes Net
CAMRS	: Context-Aware Music Recommender Systems
CV	: Varyasyon Katsayısı
CFS	: Correlation Feature Selection
CNN	: Convolutional Neural Network
CNN-LSTM	: CNN Long Short Term Memory
ÇK	: Çarpıklık Katsayısı
ÇÖ-1B-YİÖ	: Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler
DBN	: Deep Belief Network
DMM	: Derinlik Hareket Haritaları
DVM	: Destek Vektör Makineleri
EB	: En Büyük
EEG	: Elektroensefalografi
EK	: En Küçük
EKG	: Elektrokardiyografi
EM-ÇKF	: Expectation Maksimizasyon-Çok Yönlü Konik Fonksiyonlar
EMG	: Elektromiyografi
FCBF	: Hızlı Korelasyona Dayalı Filtre Yöntemi
GMM	: Gauss Mixture Model
GMM	: Gizli Markov Model
GPS	: The Global Positioning System
HDM	: Hiyerarşik Dinamik Model
HK	: Hareketli Korelasyon
HMM	: Hidden Markov Model
HO	: Hata Oranı
HS	: Hareket Sensörleri
HT	: Hareket Tanıma
HT	: Hoeffding Tree
ICA	: Indepent Component Analyses
ICO	: Iterative Classifier Optimizer
İ-1B-YİÖ	: İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler
KNLR	: Kernel Nonlinear Regression
KNN	: K- Nearest Neighbour

KT-1B-YİÖ	: Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler
K-1B-YİÖ	: Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler
LB	: Logit Boost
LMT	: Logistic Model Tree
MAP	: Mobil Algılama Platformu
MB-1D-LBP	: Median Based One-Dimensional Local Binary Patterns
MD-1D-LBP	: Multi-Dimensional One-Dimensional Local Binary Patterns
med	: Medyan
MHEALTH	: Mobile Health
MLP	: Multilayer perceptron
MNN	: Modular Neural Network
MRMR	: Minimum Redundancy and Maximum Relevance
MSP	: Mobile Sensing Platform
MT-1B-YİÖ	: Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler
NB	: Naive Bayes
NB-1D-LBP	: Neighborhood Based One-Dimensional Local Binary Patterns
ort	: Ortalama
OSELM	: Online Sequential Extreme Learning Machine
OT-1B-YİÖ	: Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler
PAMAP2	: Physical Activity Monitoring Dataset
PB	: Pencere Boyutu
PCA	: Principal Component Analyses
PSO	: Parçacık Sürüsü Optimizasyonu
PSO-KNN	: Parçacık Sürüsü Optimizasyonu Temelli KNN Yaklaşımı
QDA	: Qualitative Data Analysis
RBF	: Radial Basis Function
RC	: Random Commitee
RF	: Random Forest
RNN	: Recurrent Neural Networks
RO	: Rastgele Orman
RSS	: Random Sub Space
R-1D-LBP	: Reduced One-Dimensional Local Binary Patterns
SL	: Simple Logistic
SLFN	: Elektrokardiyografi
SMO	: Sequential Minimal Optimisation
SS	: Standart Sapma
SVM	: Support Vector Machine
S-1D-LBP	: One-Dimensional Local Binary Patterns with Shift
TP-1D-LBP	: Ternary Patterned One-Dimensional Local Binary Patterns
ÜD-1B-YİÖ	: Üçlü Desenli Bir Boyutlu Yerel İkili Örüntüler
WEKA	: Waikato Environment for Knowledge Analysis
WISDM	: Wireless Sensor Data Mining
W-1D-LBP	: Weighted One Dimensional Robust Local Binary Patterns
YİÖ	: Yerel İkili Örüntü
YSA	: Yapay Sinir Ağları
1B-YİÖ	: Bir Boyutlu Yerel İkili Örüntüler
1D-LBP	: One Dimensional Local Binary Patterns

ÖZET

DOKTORA TEZİ

GIYİLEBİLİR SENSÖR İŞARETLERİNDEN HAREKET TANIMA İÇİN YENİ YAKLAŞIMLAR

Fatma KUNCAN

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman : Dr. Öğr. Üyesi Yılmaz KAYA

2019, 168 Sayfa

Son yıllarda insan hareketlerinin tanınması, izlenmesi ve ayırt edilmesi alanında birçok farklı çalışma yapılmaktadır. Hareket tanıma (HT) için genellikle iki ana yaklaşım kullanılmaktadır. Bunlar vizyon tabanlı (bilgisayarlı görü) yaklaşım ve sensör (algılayıcı) tabanlı yaklaşımdır. Sensör tabanlı yaklaşım, insan hareketlerinin durumunu yansıtan fizyolojik sinyallerin sürekli izlenmesini sağlayarak vücut hareketlerini algılamayı sağlamaktadır. HT sisteminde hareketleri birbirinden en iyi şekilde ayırt eden özneliklerin belirlenmesi gerekmektedir. Öznelik seçimi yapıldıktan sonra makine öğrenmesi yöntemleri ile sınıflandırma işlemleri gerçekleştirilmektedir. Özneliklerin iyi seçilmemesi durumunda sınıflandırma performansı düşeceğinden, öznelik çıkarımı örüntü tanıma sürecinde önemli bir rol oynamaktadır. Bu çalışmada HT için sensör işaretlerinden öznelik çıkarımını gerçekleştiren yeni yaklaşımlar önerilmektedir. Çalışma kapsamında öznelik çıkarımı için dokuz farklı yeni yaklaşım önerilmiştir. Bu yaklaşımlar: Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ), Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler (OT-1B-YİÖ), Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler (MT-1B-YİÖ), Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler (ÇÖ-1B-YİÖ), Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-YİÖ), Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler (KT-1B-YİÖ), Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler (K-1B-YİÖ), Üçlü Desenli Bir Boyutlu Yerel İkili Örüntüler (ÜD-1B-YİÖ) ve İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler (İ-1B-YİÖ) yöntemleridir. Önerilen yaklaşımlar görüntü işleme uygulamalarında sıkça kullanılan Yerel İkili Örüntüler metoduna dayalı olarak geliştirilen Bir Boyutlu Yerel İkili Örüntüler metodu baz alınarak geliştirilmiştir. Önerilen HT sistemi altı aşamadan oluşmaktadır. Birinci aşamada, insanların çeşitli fiziksel hareketlerine ait sensör işaretlerinin temini yapılmıştır. İkinci aşamada, bu sensör işaretlerine geliştirilen öznelik çıkarım yöntemleri uygulanarak daha anlamlı işaretler elde edilmiştir. Üçüncü aşamada, elde edilen anlamlı işaretlerin histogramları oluşturulmuştur. Dördüncü aşamada, oluşturulan histogramlardan öznelikler elde edilmiştir. Beşinci aşamada, elde edilen öznelikler Rastgele Orman Algoritması (RO) makine öğrenmesi yöntemi ile sınıflandırılmıştır. Altıncı aşamada, çeşitli kriterlere göre geliştirilen öznelik çıkarım yöntemlerinin karşılaştırılmaları yapılmıştır. Geliştirilen yöntemler ile elde edilen özneliklerin Rastgele Orman algoritmasına göre sınıflandırılmaları yapılarak en yüksek başarı oranının %95,83 oranı ile İ-1B-YİÖ metodunda gerçekleştiği gözlenmiştir.

Anahtar Kelimeler: Hareket Tanıma, Öznelik Çıkarımı, Giyilebilir Sensör İşaretleri, 1B-YİÖ.

ABSTRACT

Ph.D. THESIS

NEW APPROACHES FOR MOTION RECOGNITION FROM THE WEARABLE SENSOR SIGNALS

Fatma KUNCAN

**The Graduate School of Natural and Applied Science of Siirt University
The Degree of Ph.D. in Electrical-Electronics Engineering**

Supervisor: Assist. Prof. Dr. Yılmaz KAYA

2019, 168 Pages

In recent years, there have been many different studies in the field of recognition, monitoring and differentiation of human movements. Two main approaches are generally used for activity recognition (AR). These are a vision-based approach and sensor-based approach. The sensor-based approach enables continuous monitoring of physiological signals that reflect the state of human movements, enabling the sensation of body movements. In the AR system, it is necessary to identify the attributes that best distinguish the movements from each other. After the feature selection is made, classification methods are carried out by machine learning methods. As the classification performance is reduced if the attributes are not selected well, attribute extraction plays an important role in the pattern recognition process. In this study, novel approaches to extracting features from sensor signals for AR are proposed. Nine different new approaches have been proposed for feature extraction. These approaches are: One-Dimensional Local Binary Patterns (1D-LBP), Average Based One-Dimensional Local Binary Patterns (AB-1D-LBP), Median Based One-Dimensional Local Binary Patterns (MB-1D-LBP), Multi-Dimensional One-Dimensional Local Binary Patterns (MD-1D-LBP), Weighted One Dimensional Robust Local Binary Patterns (W-1D-LBP), Neighborhood Based One-Dimensional Local Binary Patterns (NB-1D-LBP), One-Dimensional Local Binary Patterns with Shift (S-1D-LBP), Ternary Patterned One-Dimensional Local Binary Patterns (TP-1D-LBP) and Reduced One-Dimensional Local Binary Patterns (R-1D-LBP). The proposed approaches are developed based on the One-Dimensional Local Binary Patterns method developed based on the Local Binary Patterns method used frequently in image processing applications. The proposed AR system consists of six stages. In the first stage, sensor signals of various physical movements of the people were provided. In the second stage, more significant signals have been obtained by applying the feature extraction methods developed in these sensor signals. In the third stage, histograms of the significant signs obtained were generated. In the fourth stage, attributes were obtained from generated histograms. In the fifth stage, the obtained attributes are classified by Random Forest Algorithm machine learning method. In the sixth stage, the comparison of feature extraction methods developed according to various criteria was made. According to the Random Forest algorithm, the highest success rate was 95,83% and the R-1D-LBP method was used. In this study, it has been observed that AR treatment is performed with high success rates by using all new approaches and sensor signals.

Keywords: Activity Recognition, Feature Extraction, Wearable Sensor Signals, 1D-LBP.

1. GİRİŞ

Son yıllarda insan hareketlerinin tanınması, izlenmesi ve ayırt edilmesi alanında birçok farklı çalışma yapılmaktadır. İnsanın fiziksel hareketlerinin otomatik tanınması genelde insan hareket tanıma (HT) olarak tanımlanmaktadır. Hareket tanıma görevini yerine getirmek için iki ana yaklaşım bulunmaktadır. Bunlar vizyon tabanlı (bilgisayarlı görü) yaklaşım ve sensör (algılayıcı) tabanlı yaklaşımdır. Bilgisayarlı görü tabanlı yaklaşım genellikle laboratuvar şartlarında iyi çalışmaktadır; ancak, gerçek dünya senaryolarında dağınıklık, değişken ışık yoğunluğu ve kontrasttan dolayı başarısız olabilmektedir.

Sensör tabanlı HT sistemleri, kişinin vücuduna bağlı heterojen sensörleri kullanarak ve insan eylemlerinin durumunu yansıtan birçok fizyolojik sinyalin sürekli izlenmesine izin vererek kullanıcının ve çevresinin durumunu yakalamayı hedeflemektedir. Özellikle son yıllarda belirgin bir şekilde gelişen özel sensörlerin ve mobil cihazların hareket tanıma uygulamalarında kullanılmasıyla mikroelektronik ve bilgisayar sistemlerinde çok önemli ölçüde gelişim gösterdiği görülmüştür (Györbíró ve ark., 2009).

Hareketleri ve eylemleri analiz etmek uzun bir geçmişe sahip olmanın yanı sıra psikoloji, biyoloji ve bilgisayar bilimi gibi çeşitli disiplinlerle etkileşim içerisinde olmayı gerektirmektedir. Son yıllarda sensör temelli insan HT, günlük yaşamdaki geniş kullanımı nedeniyle bilgisayar bilimi alanında önemli bir yere sahip olmaya başlamıştır (Wu ve ark., 2007).

HT'nın bir amacı, bilgi işlem sistemleri vasıtasıyla bir kullanıcının davranışları hakkında bilgi elde edilmesidir. HT için genellikle EEG, ivmeölçerler, jiroskoplar, manyetometreler gibi vücuda takılabilen hareket sensörleri (HS) kullanılmaktadır. İvmeölçer, hassas bir ekseninde hareket eden ivmeyi ölçen sensör çeşididir. Jiroskop, hassas bir eksen etrafında dönme oranını ölçen sensör çeşididir. Manyetometre, manyetik bir sensördür ve hassas bir eksen boyunca yerel manyetik alanın bileşenlerini ölçmektedir (Lara ve Labrador, 2013).

Hareket sensörleri, kullanıldığı vücut bölgesinin hareketi ile doğrudan ilişkili olan fiziksel niceliklerin ölçülmesine dayalı olarak konum ve yönlendirme bilgilerini vermektedir. HS yaygın bir çalışma alanında vücut hareketini algılamak ve izlemek için

kullanılmaktadır. Geçmiş dönemlere kadar HS, yalnızca uzay gemileri, uçaklar, gemiler, denizaltılar, arabalar vb. üzerinde kullanılırken son zamanlarda oyun sektörü (oyun konsolları vb.), kol bantları (sunum, spor vb.), sağlık sektörü, tekerlekli ve bacaklı robotlar dahil olmak üzere birçok farklı insan yapımı araçların hareketini izlemek ve kontrol etmek için kullanılmaktadır.

HT sistemleri; anormal durumları tespit etmek veya öngörülemeyen olayları önlemek için aktivitelerin sürekli olarak izlenmesine ihtiyaç duymaktadır. Yeni teknolojiler sayesinde sağlık izleme cihazları vücut üzerine giyilebilir sensör (cihaz) haline gelmiştir. Gelişen sensör teknolojisiyle beraber genellikle Elektrokardiyografi (EKG), Elektromiyografi (EMG), kan basıncı, kalp atış hızı ve sıcaklık gibi hayati bulguları izlemek için nöbetler, hipertansiyon, distimya ve astım gibi hastalıklar fizyolojik izleme ile teşhis ve tedavi edilebilmektedir. Hastane ortamında da hastaların hareket takiplerinin yapılması çok önemlidir. Çünkü yatar durumda olan hastaların yanlış hareketler yaparak sakıncalı hareketlerde bulunmaları yüzünden iyileşme süreleri uzamaktadır. Ayrıca gelişen teknolojik çalışmaların bir diğer parçası olan elektroensefalografi (EEG) cihazı, beyinde gerçekleşen elektriksel aktiviteleri değerlendirmek için kullanılmaktadır (Yin ve ark., 2007; Kwapisz ve ark., 2011; Hassan ve ark., 2018).

HT sistemleri insan-robot etkileşimi için de kullanılabilir. Robotların kullanıcıların bir sonraki aşamadaki hareketlerini anlaması, tahmin etmesi ve kullanıcılara uygun bir yanıt vermesi gerekmektedir. Bu nedenle, insan faaliyetlerinin erken tanınması insan-robot etkileşiminde önemli bir yer almaktadır. Ayrıca HT uygulamaları günlük aktiviteler, spor faaliyetleri, eğlence-oyun alanları (oyun konsolları), günlük iş aktiviteleri (sunum ve toplantılar), hasta bakımı izlenmesi (rehabilitasyon uygulamalarının gerçekleştirilmesi), yaşlı bakımı izlenmesi, güvenlik anlamında (anormal durumları tespit etmek veya öngörülemeyen olayları önlemek), askeri anlamda vb. birçok farklı alanda kullanılabilir. Hareket tanıma sistemleri özellikle sağlık, askeri ve güvenlik alanları başta olmak üzere birçok farklı alanda kullanılmaktadır (Nweke ve ark., 2007). HT bir hastane ortamının dışında izlenen kişilerin sağlığı hakkında değerli bilgiler sağlayabilen hızla büyüyen bir araştırma alanıdır. Herhangi bir hastalığı olan ve tedavilerinin bir parçası olan egzersiz yapmaları gereken hastalar HT sisteminden faydalanabilmektedirler. Yürüyüş, koşu vb. hareketlerin

tanınması hastanın davranışı hakkında hasta yakınına veya doktoruna geri bildirim sağlaması için oldukça faydalı olabilmektedir. Bunun dışında hastaların anormal hareketlerini (aktiviteleri) belirlemek ve istenmeyen sonuçları önlemek için hasta hareketleri izlenebilmektedir (Tharwat ve ark., 2018; Jordao ve ark., 2018).

Gelişen teknolojik çalışmalar neticesinde sensör tabanlı HT sistemlerinde kişinin vücuduna bağlı heterojen sensörleri kullanarak, insan eylemlerinin durumu hakkında bilgi elde edilebilmektedir. Yapılan çalışmaların neticesinde, birçok sektörde kullanılabilen farklı giyilebilir sensör çeşitleri bulunmaktadır. Giyilebilir sensörlerin düşük maliyeti, küçük boyutlu olmaları ve düşük enerji tüketimi sayesinde insan hareket tanınması üzerindeki çalışmaların günlük aktivitelerden elde edilmesine olanak sağlamaktadır. Hareket tanınmanın temel amacı sensör verilerinin kullanılması sayesinde hareketler için ayırt edici bilgilere ulaşılmasıdır (Györbíró ve ark., 2009; San-Segundo ve ark., 2018).

Hareket tanıma sistemlerinin havacılık, sanayi, sağlık, ofis senaryoları, eğitim, robotik, akıllı evler, eğlence sektörü spor, askeri, güvenlik, müzik vb. birçok farklı alanlarda fayda sağlamak için hem akademik hem de endüstriyel alanda yaygın olarak kullanıldığı görülmüştür (Jain ve Kanhangad, 2018).

HT sistemleri iki önemli bileşenden oluşmaktadır. Birinci aşama hareketleri birbirinden ayırt edecek öznelik bileşenidir. İkinci aşama ise makine öğrenmesi (sınıflandırma) aşamasıdır. Sistemin başarısı birinci aşamada elde edilen etkin özneliklere bağlıdır (Lara ve Labrador, 2013).

HT tanıma sisteminde hareketleri birbirinden en iyi şekilde ayırt eden özneliklerin belirlenmesi gerekmektedir. Özneliklerin iyi seçilmemesi durumunda sınıflandırma performansı düşeceğinden, öznelik çıkarımı örüntü tanıma sürecinde önemli bir rol oynamaktadır.

Bu çalışmada HT için sensör işaretlerinden öznelik çıkarımını gerçekleştiren yeni yaklaşımlar önerilmektedir. Çalışma kapsamında öznelik çıkarımı için dokuz farklı yeni yaklaşım önerilmiştir. Bu yaklaşımlar; Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ), Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler (OT-1B-YİÖ), Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler (MT-1B-YİÖ), Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler (ÇÖ-1B-YİÖ), Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-YİÖ), Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler (KT-1B-YİÖ), Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler (K-1B-YİÖ), Üçlü Desenli Bir Boyutlu

Yerel İkili Örüntüler (ÜD-1B-YİÖ), İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler (İ-1B-YİÖ)'dir. Önerilen yaklaşımlar görüntü işleme uygulamalarında sıkça kullanılan Yerel İkili Örüntüler metoduna dayalı olarak geliştirilen Bir Boyutlu Yerel İkili Örüntüler metodu baz alınarak geliştirilmiştir. Geliştirilen yöntemler ile gerçekleştirilen öznitelik çıkarımları sınıflandırma işleminden önce gerekli bir adım olmaktadır. Önerilen HT sistemi altı aşamadan oluşmaktadır. Birinci aşamada çalışma sürecinde kullanılmak üzere işaretlerin temini ve bu işaretlerin düzenlenmesi işlemleri yapılmaktadır. Çalışma süresince UCI kütüphanesinden temin edilen MHealth (Mobil Health) veri seti kullanılmıştır. İkinci aşamada düzenlenen işaretler grubuna geliştirilen öznitelik çıkarım yöntemleri uygulanarak daha anlamlı işaret grupları elde edilmektedir. Üçüncü aşamada elde edilen yeni işaret gruplarının histogramları oluşturulmaktadır. Dördüncü aşamada Histogramlardan çeşitli istatistiksel özniteliklerin çıkarımı sağlanmaktadır. Beşinci aşamada çıkarılan istatistiksel özniteliklerin Rastgele Orman algoritması ile 10 katlı çapraz geçerlilik testine göre sınıflandırma işlemi yapılmaktadır. Rastgele orman algoritması eğitim veri setinden çok sayıda karar ağacı oluşturulmasına dayanmaktadır. Altıncı aşamada çeşitli kriterlere göre sınıflandırma sonuçları değerlendirilmektedir. Geliştirilen yöntemlerin çok önemli avantajları bulunmaktadır. En belirgin avantajları öznitelik çıkarımı için tüm işaretlerdeki değerleri tek tek kullanmalarıdır. İkinci bir önemli avantaj ise geliştirilen yöntemlerin kolay uygulanabilir ve hızlı olmasıdır. Gerçek zamanlı uygulamalar için önemli metotlar olmaktadır. Geliştirilen yöntemler içinde kendine özgü parametreler içeren metotların bulunması aynı yöntem ile farklı öznitelik gruplarının oluşturulmasını sağlamaktadır.

2. LİTERATÜR ARAŞTIRMASI

Sensör tabanlı HT son yıllarda önemli bir araştırma alanı olmuştur. Etkinliğe (harekete) duyarlı sistemler, yeni kullanıcı ara yüzlerine ve akıllı ortamlardaki, gözetimdeki, acil durum müdahalesindeki ve askeri görevlerdeki yeni uygulamalara ilham vermektedir. İnsan hareketlerini vücuda takılan sensörlerden tanıyan sistemler, fitness izleme, yaşlı bakımı desteği, uzun süreli önleyici ve kronik bakım ve bilişsel yardım gibi sağlık hizmetleri dünyasına birçok kapı açabileceği yapılan çalışmalar neticesinde görülmektedir.

Son yıllarda, vücut hareketlerini gerçek zamanlı algılama çalışmalarında birçok farklı cihaz, akıllı telefon, sensör, gömülü sistemler vb. ekipmanlar kullanılmaktadır. HT için genellikle ivmeölçerler, jiroskoplar, manyetometreler gibi vücuda takılabilen hareket sensörleri kullanılmaktadır. Sensör teknolojisi hareket tanıma aşamasında başarıya etki eden önemli bir adımdır. Hareket tanıma kapsamında giyilebilir sensörler kullanılarak çevresel özellikler (sıcaklık), ivme (duruş ve uzuv hareketleri vb.), yer bilgisi (konum) ve fizyolojik özellikler (EMG, EKG, kalp atım izleme, akciğer hava kapasitesi ölçme vb.) gibi dört özellik grubu ölçülmektedir. Günümüzde HT için mobil cihaz sensörlerin yoğun bir şekilde kullanıldığı görülmektedir. Yeni teknolojiler sayesinde kullanılan sensör ve cihazlar vücut üzerine giyilebilir cihaz (sensör, kol bandı, saat vb.) haline gelmiştir. Giyilebilir sistemler kolay bir şekilde kullanılabilmesi için önemli bir avantaja sahiptir. Örneğin bir spor uygulaması kullanıcıları hareketleri gerçekleştirmeye teşvik etmek için gerçek zamanlı aktivite bilgilerini kullanabilmektedir. Ayrıca, genel olarak insanların bu tür hareket tanıma sistemlerini kabul etmesi daha uygundur, çünkü giyilebilir hareket tanıma sistemlerinin genellikle kapatılması veya çıkarılması kolaydır. Bu uygulamaları kullanan sistemlerin pratik olması için, temel tanıma modülünün farklı çevresel koşullar altında farklı kişiler tarafından birçok farklı şekilde rutin olarak gerçekleştirilen çeşitli aktiviteleri tespit etmesi gerekmektedir. Bu, gerçek dünyanın gürültülü verilerini ve karmaşıklıklarını idare edebilecek yapı sistemlerinin zorluğunu göstermektedir. Ayrıca, sistemleri dağıtmak bazı önemli kısıtlamalar getirmektedir. Dağıtım, kullanıcının temas ettiği kişilerin gizliliğinin yanı sıra, kullanıcının gizliliğini de korumalıdır. Sensörler hafif, belirgin olmayan ve makine öğrenmesi algoritmaları kapsamlı bir insan denetimi gerektirmeden kullanılabilir olmalıdır. Bu kısıtlamalar iyi bir hareket tanıma sistemini

oluşturmak için zorlaştırıcı etki göstermektedir (Lin ve ark., 2008; Chen ve ark., 2010; Chan ve ark., 2012; Baig ve ark., 2013; Tamura ve ark., 2013; Barnes ve ark., 2014).

Foerster ve Fahrenberg (2000) yürüyüş ve merdiven tırmanma gibi hareketlerin birbirinden ayırt edilmesini sağlamak ve uyku esnasında vücudun rotasyonunu ayırt etmek için çalışmalarda bulunmuşlardır. Çok kanallı kayıtlar için Vitaport 2 (Becker Ingenieurbüro, Karlsruhe, Germany) kayıt aparatını kullanmışlardır. Sınıflandırma metodu olarak seçimlerini hiyerarşik sınıflandırmadan yana kullanmışlardır. Elde ettikleri bulgulara göre kalibre edilmiş ivmeölçerin hareket ve duruşu değerlendirmede etkili olduğunu ve yüksek doğruluk sonuçları sağladığını tespit etmişlerdir.

Mantjarvi ve ark. (2001) çalışmalarında insan HT için giyilebilir sensör olarak, ivmeölçer sensörlerini tercih etmişlerdir. Öznitelik çıkarımında temel bileşen analizi ve dalgacık dönüşümü ile bağımsız bileşen analizi işlemlerini gerçekleştirmişlerdir. Makine öğrenmesi yöntemlerinden çok katmanlı yapay sinir ağları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Yazarlar, elde edilen sonuçların başarı oranının %83 ile %90 arasında olduğunu belirtmişlerdir.

Parkka ve ark. (2006) çalışmalarında GPS, ses, EKG, ivmeölçer, pusula, nem, ışık, sıcaklık, nabız, cilt direnci gibi parametreleri kullanarak hareket tanıma işlemi gerçekleştirmeyi amaçlamışlardır. Yazarlar çalışmada Heuristik öznitelik çıkarım yöntemlerini uygulamışlardır. Yapılan çalışmanın sonunda, karar ağaçları ile sınıflandırma algoritmalarını kullanarak %86 doğruluk başarısı elde ettiklerini belirtmişlerdir.

Maurer ve ark. (2006) belirli aktiviteleri tanımayı amaçlamışlardır. Bu bağlamda, veri elde etmek için çoklu sensörlerden faydalanmışlardır. Korelasyona dayalı öznitelik çıkarım yöntemini (CFS) öznitelik elde etmek için ve Karar ağaçları, k-en yakın komşu, Naive Bayes ve Bayes Net algoritmalarını sınıflandırmayı gerçekleştirmek için kullanmışlardır. Yazarlar yaptıkları çalışma sonucunda, %80-%92 arasında doğruluk başarısına ulaşmışlardır.

Yin ve ark. (2007) kullanıcının vücuda takılan sensörlerden anormal aktivitelerini tespit etmek için yeni bir yaklaşım önermişlerdir. Anormal faaliyetler için eğitim verilerinin kıtlığı ile başa çıkmak için iki aşamalı anormallik algılama algoritması önermişlerdir. İlk aşamada, normal aktivitelerin çoğunu filtrelemeye yardımcı olan normal aktiviteler üzerine bir sınıf Destek Vektör Makinesi (DVM) inşa edilmiştir.

Şüpheli izlerin daha sonra daha ileri tespit için Kernel Nonlinear Regression (KNLR) ile adapte edilmiş bir anormal aktivite modelleri koleksiyonuna iletilmiştir. Yazarlar yaklaşımlarındaki en büyük avantajı, algılama oranı ile yanlış alarm oranı arasında daha iyi bir denge elde edebilme olarak belirtmişlerdir. Yaklaşımın etkinliğini, bir insan vücuduna bağlı olan sensörlerden toplanan gerçek verileri kullanarak göstermişlerdir. Yaklaşımın olası bir sınırlaması, anormal faaliyetlerin aniden norm haline gelmesi durumunda çok sayıda anormal model üretme riski olmasıdır. Bunun, izlenen bir kullanıcının belirli bir zaman noktasından sonra belirli bir davranışı tekrarladığında ortaya çıkabileceğini belirtmişlerdir. Bu sorunu çözmek için, anormal bir aktivitenin ne zaman normale döndüğünü saptayabilmenin gerektiğini söylemişlerdir. Bu çalışmadaki başka bir sınırlama, bir kullanıcı izlenirken yalnızca bir tür hareket gerçekleştirdiğini varsayılması olarak belirtmişlerdir. Bununla birlikte, gerçekte, bir kullanıcı sürekli bir kullanıcı izlemesi içinde birkaç harmanlama aktivitesi gerçekleştirebilir. Bu nedenle, her biri bir tür hareketi temsil eden kullanıcı oturumlarını doğru bir şekilde tanımlamak için, çevrimiçi bir bölümlenme algoritması tasarlanması gerekmektedir. Yazarlar sonraki çalışma olarak, sürekli kullanıcı izlerinden anormal aktivitelerin tespiti yönünde çalışmalarına devam etmek istediklerini ifade etmişlerdir. Bu, izlemenin tamamını ardışık bölümlere tam olarak ayırabilen ve bu bölümlerden gelen anormal hareketleri çevrimiçi olarak saptayabilen verimli bir bölümlenme ve algılama algoritması tasarlamalarının gerekli olduğunu söylemişlerdir.

Choudhury ve ark. (2008) etkinliğe duyarlı sistemlerin, yeni kullanıcı ara yüzlerine ve akıllı ortamlardaki, gözetimdeki, acil durum müdahalesindeki ve askeri görevlerdeki yeni uygulamalara ilham verdiğini belirtmişlerdir. Yapılan çalışmada, vücut algılayıcılarını kullanan bir otomatik hareket tanıma sistemi kurduklarını belirtmişlerdir. Mobil Algılama Platformu (MAP)'nu, tasarım ve uygulama zorluklarının birçoğunu ele alan bir çalışma olarak belirtmişlerdir. Ayrıca, donanım, yazılım tasarımı ve hareket tanıma algoritmalarını iyileştirmek için sonuçları kullanarak birçok gerçek dünya dağıtım ve kullanıcı çalışması yaptıklarına değinmişlerdir. Yazarlar, aktivite tanıma sistemlerinin tipik olarak üç ana bileşene sahip olduklarını belirtmişlerdir. İlki mikrofonları, ivmeölçerleri, ışık sensörlerini vb. kullanarak aktivitelerle ilgili düşük seviye bir algılama modülü ile sürekli veri toplama işleminin gerçekleştirilmesidir. İkinci bileşen, ham sensör verilerini hareketler arasında ayırma yardımcı olan özelliklere dönüştüren bir özellik

işleme ve seçim modülü olarak gerçekleştirilmesidir. Son olarak bir bireyin veya bir grubun hangi harekette bulunduğunu ortaya çıkarmak için öznitelikleri kullanan bir sınıflandırma modülünün gerçekleştirilmesi aşamasıdır (örneğin, yürümek, yemek yapmak veya sohbet etmek). Yazarlar hareket tanıma uygulaması için bir gömülü sistem çalışması gerçekleştirdiklerini belirtmişlerdir. MAP, diğer cihazlarla gerçek zamanlı olarak kablosuz iletişim kurabilir veya çevrimdışı kullanım için ham sensör verilerini, özelliklerini veya hareket tanıma sonuçlarını saklayabilir. Yapılan çalışmada gönüllü 24 lisansüstü öğrenci üzerinde bir yıl boyunca ayda bir, bir hafta boyunca aynı anda veriler toplanmıştır. Çevrimdışı analiz edilen 4.400 saatten fazla sensör verisi vardır. Yazarlar yaptıkları çalışmada %93,80 başarı oranı elde ettiklerini belirtmişlerdir.

Tunçel ve ark. (2009) çalışmalarında gönüllü bir deneğin sağ bacağından elde edilen jiroskop sinyallerini kullanarak deneğin sekiz (8) hareketini tespit etmeye çalışmışlardır. Gerçekleştirilen çalışmada öncelikle çok fazla öznitelik seçerek değerlendirmeler yapmışlardır, sonrasında bu öznitelikleri çeşitli sınıflandırma yöntemlerinde kullanmak üzere farklı değerlere indirgemişlerdir. Hareketleri sınıflandırma aşamasında Bayes, Yapay Sinir Ağları (YSA), destek vektör makinaları (DVM), En Yakın Komşuluk (KNN), En Küçük Kareler gibi makine öğrenmesi yöntemlerini kullanmışlardır. En küçük kareler yönteminde 48 öznitelikten 24 tanesini eğitim aşamasında kullanarak %96'lık bir başarı elde ettiklerini belirtmişlerdir.

Györbíró ve ark. (2009) cep telefonu kullanarak bir kişinin hareket faaliyetlerini belirleyen yeni bir sistem geliştirmişlerdir. Çalışmada verileri kaydetmek için cep telefonu kullanılmıştır, yoğunluğu ölçen kablosuz sensörler kullanıcının vücut kısımlarına takılmıştır. Verimli bir mimik ve duruş hareketlerini tanıma işlemi için İleri Beslemeli Geri Yayılım Sinir Ağları kullanmışlardır. Yazarların, gerçekleştirdiği sistemi (tasarım ve uygulama) deneklerde kullanarak kayıtları ile birlikte sunmuşlardır. Sonuç olarak altı (6) farklı hareket için, yüksek tanıma oranlarını elde ettiklerini belirtmişlerdir.

Avcı ve ark. (2010) çalışmalarında, sağlık hizmetleri, dinlenme ve spor uygulamalarına odaklanarak eylemsizlik algılayıcıların farklı yaklaşımları üzerine bir araştırma çalışması yapmışlardır. Yazarlar öncelikle ana zorlukları ve uygulama talimatlarını belirlemişlerdir, daha sonra ilgili çalışmaları hareket tanıma sürecinin ana adımlarına göre analiz etmişlerdir. Ön işleme, segmentasyon, öznitelik çıkarımı, boyutluluk azaltma ve sınıflandırma olarak adımları tanımlamışlardır. Genel bir gözlem

olarak, hemen hemen tüm durumlarda literatürde bildirilen sonuçların, önce duyuşal bilgiyi merkezi bir bilgisayarda toplamak ve sonra verilerin çevrimdışı olarak işlenerek elde edildiğine dikkat çekmişlerdir. Bu nedenle, çevrimiçi olarak ve dağıtılmış bir şekilde hareket tanıma (yani her bir sensörün genel durumun sadece kısmi bir görüntüsüne sahip olmasıyla) yapılmasını açık bir araştırma sorusu olarak ifade etmişlerdir. Bununla birlikte, dağıtılmış zekâ da yeni sorunlar yaratmakta ve bu sorunların hala keşfedilmemiş kısımlarının olduğuna değinmişlerdir. Bu sorunlardan biri, minimum iletişim ve güç tüketimi ile en iyi karara varmanın bir yolunu bulmak olduğunu belirtmişlerdir. Benzer şekilde, dağıtılmış eğitim ve öğrenme yapmanın iyi bir yolunu bulmak, dağıtılmış muhakeme sistemleri için hala açık bir araştırma sorusu olarak ifade edilmiştir. Ayrıca yazarlar gerçekleştirdikleri kapsamlı hareket tanıma inceleme çalışmasında birçok yazarın bu alanda gerçekleştirdikleri yöntemleri ve başarımlarını sunmuşlardır.

Kwapisz ve ark. (2011) bir akıllı telefonun hareketleri tanımak için sadece cebinde tutularak nasıl kullanılabileceği üzerine bir çalışma yapmışlardır. Ayrıca hareket tanımanın çok doğru olabileceğini ve çoğu aktivitenin zamanın %90'ında doğru bir şekilde tanındığını ifade etmişlerdir. Ek olarak, her bir örnek yalnızca 10 saniyelik veriden üretildiği için bu faaliyetlerin hızlı bir şekilde tanınabildiğini belirtmişlerdir. Faaliyetlerin tanınması için birçok farklı uygulamaya sahip olduklarını ve yakın gelecekte bu uygulamalardan bazılarını uygulamayı planladıklarını ifade etmişlerdir. Wireless Sensor Data Mining (WISDM) Android tabanlı veri toplama platformunu oluşturmadan çalışmalarının mümkün olmayacağını ve verilerin telefonla İnternet tabanlı sunucularına iletildiği bu yazılım ve donanım mimarisini, bunun sonucunda üretilen anahtar bir kaynak olarak gördüklerini belirtmişlerdir. Bunu yaparak, diğer mobil sensör verilerini çok daha hızlı bir şekilde değerlendirebileceklerini ifade etmişlerdir. Bu platformun ve toplanan verilerin insanlar ile paylaşılacağını ifade etmişlerdir. Hareket tanıma işlemini çeşitli şekillerde iyileştirmeyi planladıklarını belirtmişlerdir. Yazarların belirledikleri senaryolar, bisiklet ve araba sürme gibi ek hareketleri tanımayı öğrenmek, bunun sonuçları iyileştireceği beklentisiyle daha fazla kullanıcıdan eğitim verisi elde etmek, veri toplama sırasında ek ve daha sofistike özellikler üretmek, ham zaman serisi verileri ve cep telefonunun bir kemer köprüsü gibi farklı yerlere taşınmasının etkisinin değerlendirilmesi olarak belirtmişlerdir. Ek olarak, yakın gelecekte WISDM platformunu önemli ölçüde geliştirmeyi planladıklarını belirtmişlerdir. Böylece şu anda çevrimdışı

retilen, cep telefonuna ve kullanıcıya geri rapor edilemeyen sonuların gerek zamanlı olarak retilebileceđini belirtmiřlerdir.

Atallah ve ark. (2011) alıřmalarında ivmeler sensrleri kullanarak ReliefF, Simba ve Minimum Redundancy and Maximum Relevance MRMR znitelik ıkarım yntemlerini kullanarak eřitli hareketleri sınıflandırmaya alıřmıřlardır. Yapılan alıřmada, toplamda 124 tane znitelik elde etmiřler ve sınıflandırmayı KNN ve Bayes algoritmalarını kullanarak gerekleřtirdiklerini belirtmiřlerdir. Yapılan alıřmanın sonunda yaklaşık olarak %90 seviyelerinde bir dođruluk elde etmiřlerdir.

Siirtola ve Roning (2012) akıllı telefonun ivmeler verilerini kullanarak hareket tanıma iin bir alıřma yapmıřlardır. Yazarlar KNN ve Quadratic Discriminant Analysis sınıflandırma metotlarını kullanmıřlardır. Hareket tanıma iin elde edilen deneysel sonularda bařarı oranının %95 olduđunu belirtmiřlerdir.

Wang ve ark. (2012) gnlk aktiviteler iin duyarlı mobil mzik alıřması nermiřlerdir. Mevcut mzik neri sistemlerinin, kullanıcıların uzun vadeli mzik alma ihtiyalarını karřılamak iin iř birliđine dayalı veya ierik tabanlı teknolojilere dayandıklarını ifade etmiřlerdir. İyi algılama ve kablosuz iletiřim zelliklerine sahip mobil mzik cihazlarının poplerliđi gz nne alındıđında, yazarların alıřması, kullanıcıların kısa vadeli mzik alma ihtiyalarını karřılamak iin mobil cihazlarla toplanan bađlamsal bilgileri kullanmak iin yeni bir yaklařım sunmaktadır. Gnlk aktiviteler iin mzik nerileri sunan iin bađlamsal bilgileri mzik ieriđi analizi ile entegre etmek iin olasılıklı bir model sunmuřlardır. Ayrıca yazarlar modelin prototip uygulamasını da geliřtirdiklerini ifade etmiřlerdir. Yazarlar alıřmalarında zengin bir hareket kmesi ve mzik ieriđi zelliklerini destekleyen, otomatik hareket sınıflandırmasını otomatik mzik ieriđi analizi ile birleřtiren, mzik nerisi iin yeni bir olasılıksal model rneđi geliřtirdiklerini belirtmiřlerdir. İnternette bir dizi alma listesi, 1200 adet net bir řekilde aıklamalı řarkı seti ve gnlk aktivitelerden kaydedilen bir dizi sensr verisi kullanmıřlardır. 1200 adet aıklamalı řarkı verisine dayanarak, bađlam aıklamalarının znel olmasına rađmen, insanların yine de aıklamalarında hemfikir olduklarına deđinmiřlerdir. Veri setleri kullanılarak hem sensr ierik modeli hem de mzik ierik modeli deđerlendirilmiř ve sonuların ok umut verici olduđunu ifade etmiřlerdir. Olasılık modeline dayanarak, cep telefonları iin bir Context-Aware Music Recommender Systems (CAMRS) uyguladıklarını belirtmiřlerdir. alıřmanın sonuları,

sistemin kullanımının kolay olduğunu ve önceden var olan kullanıcı derecelendirmelerinin veya açıklamalarının yokluğunda bile, geleneksel sistemlerin yalnızca rastgele şarkılar önerebileceği bir durumda dahi iyi öneriler sunabileceğini ifade etmişlerdir. Bu nedenle, sistemin bağlam farkındalığı nedeniyle, kullanıcıların kısa vadeli ihtiyacını daha iyi karşılandığı ve ayrıca kötü başlatma sorununa bir çözüm sunmaktadır. Değerlendirme sonuçları sistemin, belirli bir kullanıcıya adapte olmak için, kendisini gerçek zamanlı olarak güncelleyebileceğini göstermektedir. Yazarlar çalışmalarında sistemin kullanıcı deneyimini iyileştirerek Google Android Market'te yayımlayacaklarını ifade etmişlerdir. Son olarak, model ve prototipin doğruluğunu ve kullanılabilirliğini gösteren değerlendirme sonuçlarının yüksek başarımla gerçekleştirildiklerini sunmuşlardır.

Chernbumroong ve ark. (2013) çalışmalarının amacı olarak, hem teknik hem de pratik yönleri dikkate alarak, yaşlı bir insanın günlük dokuz aktivitesinin tespiti için bir aktivite tanıma yöntemi geliştirdiklerini belirtmişlerdir. Pratik açıdan dikkate alındığında, önerilen tanıma yöntemi, küçük, ucuz, çoklu sensörleri olmayan, yani bir kol saatine girdi olarak gömülü ivmeölçer, sıcaklık sensörü ve altimetre kullanılmaktadır. Gündelik bir nesneye, yani kol saatine yerleştirilmiş sensörler, yaşlanma-destek ekipmanındaki önemli kaygılardan biri olan yaşlı insanlardaki sensörlerin gözükmemesinden dolayı damgalanma kaygısını azaltacaktır. Ayrıca, bilekte kullanılan ekipman, serbest yaşam alanı ortamında uzun süreli faaliyet tanıma için uygun faaliyetler gerçekleştirilirken ortaya çıkabilecek kısıtlama veya rahatsızlık gibi sorunları azaltmaktadır. Teknik açıdan, önerilen hareket tespit yönteminin yüksek performans elde edebilmesi de önemlidir. MLP, RBF ve SVM'ye göre farklı sınıflandırma modelleri karşılaştırılmıştır. Sonuçlar, SVM'nin en güçlü sınıflandırma algoritması olduğunu göstermiştir. Yazarlar bu nedenle, SVM kullanarak yaşlı günlük yaşam aktivitelerini tespit etmek için bilekte takılan çoklu sensörlere dayalı toplanan verilerden aktivite tanıma ve sınıflandırma yöntemi önerdiklerini belirtmişlerdir. Önerilen yöntem, F-skorunun 0,81 ile 0,97 arasında yüksek bir sınıflandırma performansı ve %90,23'lük bir genel doğruluk sağlamaktadır. Bu, önerilen yöntemin yaşlı bir insanın faaliyetlerini tespit etmede çok iyi performans gösterdiğini ifade etmişlerdir.

Lara ve Labrador (2013) yaptıkları çalışmada, giyilebilir sensörlere dayanan, insan hareketi tanıma alanındaki en son teknolojiyi araştırdıklarını belirtmişlerdir. Yaptıkları çalışmada, insan hareket tanıma sistemlerini tepki sürelerine ve öğrenme

programlarına göre düzenleyen iki seviyeli bir taksonomi tanıtılmıştır. Yirmi sekiz adet sistem cevap verme süresi, öğrenme yaklaşımı, olumsuzluk, esneklik, tanıma doğruluğu ve diğer önemli tasarım konularında nitel olarak karşılaştırılmıştır. Her insan hareket tanıma sisteminin önemli bileşenleri olduğu için öznitelik çıkarma ve makine öğrenmenin temelleri de dâhil edilmiştir. Son olarak, gelecekteki araştırmalar için bu alanı daha gerçekçi ve yaygın senaryolara genişletmek için çeşitli fikirler önermişlerdir.

Elvira ve ark. (2014) çalışmalarında insan HT için yeni bir öznitelik çıkarım yöntemi önerdiklerini belirtmişlerdir. Yazarlar çalışmalarında, atalet ve manyetik sensörler kullanmışlardır. Önerilen yöntem için kuaterniyon gösterimi kullanılarak kişinin yeryüzüne göre yönü tahmin edilmektedir. Önerilen öznitelik çıkarma tekniğini, Gizli Markov Modellerine (GMM) dayalı en gelişmiş bir hiyerarşik dinamik modele (HDM) uygulayarak performansını değerlendirmişlerdir. Yazarlar yaptıkları çalışmada %86-%89 arasında bir başarılı sınıflandırma işleminin gerçekleştirildiğini belirtmişlerdir.

Bayat ve ark. (2014) çalışmalarında android cep telefonunda üç eksenli ivmeölçer kullanarak belirli hareketleri tanımayı amaçlamışlardır. Sınıflandırma için gerekli öznitelikleri, özellik kümeleme işlemini gerçekleştirerek elde etmişlerdir. Sınıflandırma aşamasında Çok Katmanlı Yapay Sinir Ağları, Karar Destek Vektörleri ve Rastgele Orman (RO) algoritmalarını kullanmışlardır. Yapılan çalışmada %81-%91 arasında doğruluk elde ettiklerine değinmişlerdir.

Kurban (2014), tez çalışmasında düşme tespiti ve hareket tanıma işlemleri için herhangi bir öznitelik çıkarım yöntemi kullanmadan gerçekleştirebilecek bir sistem elde ettiğini belirtmiştir. Yapılan çalışmada Çok Katmanlı Algılayıcı, Destek Vektör Makineleri, Yapay Sinir Ağı yapısında radyal tabanlı fonksiyon ve Naive Bayes sınıflandırıcıları kullanarak sınıflandırmada başarı etkisini belirtmiştir.

Capela ve ark. (2015) çalışmalarında HT için, içerisinde ivmeölçer ve jiroskop sensörleri bulunan akıllı telefon sinyallerini kullanarak, üç filtre tabanlı öznitelik çıkarım metodu ile elde edilen öznitelikleri sınıflandırmayı amaçlamışlardır. Yazarlar yaptıkları çalışmalarında hareketleri sınıflara ayırırken, hareket sayısının artması ile doğruluk yüzdesinin azaldığına değinmişlerdir.

İnsan aktivitelerinde sensörler gürültüden kolaylıkla etkilenmektedir. Ponce ve ark. (2016) başarılı bir hareket sınıflandırma uygulaması için gürültülü veriler için kararlı ve sağlam makine öğrenme tekniklerinin kullanılması gerektiğine değinmişlerdir.

Çalışmalarında Yapay Bir Hidrokarbon Ağı (AHN) tekniğini önermişlerdir. AHN sınıflandırıcı yönteminin hareket tanıma için diğer makine öğrenme yöntemleriyle karşılaştırmasını yaparak %97'lik oranda başarı elde ettiklerini belirtmişlerdir.

Damasevicius ve ark. (2016) çalışmalarında günlük insan faaliyetlerinin çevrimdışı tanınması için bir yöntem önermişlerdir. Yazarlar yüksek boyutlu öznitelikler kullanılarak, düşük boyutlu özniteliklere geçiş yapıp verilerin olasılık yoğunluk fonksiyonları arasındaki Jaccard mesafesini kullanarak sınıflandırma yapmışlardır. Çalışmanın öznitelik seçim aşamasında Principal Component Analysis (PCA), ReliefF, RankFeatures metotları tercih edilmiştir. Çalışma sonunda elde edilen sonuçlarda %94'lük bir doğruluk olduğuna değinmişlerdir.

Howcroft ve ark. (2017) çalışmalarında, ivmeölçer ve basınç algılayan tabanlık ile yürüyüş verileri elde etmişlerdir. Elde edilen verilerden türetilmiş geniş özellik kümelerinden, daha iyi sınıflandırma başarısı için daha küçük öznitelik kümelerini tanımlamak ve değerlendirmek gerektiğini amaçlamışlardır. Yazarların gerçekleştirdiği çalışmada özellik seçimi için korelasyon tabanlı öznitelik seçimi, hızlı korelasyon tabanlı filtre ve Relief-F algoritmaları kullanılmıştır. Faller sınıflandırması tekrarlanan rasgele örnekleme ile çok katmanlı yapay sinir ağı, Naive Bayesian ve Destek Vektör Makinesi sınıflandırıcıları kullanılarak gerçekleştirilmiştir. Yazarlar, elde ettikleri sonuçlara göre en iyi performans gösteren modeli, %78 doğruluk, %26 duyarlılık, %95 özgüllük, 0,36 F1 skoru ve bir posterior pelvis ivmeölçer girişi özelliği (sol ivme standart sapması) olan bir destek vektör makinesi olarak belirtmişlerdir.

Hassan ve ark. (2018) yaptıkları çalışmanın temel amacını, akıllı telefon sensörlerinin verilerine dayanan sağlam bir insan etkinliği tanıma sistemi geliştirmek olduğunu belirtmişlerdir. Aktivite tanıma için akıllı telefonları kullanmanın çok akıllıca olduğunu çünkü akıllı telefonların günlük yaşamlarında sadece iletişim kurmak için değil, aynı zamanda sağlık hizmetleri de dâhil olmak üzere çok çeşitli uygulamalar için de en çok kullanılan cihazlardan biri olarak ifade etmişlerdir. Böylece, ivmeölçer ve jiroskop sensörleri gibi akıllı telefon atalet sensörlerini kullanarak hareket tanıma için yeni bir yaklaşım önermişlerdir. Sensör sinyallerinden, boyut küçültme için çoklu sağlam özellikler ve ardından KPCA çıkartmışlardır. Ayrıca, sağlam öznitelikleri, aktivite eğitimi ve tanınması için derin öğrenme tekniği olan, Deep Belief Network (DBN) ile birleştirmişlerdir. Önerilen yöntemin üstünlüğü gösterdiği geleneksel çoklu sınıf SVM

yaklaşımı ile karşılaştırılmıştır. Yazarlar çalışmalarında %89,61'lik ortalama tanıma oranı ve %95,85'lik genel doğruluk oranını on iki farklı fiziksel aktivite için kontrol edilerek elde edildiğini belirtmişlerdir. Ayrıca, diğer geleneksel yaklaşımların ortalama %82,02 tanıma oranına ve en iyi ihtimal ile %94,12 genel doğruluk oranına ulaşabildiğini ifade etmişlerdir. Ayrıca, temel geçiş ve geçiş dışı faaliyetler arasında ayırım yapabilme yeteneğini göstermişlerdir. Gelecekte, daha güçlü özelliklere odaklanmayı ve gerçek zamanlı ortamlarda daha verimli ve karmaşık bir hareket tanıma için çalışmalarına devam edeceklerini belirtmişlerdir.

Nweke ve ark. (2018) insan hareket tanıma üzerine kapsamlı bir araştırma çalışması gerçekleştirdiklerini belirtmişlerdir. Hareket tanıma işlemi için kullanılan farklı yöntemlere değinmişlerdir. Hareket tanıma için öznelik çıkarım yönteminin öneminden yaptıkları çalışmada kapsamlı olarak bahsetmişlerdir. İlgili özelliklerin çıkarılmasının, mobil ve giyilebilir sensör tabanlı insan hareketi tanıma hattının en zorlu kısmı olarak belirtmişlerdir. Bununla birlikte, mevcut insan hareketi tanımanın, özellikle mevcut çoklu model ve yüksek boyutlu sensör verilerinin akışıyla karmaşık hareketleri kontrol edemeyen el yapımı özelliklere dayanmakta olduğunu belirtmişlerdir. Yazarlar yapılan inceleme çalışması sonucunda metodun, benzersizliğini, avantajlarını ve sınırlamalarını sunmuşlardır. Çalışmaların yalnızca üretken, ayırt edici ve hibrit metoda göre sınıflandırılmadığını, aynı zamanda önemli avantajlarının da olduğunu vurgulamışlardır. Ayrıca, incelemelerinde sınıflandırma ve değerlendirme prosedürlerini sunarak, mobil sensörlerden elde ettikleri insan hareketi tanıma için halka açık veri kümelerinin etkinliğini ifade etmişlerdir. Ayrıca derin öğrenme uygulamalarının hareket tanıma işlemleri için faydalı olabileceğine değinmişlerdir. Yazarlar çalışmalarında hareket tanıma sistemleri için daha fazla araştırma ve iyileştirme gerektiren araştırma sorunlarını aşmak için bazı zorlukları ana hatlarıyla açıklamışlardır.

Tharwat ve ark. (2018) kalabalık mobil kitle modelini, bir grup mobil kullanıcısının, büyük ölçekli bir algılama görevini birlikte yürütmek üzere akıllı telefonlar veya cep telefonları gibi akıllı cihazların kullanıldığı son modellerden biri olarak ifade etmişlerdir. Bu görevlerden biri insan faaliyetlerinin sınıflandırılması ya da tanınmasıdır. Yapılan çalışmada, yanlış sınıflandırma oranını en aza indiren k değerini arayabilen yeni bir parçacık sürüsü optimizasyonu temelli yaklaşım (PSO-KNN) bulunmaktadır. Optimal yanlış sınıflandırma oranını elde etmek için optimal k değeri veri

setine uygulanır. Yazarlar yaptıkları çalışmada üç ana deney kısmı olduğunu ifade etmişlerdir. İlk deneyi, PSO algoritmasının simüle edilmiş bir örneğini göstererek yanlış sınıflandırma oranını en aza indiren en uygun k değerini aradığını göstermek için yapılmıştır. İkinci deneyi, birçok standart sınıflandırma veri setini uygulayarak, önerilen PSO-KNN algoritmasını farklı algoritmalar ile karşılaştırmak için yapmışlardır. Yazarlar çalışmanın sonuçlarında PSO-KNN algoritmasının, diğer iki algoritmadan daha düşük minimum sınıflandırma oranlarına ulaştığını belirtmişlerdir. Üçüncü deneyde, önerilen algoritma insan faaliyetlerini tanımak için kullanılmış ve sonuçlar sınıflandırma doğruluğu ve hesaplama süresi açısından SVM, ANN ve NB sınıflandırıcıları ile karşılaştırılmıştır. Önerilen algoritmanın en iyi sonuçları elde ettiği (%98,7) ve diğer öğrenme algoritmalarından daha düşük hesaplama süresi gerektirdiğini belirtmişlerdir. Yazarlar gelecekteki çalışmalar için birkaç yöntem önermişlerdir. Birincisi, yazarların yaptıkları bu çalışmadaki deneyler sadece on veri seti kullanılarak yapıldığı, ancak ileride önerilen algoritmayı doğrulamak ve genişletmek için diğer veri setleri ile de test edilmesidir. Daha önce de belirttikleri gibi, PSO algoritması parametre ayarlarına duyarlıdır. Bu nedenle, alternatif parametre ayarlama politikaları ve KNN sınıflandırıcısı için algoritmayı yeni parametreler geliştirerek özelleştirmeye yönelik daha kapsamlı bir çalışmanın daha derinlemesine araştırılmasını ikinci yöntem olarak önermişlerdir. Üçüncüsü, KNN sınıflandırıcısı oldukça basit ve tembel sınıflandırıcı olduğundan ve PSO oldukça yönlü olduğundan, PSO'nun potansiyelini diğer sınıflandırıcılara göre keşfetmenin faydalı olacağını belirtmişlerdir.

Jordao ve ark. (2018) yaptıkları çalışmada insan hareket tanıma uygulamasını iyileştirmek için ivmeölçer verilerinden bir dizi yöntem sunduklarını belirtmişlerdir. İlk olarak, ConvNet-based yaklaşımlarda sonuçları geliştiren basit ve etkili bir bölümleme tekniği önerdiklerini ifade etmişlerdir. İkinci olarak, ivmeölçer verilerinin tutum tahmininden faydalanan bir dizi yeni özellik tanımlayıcısı geliştirmişlerdir. Bu özellikler, ham ivmeölçer verileriyle birleştirildiğinde hareket sunumunu iyileştirerek doğru bir sınıflandırmaya olanak sağlamaktadır. Üçüncü olarak, yeni bir ConvNet mimarisi önerdiklerini ve daha iyi hareket tanıma elde etmenin basit ama etkili bir yolu olduğunu gösterdiklerini belirtmişlerdir. Yazarlar yöntemlerinde hesaplama açısından verimli ve ConvNets-Based yaklaşımlar ve el yapımı özellikler de dahil olmak üzere mevcut son teknolojiye sahip yaklaşımları, ivmeölçer verilerine dayanarak, insan faaliyetlerini

tanıma konusunda en güncel veri kümelerinden birinde daha iyi bir performans gösterdiğini belirtmişlerdir. Yazarlar ConvNet'in ham sinyal (ProposedCNN) ve tutum tahmin özelliklerini kullanarak her bir aktivitede (ProposedCNN+) elde ettiği tanıma doğruluğunda en yüksek başarımların %94,54 olarak bulduklarını belirtmişlerdir.

San-Segundo ve ark. (2018) yaptıkları çalışmada, çeşitli kullanıcılardan gelen hareket sensörü çıktılarını analiz ettiklerini ve insan hareket tanıma sistemlerinde akıllı cihazları için çeşitli zorlukları belirleyen akıllı telefonlar ve akıllı saatler olarak belirtmişlerdir. Bu zorluklar akıllı kol saatleri için akıllı telefonlardan önemli ölçüde daha büyüktür ve bunun sebebinin kol ve tüm vücut hareketleri de dâhil olmak üzere akıllı kol saatleri kayıtlarındaki büyük değişkenlikten kaynaklanıyor olmasıdır. İkinci olarak, farklı akıllı cihaz modelleri, kullanıcıya bağlı faaliyetler ve kullanım özellikleri arasındaki heterojenlikte de zorluklar ortaya çıktığını belirtmişlerdir. Bu zorlukları araştırmak için, hala literatürde yeterince çalışmanın olmadığını ifade etmişlerdir. Cihaz modelleri, cihaz örnekleri ve kullanıcılar eğitim ve testlerde farklı olduğunda, insan hareket tanıma performansını ve ilgili düşüşleri analiz etmeye odaklandıklarını belirtmişlerdir. Yukarıdaki analize dayanarak, ikinci katkıyı, akıllı saatler ve akıllı telefonlar gibi bir cihaz tipinin belirgin özellikleriyle başa çıkmak için ve henüz eğitilmemiş yeni cihaz modellerine veya kullanıcılarına en iyi şekilde genelleştirilen veya uyarlanan tekniklerin bir değerlendirmesini ikinci katkı olarak tanımlamışlardır. Öznitelik çıkarımını iyileştirmek için çeşitli stratejilerin değerlendirildiği, bazı tekniklerle akıllı saatlerin bozulmasına karşı ilginç sonuçlar bildirmişlerdir. Ek olarak, iki işlem sonrası özellik tekniğini değerlendirmişlerdir. Hareketli Ortalama (Moving Mean) tabanlı bir düşük geçiş filtresi (ardışık çerçeveler arasındaki gürültülü varyasyonları azaltmayı, daha yumuşak bir özellik dizisi sunmayı hedefleyen) ve farklı oturumlar arasındaki değişkenliği azaltmak için normalleştirme işlemini (farklı kullanıcılar tarafından veya farklı cihazlar kullanılarak) kullanmışlardır. Son olarak, geleneksel el yapımı özellikleri, derin CNN'ler kullanılarak elde edilen özellikler ile karşılaştırdıklarını belirtmişlerdir. CNN'leri kullanırken, sonuçlar her cihaza uyarlanmış farklı özellik setleriyle elde edilen en iyi sonuçlara çok yakın olarak tanımlamışlardır. Bunlar akıllı telefon kayıtları için zaman ve frekans temelli özellikler ve akıllı saat kayıtları için temel özelliklerdir. Önemli bir sonuç ise, CNN-MLP mimarisinin farklı durumlara uyarlanmış çok iyi özellikleri çıkardığıdır. Son olarak, sürekli fiziksel aktivitelerin zaman sekansını modellemek için

Hidden Markov Model (HMM) ve Recurrent Neural Networks (RNN) lerin kullanımını araştırmışlardır. Her iki stratejide önemli gelişmeler elde edildiği ifade edilmiştir. Akıllı telefon kayıtları için, CNN-LSTM stratejisinin en iyi sonuçları sağladığı ifade edilmiştir. Akıllı saat kayıtları için, HMM'ler uyumsuzluk koşullarında (1-KULLANICI-ÇIKIŞ, 1-MODEL-ÇIKIŞ ve 1-CİHAZ ÇIKIŞI) daha iyi bir sağlamlık sunarak daha az veri olduğunda daha iyi sonuçlar verebileceğini belirtmişlerdir. Çalışmada 33 akıllı saat ve 69 akıllı telefonu oturumlar için kullanmışlardır. Test verisi için bir aygıttan (sırasıyla bir kullanıcıdan) tüm verileri ayırma (ve böylece eğitim verisinden çıkarma) gibi gerçekçi değerlendirme modlarında, akıllı saat verileri için insan hareket tanıma sisteminde F-ölçütleri 78,6'dan 88,1'e çıkarılmıştır. Akıllı telefon verileri için orijinal F-skorları 96,4'ten 98,1'e yükseldiğini belirtmişlerdir. Yazarlar, gelecekteki çalışmalar için, ek akıllı cihaz türleri ve hareketleri üzerinde değişen ek araştırmaları düşündüklerini belirtmişlerdir. Analizde önerilen tekniklerin kullanılabilirliğinin cihazın türüne (yani akıllı telefonlar vs. akıllı saatler) bağlı olarak değişiklik gösterdiğine dair kanıtlar sunsa dahi, yazarlar çalışmalarında arzu edilen bir uzantısı giriş cihazına bağlı olarak en iyi tekniği seçmenin için daha genel kurallar olacağını belirtmişlerdir. Yazarlar akıllı telefon ile yaptıkları çalışmadaki en yüksek doğruluk başarısının %99,4 ve akıllı saat için en yüksek doğruluk başarısının %98,8 olduğunu ifade etmişlerdir.

Jain ve Kanhangad (2018) yaptıkları çalışmada bir akıllı telefonun yerleşik sensörlerini kullanarak günlük fiziksel aktivitelerin sınıflandırılması için tanımlayıcı tabanlı bir yöntem sunduklarını belirtmişlerdir. Yaklaşımlarının bir akıllı telefondan veya benzeri bir cihazdan ivmeölçer ve jiroskop sensör okumalarını kullanmışlardır. Yazarlar yaklaşımlarında ayrıca, başlangıçta elde edilen sinyallerden türetilen bir dizi zaman ve frekans sinyalini de kullandıklarını belirtmişlerdir. Önerilen yaklaşım açık kaynak iki veri setinde değerlendirilmiştir. Deneysel sonuçların, özellik seviyesindeki füzyonun puan seviyesi füzyonundan daha iyi performans gösterdiğini ve böyle bir kombinasyonun sınıflandırma doğruluğunda önemli bir gelişme sağladığını belirtmişlerdir. Yazarlar, önerilen yaklaşımın performansının ümit verici olmakla birlikte, fiziksel aktiviteler gerçekleştirilirken alt gövde bölümlerinin istemsiz yapılan hareketlerin yanlış sınıflandırmalara yol açabilecek sinyallerin oluşacağından bahsetmişlerdir. Ancak, bu tür senaryolar kısa sürerse, günlük fiziksel aktivitelerin izlenmesi için kullanıldığında yaklaşımlarının genel performansını olumsuz yönde etkilenmeyeceği ifade edilmiştir.

Yazarlar, gelecekteki çalışmalarında bu çalışmada ele alınan sinyallerden, hareket tanıma için daha uygun olan sinyalleri tanımlamanın yollarını araştırmayı düşündüklerini belirtmişlerdir. Sonraki çalışmalarda yapılması planlanan yöntem, özellik boyutunu azaltmaya ve yaklaşımlarının hesaplama performansını geliştirmelerine yardımcı olacağını ifade etmişlerdir. Tablo 2.1’de farklı hareket tanıma çalışmalarında kullanılan sensör, model ve başarı sonuçları gösterilmiştir.

Tablo 2.1. Literatürdeki farklı hareket çalışmaları

Yazar(lar)	Sensör(ler)	Model(ler)	Başarı
Foerster ve Fahrenberg. (2000)	İvmeölçer	Chi-square and Cramer's rule	96,80%
Mantjarvi ve ark. (2001)	İvmeölçer	PCA and ICA	83-90%
Parkka ve ark.(2006)	GPS, ECG, İvmeölçer	Karar ağaçları	86%
Maurer ve ark. (2006)	Çoklu Sensörler	Karar ağaçları, KNN, Naive Bayes	92%
Choudhury ve ark. (2008)	İvmeölçer	MSP	93,8%
Yin ve ark. (2007)	Manyetometre, İvmeölçer	SVM+KNLR	98,5%
Tunçel ve ark. (2009)	Jiroskop	bayesian decision theory, KNN, ANN, SVM	80-96%
Györbíró ve ark. (2009)	İvmeölçer (Akıllı Telefon)	ANN	54-99%
Kwapisz ve ark.(2011)	İvmeölçer	Decision tree, logistic regression, and MNN	91,70%
Atallah ve ark. (2011)	İvmeölçer	Relief Feature Selection, Simba Feature Selection Bayes, KNN	90%
Siirtola ve ark. (2012). [29]	İvmeölçer (Akıllı Telefon)	Decision tree KNN/QDA	95%
Chernbumroong ve ark. (2013)	İvmeölçer, Sıcaklık sensörü, Altimetre	MLP, RBF ve SVM	90.23%
Elvira ve ark. (2014)	Manyetometre, İvmeölçer, Jiroskop	Hidden Markov models (HMM)	89%
Bayat ve ark. (2014)	İvmeölçer (Akıllı Telefon)	ANN, SVM, Random Forest	81-91%
Kurban (2014)	İvmeölçer	ANN, SVM, NB,	83-98%
Capela ve ark. (2015)	İvmeölçer, Jiroskop (Akıllı Telefon)	Naive Bayes, SVM, j48 Decision Tree	90-97%
Ponce ve ark. (2016)	Manyetometre, İvmeölçer, Jiroskop	Artificial hydrocarbon networks (AHN)	97%
Damaševičius ve ark. (2016)	İvmeölçer, Jiroskop	Jaccard distance	95,6%
Howcroft ve ark. (2017)	İvmeölçer, Basınç Sensörü	Correlation-based feature selection, fast correlation-based filter (FCBF), and Relief-F	95%
Hassan ve ark. (2018)	İvmeölçer, Jiroskop (Akıllı Telefon)	Derin öğrenme tekniği, Belief Network	94,12%

Tablo 2.1. (Devam) Literatürdeki farklı hareket çalışmaları

Yazar(lar)	Sensör(ler)	Model(ler)	Başarı
Tharwat ve ark. (2018)	İvmeölçer, Jiroskop (Akıllı Telefon)	PSO-KNN	98,7%
Jordao ve ark. (2018)	İvmeölçer	ConvNet-based, ProposedCNN	94,54%
San-Segundo ve ark. (2018)	Akıllı telefon, Akıllı saat	CNN-MLP	99%
Jain ve ark. (2018)	İvmeölçer, Jiroskop (Akıllı telefon)	SVM, KNN	96,83%
Heinz ve ark., 2006; Mathie ve ark., 2002; Bidargaddi ve ark., 2002; Mathie ve ark., 2003; Bao ve ark., 2004.	İvmeölçer, Manyetometre, Jiroskop (Çoklu sensörler)	Threshold-based, Decision Tables, Decision Trees, Nearest Neighbor	46,75-89%
Ravi ve ark., 2005; Karantonis ve ark., 2006; Caros ve ark., 2005; Lombriser ve ark., 2007; Wu ve ark., 2008.	İvmeölçer, Manyetometre, Jiroskop (Çoklu sensörler)	Threshold-based, Decision Tables, Decision Trees, Nearest Neighbor	46,67-91%
Dougherty ve ark., 1995; Wang ve ark., 2005; He ve ark., 2008; Lester ve ark., 2006; Ward ve ark., 2006.	İvmeölçer, Manyetometre, Jiroskop (Çoklu sensörler)	Naive Bayes, SVM, HMMs	73-90%
Zappi ve ark., 2008; Ibrahim ve ark., 2007; Allen ve ark., 2006; Jafari ve ark., 2007; Yang ve ark., 2008.	İvmeölçer, Manyetometre, Jiroskop (Çoklu sensörler)	GMMs, ANN	76-95%
Berchtold ve ark., 2010; Gupta ve Dallas, 2014; Henpraserttae ve ark., 2008; Hoque ve Stankovic, 2012; Iso ve Yamazaki, 2006; Kose ve ark., 2012; Lane ve ark., 2012.	GPS, İvmeölçer, Mikrofon, Konum Sensörü	Bulanık Çıkarım, Relief-F, Kümeleme, Bayesçi olasılıklar, KNN, Naive Bayes	65-98%
Lee ve Cho, 2011; Mannini ve Sabatini, 2010; Mathie ve ark., 2004; Miluzzo ve ark., 2008; Saponas ve ark., 2008; Sohn ve ark., 2006; Yang 2009; Zhu ve Sheng, 2012.	İvmeölçer, GPS, Çoklu Sensörler	HMM, Hidden Markov Model, İkili karar Ağacı, Karar Ağacı, Naive-Bayesian Network, Logistic Regression, KNN, SVM, Neural network ensemble	67-99%
Ermes ve ark., 2008; Tapia ve ark., 2007; Kao ve ark., 2009; Brezmes ve ark., 2009; Riboni ve Bettini, 2011; Berchtold ve ark., 2010.	İvmeölçer, Çevresel Sensörler (GPS, Akıllı Saat, Akıllı Telefon, Kalp atışı ekranı)	Decision Tree-based classifier, Naive-Bayes classifier, Bulanık Çıkarım, KNN,	56-98%

Tablo 2.1. (Devam) Literatürdeki farklı hareket çalışmaları

Yazar(lar)	Sensör(ler)	Model(ler)	Başarı
Hanai ve ark., 2009; He ve Jin, 2008; He ve Jin, 2009; Zu ve Sheng, 2009; Altun ve Barshan, 2010; Cheng ve ark., 2010; McGlynn ve Madden, 2011; Pham ve Abdelzaher, 2008; Vinh ve ark., 2011; Lara ve ark., 2011; Khan ve ark., 2010; Jatoba ve ark., 2008; Chen ve ark., 2008; Minnen ve ark., 2007.	İvmeölçer, Jiroskop, Çevresel Sensörler, Elektrotlar	Naive-Bayes, HMM, Bulanık Çıkarım, SVM, KNN, ANN, Linear Discriminant Analysis, Bayesian Network classifier	77-99%

3. MATERYAL ve METOT

3.1. Materyal

Tez çalışması sürecinde geliştirilen öznelik çıkarma yöntemlerinin performanslarını değerlendirmek amacıyla UCI kütüphanesinden temin edilen MHealth (Mobil Health) veri seti (Banos ve ark., 2015a; Banos ve ark., 2015b) kullanılmıştır. Üzerinde çalışılan veri seti Tablo 3.1’de verilen 12 fiziksel aktiviteden oluşan vücut hareketleri ve yaşamsal belirtileri içeren on gönüllüden alınmış verileri içermektedir.

Tablo 3.1. Veri setinde yer alan hareketler

Etiket	Aktivite
L1	Hareketsiz durma (1 dk.)
L2	Oturma ve rahatlama (1 dk.)
L3	Uzanma(1 dk.)
L4	Yürüme (1 dk.)
L5	Merdiven çıkma (1 dk.)
L6	Öne eğilme (20 kez)
L7	Kolları yukarı kaldırma(20 kez)
L8	Dizleri bükme (Çömelme) (20 kez)
L9	Bisiklet sürme (1 dk.)
L10	Tempolu yürüyüş yapma (1 dk)
L11	Koşma (1 dk.)
L12	Öne ve arkaya zıplama(20 kez)

Veri setini oluşturmak için giyilebilir 3 adet 3 eksenli sensör kullanılmıştır. Bu sensörler, sırasıyla deneklerin göğüs bölgesi, sağ el bilekleri ve sol ayak bileklerine yerleştirilmiş ve elastik kayışlar kullanılarak tutturulmuştur. Çok eksenli sensör kullanılması, vücut bölümlerinin çeşitli hareketleri ivme, dönüş hızı ve manyetik alan yönelimine bağlı ölçmeyi ve böylece vücut dinamiklerini daha iyi yakalamayı sağlamıştır. Göğüs hizasına yerleştirilen sensör, 2 uçlu elektrokardiyogram (EKG) ölçümlerini sağlamıştır. Tüm algılama yöntemleri, insan aktivitesini yakalamak için yeterli olduğu düşünülen 50 Hz’lik bir örnekleme hızında kaydedilmiştir.


Bu veri setindeki aktiviteler, vücut parçalarının çeşitliliğini içeren hareketleri (örneğin kolları yukarı kaldırma, dizleri bükme), hareketlerin yoğunluğu (örneğin bisiklet sürme, oturma ve rahatlama) ve uygulama hızları ve dinamikleri içeren (örneğin koşma ve hareketsiz durma) günlük yaşamın genel aktivitelerine göre seçilmiştir. Veri seti, deneklerden elinden gelen en iyi performans sergilenerek laboratuvar dışında bir ortamda

toplanan verilerden oluşturulmuştur. Bu veri setinin oluşturulması için 10 gönüllünün kayıtları alınmıştır. Her gönüllü 12 fiziksel hareketi gerçekleştirmiştir. Her kişi için toplanan veriler kişiye ait bir dosyada saklanmıştır. Her dosya Tablo 3.2’de ayrıntılı olarak verilen sütunlar halinde tüm sensörlerden elde edilen tüm satırlardaki örneklerden oluşmaktadır.

Tablo 3.2. Veri setinde bulunan sütunlara ait bilgiler

Sütun No	Açıklama
1	Göğüs sensöründen ivmeölçer (X ekseni)
2	Göğüs sensöründen ivmeölçer (Y ekseni)
3	Göğüs sensöründen ivmeölçer (Z ekseni)
4	EKG sinyali (1. uç)
5	EKG sinyali (2. uç)
6	Sol ayak bileği sensöründen alınan ivmeölçer (X ekseni)
7	Sol ayak bileği sensöründen alınan ivmeölçer (Y ekseni)
8	Sol ayak bileği sensöründen alınan ivmeölçer (Z ekseni)
9	Sol ayak bileği sensöründen alınan jireskop (X ekseni)
10	Sol ayak bileği sensöründen alınan jireskop(Y ekseni)
11	Sol ayak bileği sensöründen alınan jireskop (Z ekseni)
12	Sol ayak bileği sensöründen alınan manyetometre (X ekseni)
13	Sol ayak bileği sensöründen alınan manyetometre (Y ekseni)
14	Sol ayak bileği sensöründen alınan manyetometre (Z ekseni)
15	Sağ el bilekleği sensöründen alınan ivmeölçer (X ekseni)
16	Sağ el bilekleği sensöründen alınan ivmeölçer (Y ekseni)
17	Sağ el bilekleği sensöründen alınan ivmeölçer (Z ekseni)
18	Sağ el bilekleği sensöründen alınan jireskop (X ekseni)
19	Sağ el bilekleği sensöründen alınan jireskop (Y ekseni)
20	Sağ el bilekleği sensöründen alınan jireskop (Z ekseni)
21	Sağ el bilekleği sensöründen alınan manyetometre (X ekseni)
22	Sağ el bilekleği sensöründen alınan manyetometre (Y ekseni)
23	Sağ el bilekleği sensöründen alınan manyetometre (Z ekseni)
24	Sınıf etiketi

Şekil 3.1’de çalışmada kullanılan veri setindeki hareketlere ait örnek işaretler bulunmaktadır.



Şekil 3.1. Tüm hareketlere ait örnek işaretler (A) L1 (hareketsiz durma) hareketi, (B) L2 (oturma ve rahatlama) hareketi, (C) L3 (uzanma) hareketi, (D) L4 (yürüme) hareketi, (E) L5 (merdiven çıkma) hareketi, (F) L6 (öne eğilme) hareketi, (G) L7 (kolları yukarı kaldırma) hareketi, (H) L8 (dizleri bükme) hareketi, (I) L9 (bisiklet sürme) hareketi, (J) L10 (tempolu yürüyüş yapma) hareketi, (K) L11 (koşma) hareketi, (L) L12 (öne ve arkaya zıplama) hareketi

Çalışma sürecinde geliştirilen yöntemler Şekil 3.1’de örnek kısımları verilen bu hareket işaretleri üzerinde uygulanmıştır.

3.2. Metot

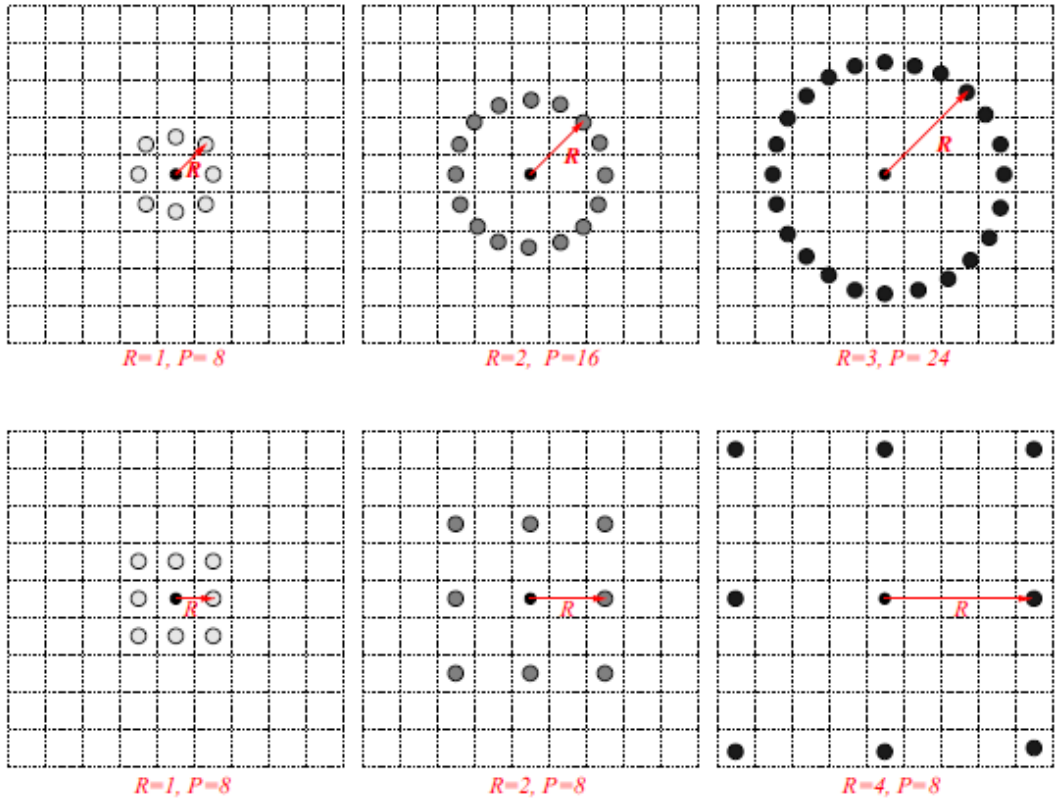
3.2.1. Yerel İkili Örüntüler (YİÖ)

Yerel İkili Örüntüler (Local Binary Patterns) metodu görüntü işlemede kullanılan komşuluk değerlerine göre görüntüyü açıklayan bir istatistiksel yaklaşımdır. Ojala ve arkadaşları bu yöntemi bir operatör adıyla yerel görüntü kontrastı için tamamlayıcı bir ölçüt olarak ortaya atmıştır (Ojala ve ark., 1996). Bu yöntemin ışık değişimlerine karşı duyarlılığı az olduğu için gri seviye görüntüler üzerinde kullanılmaktadır. YİÖ metodu genellikle iki boyutlu gri görüntüler üzerinde öznelik çıkarımı için tercih edilmektedir.

YİÖ metodu merkez ve komşu piksel değerleri arasında sıralı ikili karşılaştırmalara dayalı, ayırimsama gücü yüksek bir desen analizi tekniğidir (Ojala ve Pietikinen, 2000). YİÖ metodu iki boyutlu bir görüntüdeki pikselleri kendi etrafındaki pikseller ile karşılaştırma tekniğine dayanmaktadır. Bu metot ile 9 pikseli bir görüntü

parçasında merkez piksel (P_C) ve 8 komşu pikseller (P_i) seçilerek merkez pikseli bu 8 komşu piksel ile tek tek karşılaştırılmaktadır. Karşılaştırma sonucunda merkez piksel için ikilik tabanda yeni bir değer elde edilmektedir. İkilik tabanda elde edilen bu değer onlu tabana çevrilerek merkez piksel bu onlu tabana çevrilmiş yeni değer ile etiketlenmektedir. Daha sonra tüm görüntü üzerinde her pikseli tek tek merkez piksel kabul ederek tüm pikseller için yeni etiketler oluşturulmaktadır. Etiketler oluşturulurken YİÖ metodu Şekil 3.2'de de gösterildiği gibi farklı şekillerde uygulanabilmektedir. YİÖ metodu tanımlanan iki kritere göre uygulanmaktadır. Bu kriterler merkez değer için seçilecek olan komşu sayısı (P) ve komşu piksellerin merkez piksele olan uzaklıkların (R) ölçüsüdür. YİÖ metodu uygulamalarında P komşuluk değeri farklı değerlerde alınabilmektedir. P değeri arttıkça daha fazla öznelik histogramı oluşturulacağı için işlem maliyeti de artmaktadır. Tersisi durumda yani P komşuluk değeri küçük alındığında ise önemli bilgi kaybına sebep olabilmektedir. Bu sebeple genellikle YİÖ uygulamalarında P komşuluk değeri 8 olarak alınmaktadır. YİÖ uygulamalarının dayandığı ikinci kriter olan R uzaklık değeri ile de farklı ölçekteki örüntülerin analizi gerçekleştirilmektedir. Uzaklık ölçütü ile farklı dairesel komşuluklar da kullanılabilir. Sonuç olarak farklı P ve R değerleri ile farklı ölçeklerdeki analizleri gerçekleştirmek mümkün olmaktadır.

YİÖ metodu $YİÖ_{P,R}$ gösterimiyle ifade edilmektedir. Şekil 3.2'de farklı YİÖ operatörlerine ait örnekler bulunmaktadır. YİÖ asıl versiyonunda YİÖ operatörü, pikselin sadece 8 komşusunu göz önünde bulundurmaktadır. Ama farklı piksel sayılı bütün dairesel komşulukları kapsayacak şekilde genişletilebilmektedir (Ojala ve ark., 1996; Ojala ve Pietikinen, 2002).



Şekil 3.2. Farklı YİÖ uygulamaları

YİÖ metodu her pikseli merkez piksel olarak kabul edip komşu pikseller ile karşılaştırma işlemini gerçekleştirmektedir. Komşu piksel merkez pikselden büyük veya eşit ise bu komşu piksel “1” olarak, değilse “0” olarak etiketlenmektedir. Böylece her merkez piksel değeri için ikilik tabanda 8 basamaklı yeni bir değer elde edilmektedir. Bu ikilik değer onlu tabana çevrilerek 0-255 arası bir değer ile merkez değer etiketlenmektedir. Bu onlu tabandaki değer verilen pikselin etrafındaki yerel yapısal bilgiyi temsil etmektedir (Şekil 3.3).

YİÖ metodunun bir piksel için matematiksel formülü Denklem (3.1) ve Denklem (3.2)'de gösterildiği gibidir (Ojala ve ark., 2000).

$$t = G(x_i) - G(x) \quad (3.1)$$

$$S(t) = \begin{cases} 1 & \text{if } t \geq 0 \\ 0 & \text{if } t < 0 \end{cases}$$

$$YİÖ(x) = \sum_{i=0}^p S(t)2^i \text{ dir.} \quad (3.2)$$

Burada x : merkez pikselin yeri x_i : i 'nci komşu pikselin yeri, $G(\cdot)$: piksel yoğunluk değeridir.



Şekil 3.3. YİÖ etiketinin oluşturulması

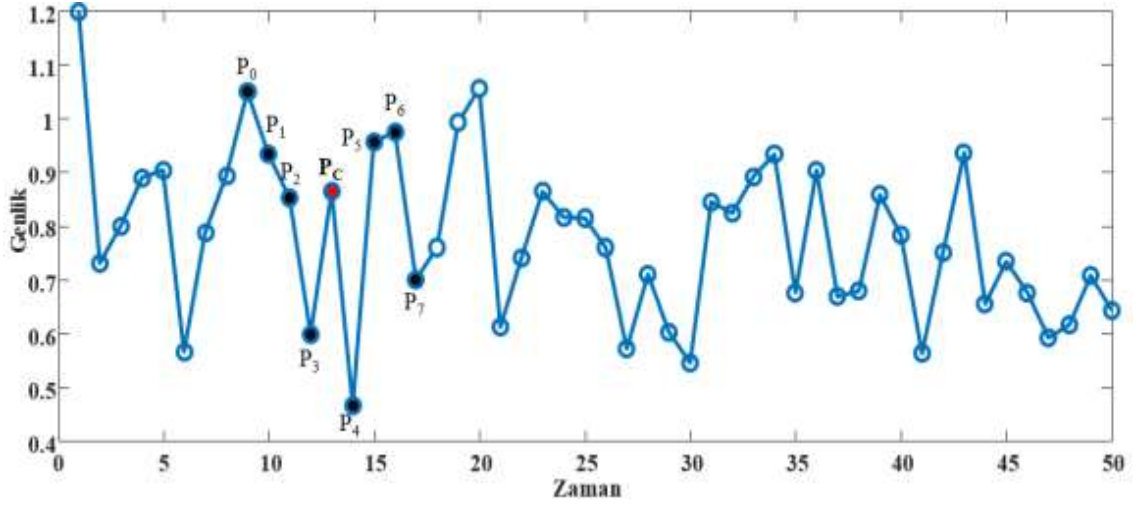
Şekil 3.3'teki alt resimde; $P = \{P_0, P_1, P_2, P_3, P_4, P_5, P_6, P_7\}$ olan komşu değerleri sırasıyla 18, 33, 44, 35, 46, 57, 11, 43'tür. P_C merkez değeri ise 42'dir. Denklem (3.2) den, $S(t) = \{t_0, t_1, t_2, t_3, t_4, t_5, t_6, t_7, t_8\}$ hesaplanmaktadır. $P_C = \{S(18 < 42), S(33 < 42), S(44 > 42), S(35 < 42), S(46 > 42), S(57 > 42), S(11 < 42), S(43 > 42)\}$ ve $S(t) = \{0, 0, 1, 0, 1, 1, 0, 1\}$ elde edilmektedir. Bu 8 bitlik ikilik sayı onlu tabana dönüştürülerek merkez değer 45 olarak etiketlenmektedir. Merkez pikselin önceki değeri 42 iken YİÖ değeri 45 olmaktadır. YİÖ metodu her pikseli kaydıra kaydıra merkez değer kabul ederek Şekil 3.3'te gösterildiği gibi yeni etiketler oluşturmaktadır. Diğer bir deyişle bu işlem görüntüdeki tüm pikseller için gerçekleştirilmektedir.

3.2.2. Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ)

Genellikle iki boyutlu olarak görüntü işlemede yaygın bir şekilde kullanılan Yerel İkili Örüntüler (YİÖ) yöntemi tek boyutlu hale getirilerek ham işaretlerden öznitelik çıkarım yöntemi olarak Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) metodu geliştirilmiştir (Kaya ve ark., 2014; Kaya, 2015; Kuncan ve ark., 2019). 1B-YİÖ metodu bir boyutlu dizilimli işaretler için veri işlemede farklı uygulamalarda kullanılmaktadır. Zaman serisi şeklinde dizilmiş tek boyutlu işaretlere uygulanarak farklı örüntüler elde etmeyi sağlamaktadır (Kaya ve ark., 2015; Kaya ve Ertuğrul, 2016).

1B-YİÖ yönteminin çalışma prensibi, bir boyutlu dizilimli sinyal üzerinde merkez değer olarak belirlenen bir değer belirlenen bir komşu değerleri ile karşılaştırmalar yapılarak ikili kodlar elde edilmesine dayanmaktadır. Bu işlem işarettaki tüm değerler için tekrarlanmaktadır. Böylece elde edilen ikili kodlar onlu tabana çevrilerek 1B-YİÖ etiketi elde edilmektedir.

Şekil 3.4'te verilen çalışma sürecinde kullanılan veri setine ait L3 (uzanma) hareketinin örnek işaret parçası üzerinde 1B-YİÖ işaretinin elde edilmesi aşağıda adım adım ayrıntılı olarak açıklanmaktadır.



Şekil 3.4. 1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

L3 (uzanma) hareketine ait Şekil 3.4'te verilen işaret örneği üzerinde merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu belirlenerek karşılaştırmalar yapılmaktadır.

Birinci adımda P_C merkez değer öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşusu alınmaktadır. Şekil 3.4'e göre P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) komşu değerleri bulunmaktadır. Şekil 3.4'te belirtilen örnek merkez değer ve komşu değerlere ait sayısal bilgiler Şekil 3.5'te verilmiştir. 1B-YİÖ etiketinin oluşturulmasında Şekil 3.5'te verilen sayısal bilgiler kullanılmaktadır.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.5. 1B-YİÖ metoduna göre merkez değer ve komşu değerler

İkinci adımda Şekil 3.5'te verilen merkez değer ve bu merkez değere ait 8 komşu değerlerin sayısal karşılıkları Denklem (3.3) ve Denklem (3.4)'e göre karşılaştırılarak ikili değerler elde edilmektedir.

x ham işaret üzerindeki bir örnek merkez değer olmak üzere, 1B-YİÖ etiketi Denklem (3.3) ve Denklem(3.4) kullanılarak elde edilmektedir.

$$t = P_i - P_c \quad (3.3)$$

$$1B\text{-YİÖ}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.4)$$

Denklem (3.3)'te verilen P_C , merkez değeri ve P_i , merkez değere ait i . komşuluk değerini göstermektedir. P_C merkez değer ve P_i komşu değerlere ait Şekil 3.5'te verilen sayısal değerler karşılaştırıldığında P_i komşu değer P_C merkez değerden büyük veya eşit ise P_i komşu değer "1" olarak, değilse "0" olarak etiketlenmektedir. Bu şekilde seçilen tüm komşulara ait sayısal değerler merkeze ait sayısal değer ile karşılaştırılarak ikili kod elde edilmektedir. L3 (uzanma) hareketine ait Şekil 3.4'te verilen örnek işaret parçası üzerinde örnek merkez değer ve komşu değerler karşılaştırılarak elde edilen etiketler Şekil 3.6'da verilmiştir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	1	0	0	0.8645	0	1	1	0

Şekil 3.6. 1B-YİÖ metoduna göre ikili dizge

Üçüncü adımda karşılaştırma sonrası oluşan ikili kod onlu koda dönüştürülerek 1B-YİÖ metoduna göre P_C merkez değer için yeni bir değer elde edilmektedir.

$$11000110=198$$

P_C								
1.0491	0.9331	0.8514	0.5988	198	0.4658	0.9552	0.9751	0.7002

Şekil 3.7. 1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Şekil 3.7'de verildiği gibi L3 (uzanma) hareketine ait örnek değerler ile oluşturulan merkez değere ait yeni değer 198 olmaktadır. Bu yeni ondalık değer merkez değerinin çevresindeki yerel yapı bilgisini ifade etmektedir.

Dördüncü adımda komşu değerler ile karşılaştırma işlemi sinyal üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. Böylece her değer için 0-255 arasında değerlere sahip 1B-YİÖ etiketi elde edilmektedir. Elde edilen her bir değerlerin frekansı bir örüntüyü ifade etmektedir. Bu örüntüler ile sensör işaretlerine ait önemli bilgilerin elde edilmesi mümkündür.


3.2.3. Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler (OT-1B-YİÖ)

HT başarısını artırmak amacıyla elde edilecek özneliklerin dönüşümlerle daha özlü hale getirilmesi için geliştirilen yöntemlerden bir diğeri de Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) modeline dayanarak geliştirilen Ortalama Tabanlı Bir Boyutlu Yerel İkili Örüntüler (OT-1B-YİÖ) metodudur.

OT-1B-YİÖ metodu 1B-YİÖ metodunda olduğu gibi, bir boyutlu dizilimli işaret üzerinde P komşuluk değerine göre P_C merkez değerden öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değer dikkate alınarak, P_C merkez değer ve bu komşu değerlerin Denklem (3.5)'e göre ortalama değerinin alınmasına dayanmaktadır.

$$\text{ortalama} = \frac{\sum_{i=0}^{p-1} P_i + P_c}{9} \quad (3.5)$$

Şekil 3.8'de verilen işaret örneği üzerinde OT-1B-YİÖ metodu uygulanarak merkez değer için yeni etiketin oluşturulması aşağıda adım adım açıklanmaktadır.



Şekil 3.8. OT-1B-YİÖ metodu kullanılarak öznelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.8'de verilen işaret örneği üzerinde 1B-YİÖ yönteminde olduğu gibi merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu belirlenerek karşılaştırmalar yapılmaktadır. P_C merkez değer öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değer belirlenmektedir. Şekil 3.8'de gösterildiği gibi P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri bulunmaktadır.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.9. OT-1B-YİÖ metoduna göre merkez değer ve komşu değerler

P_C merkez değer ve belirlenen komşu değerlerin Denklem (3.5)'e göre ortalaması hesaplanmaktadır.

$$ortalama = \frac{7.3932}{9} = 0.821$$

x ham işaret üzerindeki bir örnek işaret olmak üzere, OT-1B-YİÖ etiketi Denklem (3.6) ve Denklem (3.7) kullanılarak elde edilmektedir.

$$t = P_i - ortalama \quad (3.6)$$

$$OT-1B-YİÖ(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.7)$$

Burada P_i değerleri komşuluk değerleri ve ortalama değeri ise seçilen merkez değer ve kendine en yakın 8 komşu değerlerin ortalamasını ifade etmektedir. P_i komşu değerler hesaplanan ortalama değer ile karşılaştırıldığında P_i komşu değer ortalama değerden büyük veya eşit ise P_i komşu değer "1" olarak, değilse "0" olarak etiketlenmektedir. Bu şekilde tüm komşu değerler ortalama değer ile karşılaştırılarak Şekil 3.10 da verilen ikili kod elde edilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	1	1	0	0.8645	0	1	1	0

Şekil 3.10. OT-1B-YİÖ metoduna göre ikili dizge

Karşılaştırma sonrası oluşan ikili kod 1B-YİÖ metodunda da olduğu gibi onlu koda dönüştürülerek OT-1B-YİÖ yöntemine göre P_C merkez değer için yeni bir değer elde edilmektedir. Şekil 3.11'de görüldüğü gibi P_C merkez değerinin önceki değeri 0.8645 iken yeni dönüştürülmüş değeri 200 olarak elde edilmektedir.

11100110=200

P_c								
1.0491	0.9331	0.8514	0.5988	200	0.4658	0.9552	0.9751	0.7002

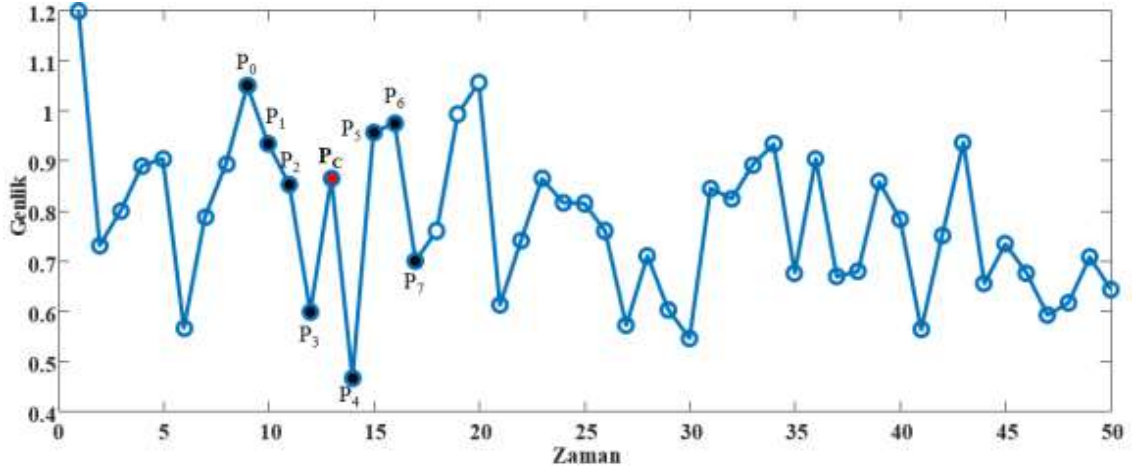
Şekil 3.11. OT-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Karşılaştırma işlemi işaret üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. Böylece her değer için 0-255 arasında değerlere sahip OT-1B-YİÖ değeri elde edilmektedir. Elde edilen her bir değer için frekansı bir örüntüyü ifade etmektedir. Sınıflandırma başarısı elde edilen özniteliklere bağlıdır. OT-1B-YİÖ yöntemi ile 1B-YİÖ yöntemine göre daha farklı öznitelikler elde edilmektedir. Farklı öznitelikler HT uygulamalarında daha etkin olabilmektedir.

3.2.4. Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler (MT-1B-YİÖ)

Tez çalışması sürecinde 1B-YİÖ metodu dikkate alınarak geliştirilen bir diğer öznitelik çıkarım yöntemi ise Medyan Tabanlı Bir Boyutlu Yerel İkili Örüntüler metodudur. MT-1B-YİÖ metodu bir boyutlu dizilişli sinyal üzerinde bir merkez değer seçilerek bu merkez değere en yakın 8 komşusunun değeri karşılaştırmalar yaparak merkez değere yeni değer atamaya dayanmaktadır. MT-1B-YİÖ etiketi oluşturulurken seçilen merkez değer ve bu merkez değere en yakın 8 komşu değerlerin ortancası (*med*) alınarak karşılaştırma işlemi gerçekleştirilmektedir.

MT-1B-YİÖ metoduna göre merkez değere yeni etiket oluşturulurken öncelikle bu merkez değer için komşuları belirlenmektedir. Şekil 3.12’de verilen işaret örneği üzerinde örnek merkez değer ve kendine en yakın 8 komşu değer seçilmesi gösterilmektedir.



Şekil 3.12. MT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.12’de verilen işaret örneği üzerinde seçilen merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu değer belirlenerek bu 9 değerden küçükten büyüğe doğru sıralaması yapılarak ortanca değer belirlenmektedir. P_C merkez değer öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değer bulunmaktadır. Şekil 3.12’ye göre P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri bulunmaktadır. Şekil 3.13’te belirlenen merkez değer ve seçilen komşu değerlerin ortanca değeri bulunarak, belirlenen komşu değerler bu ortanca değer ile karşılaştırılmaktadır.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.13. MT-1B-YİÖ metoduna göre merkez değer ve komşu değerler

Seçilen merkez değer ve belirlenen komşu değerler Şekil 3.14’te verildiği gibi küçükten büyüğe doğru sıralanmaktadır. Elde edilen sıralı dizgenin ortanca elemanı karşılaştırma için kullanılacak olan ortanca değeri ifade etmektedir. Ortanca, merkez değer P_C ile P_i komşu değerlerin oluşturduğu serinin küçükten büyüğe sıralandıktan sonra ortada kalan değerdir. Verilen örnek işaret değerlerine göre ortanca değer 0.8645 olarak bulunmaktadır. Ortanca olarak bulunan değer komşu değerler ile karşılaştırılmaktadır.

0.4658	0.5988	0.7002	0.8514	0.8645	0.9331	0.9552	0.9751	1.0491
--------	--------	--------	--------	---------------	--------	--------	--------	--------

Şekil 3.14. Ortanca değer

x ham işaret üzerindeki bir örnek işaret olmak üzere, MT-1B-YİÖ Denklem (3.8) ve Denklem (3.9) kullanılarak elde edilmektedir.

$$t = P_i - med \quad (3.8)$$

$$MT-1B-YİÖ(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.9)$$

Burada P_i değerleri komşuluk değerleri ve med değeri ise seçilen merkez değer ve kendine en yakın 8 komşu değer küçüğe doğru sıralanmış dizideki ortanca değeri ifade etmektedir. P_i komşu değerler ortanca değer ile karşılaştırıldığında P_i komşu değer ortanca değerden büyük veya eşit ise P_i komşu değer “1” olarak, değilse “0” olarak etiketlenmektedir. Bu şekilde tüm komşu değerler ortanca değer ile karşılaştırılarak Şekil 3.15’te verilen ikili kod elde edilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	1	0	0	0.8645	0	1	1	0

Şekil 3.15. MT-1B-YİÖ metoduna göre ikili dizge

Karşılaştırma sonrası oluşan ikili kod onlu koda dönüştürülerek Şekil 3.16’da gösterildiği gibi MT-1B-YİÖ yöntemine göre P_C merkez değer için yeni bir değer elde edilmektedir.

$$11000110=198$$

P_C								
1.0491	0.9331	0.8514	0.5988	198	0.4658	0.9552	0.9751	0.7002

Şekil 3.16. MT-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Şekil 3.16’da verildiği gibi merkez değer önceki değeri 0.8645 iken MT-1B-YİÖ metodu ile oluşturulan yeni değeri 198 olmaktadır. Karşılaştırma işlemi işaret


üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. Böylece her değer için 0-255 arasında değerlere sahip MT-1B-YİÖ değeri elde edilmektedir. Elde edilen her bir değerın frekansı 1B-YİÖ metodunda olduğu gibi bir örüntüyü ifade etmektedir. Öznitelik seçiminde çıkarılmış olan öznitelikler indirgenerek daha ayırt edici sonuçlar alınabilmektedir.

3.2.5. Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler (ÇÖ-1B-YİÖ)

Tez çalışması kapsamında geliştirilen öznitelik çıkarım yöntemlerinden bir diğeri de tabanı YİÖ yöntemine dayanan Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) modelinin çok ölçekli olarak işlenmesi ile oluşan Çok Ölçekli Bir Boyutlu Yerel İkili Örüntüler (ÇÖ-1B-YİÖ) metodudur.

ÇÖ-1B-YİÖ metodunun çalışma prensibi, 1B-YİÖ metodunda olduğu gibi bir boyutlu dizilimli sinyal üzerinde merkez değer olarak belirlenen bir değerın belirli komşu değerleri ile karşılaştırmalar yapılarak ikili kodlar elde edilmesine dayanmaktadır. ÇÖ-1B-YİÖ metodunun 1B-YİÖ metodundan farkı, 1B-YİÖ metodunda komşuluk değeri $P=8$ alınırken, ÇÖ-1B-YİÖ metodunda komşuluk değeri sayısı farklı alınabilmektedir. Seçilen komşuluk değerinin farklı olması farklı örüntüler oluşturmayı sağlamaktadır. Veri üzerinde çeşitli denemeler yapılarak elde edilen veri için en iyi sonucu verecek komşuluk değerinin tahlili yapılabilmektedir.


Belirlenen komşuluk değerine göre yapılan karşılaştırma işlemi işaretteki tüm değerler merkez değer olarak seçilerek tekrarlanmaktadır. Böylece elde edilen ikili kodlar onlu tabana çevrilerek ÇÖ-1B-YİÖ etiketi elde edilmektedir. Şekil 3.17’de ÇÖ-1B-YİÖ metoduna göre seçilen merkez değeri $P=6$ alınarak belirlenen komşu değerleri gösterilmektedir.



Şekil 3.17. $P=6$ alınarak ÇÖ-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3(uzanma) hareketi işaretine ait bir bölüm

Şekil 3.17’de gösterildiği gibi $P=6$ alınarak merkez değerden önce en yakın 3 adet komşu ve merkez değerden sonra en yakın 3 adet komşu seçilmektedir.

Şekil 3.18’de $P=12$ alınarak verilen işaret örneği üzerinde ÇÖ-1B-YİÖ işaretinin elde edilmesi aşağıda ayrıntılı olarak açıklanmaktadır.



Şekil 3.18. $P=12$ alınarak ÇÖ-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3(uzanma) hareketi işaretine ait bir bölüm

Şekil 3.18’de gösterildiği gibi işaret üzerindeki her değer kendisinden önceki en yakın 6 komşu değer ve kendisinden sonraki en yakın 6 komşu değer ile karşılaştırılarak ÇÖ-1B-YİÖ operatörü oluşturulmaktadır. Karşılaştırma sonucu elde edilen ikili dizge daha sonra onlu tabana çevrilerek her değer için ÇÖ-1B-YİÖ etiketleri elde edilmektedir.

İkili dizge oluşturmak için ilk olarak $P=12$ kadar komşu değer alınmaktadır. Daha sonra örnek P_C merkez değer seçilerek bu merkez değerın öncesinde ve sonrasında en yakın $P/2$ kadar komşu değer belirlenmektedir. $P=12$ için merkez değerın (P_C) öncesinde ($P_0, P_1, P_2, P_3, P_4, P_5$) komşu değerleri ve sonrasında ($P_6, P_7, P_8, P_9, P_{10}, P_{11}$) komşu değerleri alınmaktadır (Şekil 3.18). Seçilen merkez değer ve belirlenen komşu değerlere ait sayısal değerler Şekil 3.19’da gösterilmektedir.

P_0	P_1	P_2	P_3	P_4	P_5	P_C	P_6	P_7	P_8	P_9	P_{10}	P_{11}
0.7876	0.8936	1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002	0.7598	0.9923

Şekil 3.19. $P=12$ alınarak ÇÖ-1B-YİÖ metoduna göre merkez değer ve komşu değerler

Şekil 3.19’da verilen tüm komşu değerler merkez değer ile karşılaştırılmaktadır. Eğer belirlenen komşu işaret (P_i) değeri seçilen merkez işaret (P_C) değerinden küçük ise “0” olarak, diğer durumlarda ise “1” olarak etiketlenmektedir.

Karşılaştırma işlemi Denklem (3.10) ve Denklem (3.11)’e göre işaret üzerindeki tüm değerler için gerçekleştirilmektedir.

x ham işaret üzerindeki bir örnek merkez değer olmak üzere, ÇÖ-1B-YİÖ metoduna göre ikili dizge Denklem (3.10) ve Denklem (3.11) ile elde edilmektedir.

$$t = P_i - P_C \quad (3.10)$$

$$\text{ÇÖ-1B-YİÖ}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.11)$$

Burada sırasıyla P_i ve P_C değerleri belirlenen komşuluk değer ile seçilen merkez değeri göstermektedir. $P=12$ alınarak ÇÖ-1B-YİÖ metoduna göre seçilen merkez değer ve belirlenen komşu değerlere ait Şekil 3.19’da verilen değerler karşılaştırılarak elde edilen ikili dizge Şekil 3.20’de gösterilmektedir.

P_0	P_1	P_2	P_3	P_4	P_5	P_C	P_6	P_7	P_8	P_9	P_{10}	P_{11}
0	1	1	1	0	0	0.8645	0	1	1	0	0	1

Şekil 3.20. $P=12$ alınarak ÇÖ-1B-YİÖ metoduna göre ikili dizge

Şekil 3.20’de de gösterildiği gibi ikili dizge oluşturulduktan sonra bu ikili değer onlu tabana çevrilerek Şekil 3.21’de verilen P_C değerinin ÇÖ-1B-YİÖ etiketi elde edilmektedir.

011100011001=1817												
P_0	P_1	P_2	P_3	P_4	P_5	P_C	P_6	P_7	P_8	P_9	P_{10}	P_{11}
0.7876	0.8936	1.0491	0.9331	0.8514	0.5988	1817	0.4658	0.9552	0.9751	0.7002	0.7598	0.9923

Şekil 3.21. ÇÖ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Şekil 3.21’de verildiği gibi merkez değer önceki değeri 0.8645 iken ÇÖ-1B-YİÖ metodu ile oluşturulan yeni değeri 1817 olmaktadır. Bu işlemler işaret üzerindeki tüm değerler teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. Böylece oluşturulan onlu tabandaki değerler ÇÖ-1B-YİÖ etiketi olarak isimlendirilmektedir. Bu değerlerin her birine ait frekans değeri farklı örüntüleri ifade etmektedir. ÇÖ-1B-YİÖ işaretinin histogramı alındığında 2^P kadar farklı örüntü bulunmaktadır. Örneğin $P=6$ alındığında 64, $P=12$ alındığında ise 4096 öznitelik elde edilmektedir. P değeri küçük alındığında bir kısım örüntüler kaybolmaktadır. P yüksek değerler alındığında ise örüntü sayısı artmakla beraber hesaplama maliyeti de artmaktadır.


3.2.6. Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-YİÖ)

Geliştirilen öznitelik çıkarım yöntemlerinden bir diğeri de Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) modelinin merkez değer (P_C) öncesinde ve sonrasında belirlenen komşu değerleri ile ortalamasının alınmasına dayanarak merkez değer komşu değerler ile ağırlıklandırılmış hali ile komşuluk değerlerin karşılaştırılmasına karşılık gelen Ağırlıklandırılmış Bir Boyutlu Sağlam Yerel İkili Örüntüler (A-1B-YİÖ) yöntemidir. A-1B-YİÖ yöntemi, işareti gürültülere karşı çok daha duyarlı hale getirmektedir.

A-1B-YİÖ yönteminin çalışma prensibi, bir boyutlu dizilimli işaret üzerinde P komşuluk değerine göre seçilen P_C merkez değerden öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değer dikkate alınarak, P_C merkez değer ve belirlenen komşu değerlerin ortalamasının alınmasına dayanmaktadır. Bu ortalama değer komşu değerler ile ağırlıklandırılmaktadır. Ağırlıklandırılmış değer merkez değer ile komşu değerler arasındaki gürültünün etkisini oldukça fazla azaltmaktadır. P_C merkez

değerin belirlenen P_i komşu değeri elde edilen ağırlıklandırılmış değer komşu değerler ile karşılaştırılmaktadır. P_i komşu değer ağırlıklandırılmış değerden büyük veya eşit ise “1” olarak, değilse “0” olarak etiketlenmektedir.

Şekil 3.22’de verilen örnek işaret parçası üzerinde seçilen merkez değer ve belirlenen komşu değerler ile A-1B-YİÖ işaretinin elde edilmesi aşağıda ayrıntılı olarak açıklanmaktadır.



Şekil 3.22. A-1B-YİÖ metodu kullanılarak öznelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.22’de verilen işaret örneği üzerinde merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu değer belirlenerek karşılaştırmalar yapılmaktadır. P_C merkez değer öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşusu alınmaktadır. Şekil 3.22’de verilen P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri belirlenmektedir. Seçilen bu merkez değer ve belirlenen komşu değerlerine ait sayısal bilgiler Şekil 3.23’te verilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.23. A-1B-YİÖ metoduna göre merkez değer ve komşu değerler

Şekil 3.23’te sayısal değerleri verilen P_C merkez değer ve belirlenen komşu değerlerin Denklem (3.12)’ye göre ortalaması alınarak ağırlıklandırma işleminden sonra karşılaştırma işlemi yapılmaktadır.

$$ortalama = \frac{\sum_{i=0}^{p-1} P_i + P_c}{9} \quad (3.12)$$

A-1B-YİÖ metodu ile merkez değer için etiket elde edilirken gürültüyü azaltmak amacı ile ağırlıklandırma işlemi yapılmaktadır. Ağırlıklandırılmış değer Denklem (3.13) ve Denklem (3.14) kullanılarak elde edilmektedir.

$$\alpha = \frac{P_c}{ortalama} \quad (3.13)$$

$$WP_c = \frac{\alpha P_c + \sum_{i=0}^{p-1} P_i}{8 + \alpha} \quad (3.14)$$

Burada α değeri merkez değerın ortalamaya olan oranını vermektedir, WP_c ise ağırlıklandırılmış değeri temsil etmektedir. Denklem (3.12) kullanılarak ortalama değeri aşağıdaki şekilde hesaplanmaktadır.

$$ortalama = \frac{7.3932}{9} = 0.8214$$

Daha sonra bulunan bu ortalama değeri kullanılarak Denklem (3.13) ve Denklem (3.14)'e göre α ve karşılaştırmada kullanılacak olan WP_c değerleri hesaplanmaktadır.

$$\alpha = \frac{0.8645}{0.8214} = 1.0524$$

$$WP_c = \frac{0.9097 + 6.5287}{9.0524} = 0.8217$$

Hesaplanan WP_c değeri kullanılarak A-1B-YİÖ değeri elde edilmektedir. x ham işaret üzerindeki bir örnek merkez değer olmak üzere, A-1B-YİÖ etiketi Denklem (3.15) ve Denklem (3.16) kullanılarak elde edilmektedir.

$$t = P_i - WP_c \quad (3.15)$$

$$A-1B-Y\ddot{I}\ddot{O}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.16)$$

Burada sırasıyla P_i ve P_C deęerleri komşuluk deęer ile merkez deęeri, WP_C deęeri ise aęırlıklandırılmıř merkez deęeri gstermektedir. P_i komřu deęerler aęırlıklandırılmıř deęer ile karřılařtırıldıęında P_i komřu deęer aęırlıklandırılmıř deęerden byk veya eřit ise P_i komřu deęer "1" olarak, deęilse "0" olarak etiketlenmektedir. Bu řekilde tm komřu deęerler aęırlıklandırılmıř deęer ile karřılařtırılarak řekil 3.24'te verilen ikili kod elde edilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	1	1	0	0.8645	0	1	1	0

řekil 3.24. A-1B-YİÖ metoduna gre ikili dizge

Karřılařtırma sonrası oluřan ikili kod řekil 3.25'te gsterildięi gibi onlu koda dnřtrlerek A-1B-YİÖ metoduna gre P_C merkez deęer iin yeni bir deęer elde edilmektedir.

$$11100110=200$$

P_C								
1.0491	0.9331	0.8514	0.5988	200	0.4658	0.9552	0.9751	0.7002


řekil 3.25. A-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

řekil 3.25'te verildięi gibi merkez deęerin nceki deęeri 0.8645 iken A-1B-YİÖ metodu ile oluřturulan yeni deęeri 200 olmaktadır. Karřılařtırma iřlemi iřaret zerindeki her deęer teker teker merkez deęer seilerek ve aęırlıklandırılarak tm deęerlere uygulanmaktadır. Bylece her deęer iin 0-255 arasında deęerlere sahip A-1B-YİÖ deęeri elde edilmektedir. Elde edilen A-1B-YİÖ deęeri iřaretin alternatif bir gsterimi olarak sınıflandırmada dikkate alınacak histogramı oluřurmada kullanılmaktadır.

3.2.7. Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler (KT-1B-YİÖ)

1B-YİÖ metoduna dayalı geliştirilen öznitelik çıkarım yöntemlerinden biri de Komşuluk Tabanlı Bir Boyutlu Yerel İkili Örüntüler (KT-1B-YİÖ) metodudur. Bir boyutlu YİÖ yönteminde P komşuluk değerine göre merkez değerden hemen öncesinde $P/2$ ve hemen sonrasında $P/2$ kadar komşu değer dikkate alınırken, KT-1B-YİÖ yönteminde ise merkez değerden α kadar öncesinden başlanarak ve β kadar atlanarak $P/2$ ve α kadar sonrasında başlanarak ve β kadar atlanarak $P/2$ kadar komşu değer dikkate alınmaktadır (Kaya ve Ertuğrul, 2016).

KT-1B-YİÖ metodu, bir boyutlu dizilimli işaret üzerinde merkez değer olarak belirlenen bir değer α ve β değerleri dikkate alınarak belirli komşu değerleri ile karşılaştırmalar yapılarak ikili kodlar elde edilmesine dayanmaktadır. Komşu değerler belirlenirken merkez değerden α kadar önceki komşudan ve merkez değerden α kadar sonraki komşudan başlanılıp β kadar atlanarak komşu değerler alınmaktadır. Bu işlem işaretteki tüm değerler merkez değer olarak seçilerek tekrarlanmaktadır. Böylece elde edilen ikili kodlar onlu tabana çevrilerek KT-1B-YİÖ işareti elde edilmektedir. Şekil 3.26'da $\alpha=1$ ve $\beta=2$ değerleri için komşuluk değerlerin belirlenmesine ait örnek gösterim verilmiştir.




Şekil 3.26. $\alpha=1$ ve $\beta=2$ alınarak KT-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.26'da seçilen merkez değer $\alpha=1$ ve $\beta=2$ değerine göre KT-1B-YİÖ metodunun uygulanması için belirlenen komşu değerleri gösterilmektedir. P_c merkez

değerden $\alpha=1$ kadar uzaklıktaki komşu değerlerinden başlanarak ve $\beta=2$ komşu değer atlanarak komşu değerler belirlenmiştir.

Şekil 3.27’de verilen örnek işaret üzerinde $\alpha=2$ ve $\beta=2$ değerlerine göre KT-1B-YİÖ işaretinin elde edilmesi aşağıda ayrıntılı olarak açıklanmaktadır.



Şekil 3.27. $\alpha=2$ ve $\beta=2$ alınarak KT-1B-YİÖ metodu kullanılarak öznelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.27’de verilen işaret örneği üzerinde merkez değer (P_C) için $\alpha=2$ komşu değer öncesinde ve $\alpha=2$ komşu değer sonrasında toplam $P=8$ adet komşu değer $\beta=2$ komşu değer kadar atlanarak belirlenip merkez değer ile karşılaştırmalar yapılmaktadır. Şekil 3.27’de de görüldüğü gibi P_C merkez değer öncesinde $P/2$ ve sonrasında $P/2$ kadar komşu değer alınmaktadır. P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri bulunmaktadır. Seçilen merkez değer ve belirlenen komşu değerlere ait sayısal bilgiler Şekil 3.28’de verilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
0.9037	0.7876	1.0491	0.8514	0.8645	0.9552	0.7002	0.9923	0.6120

Şekil 3.28. $\alpha=2$ ve $\beta=2$ alınarak KT-1B-YİÖ metoduna göre merkez değer ve komşu değerler

Şekil 3.28’de verilen merkez değer ve komşu değerler Denklem (3.17) ve Denklem (3.18)’e göre karşılaştırılarak ikili değerler elde edilmektedir. x ham işaret üzerindeki bir örnek merkez değer olmak üzere,

$$t = P_i - P_c \quad (3.17)$$

$$KT-1B-YIÖ(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.18)$$

Burada sırasıyla P_i ve P_c değerleri komşuluk değer ile merkez değeri göstermektedir. Şekil 3.28’de sayısal değerleri verilen P_c merkez değer P_i komşu değerler ile karşılaştırıldığında P_i komşu değer P_c merkez değerden büyük veya eşit ise P_i komşu değer “1” olarak, değilse “0” olarak etiketlenmektedir. Bu şekilde tüm komşu değerler merkez değer ile karşılaştırılarak seçilen merkez değer için ikili kod Şekil 3.29’da gösterildiği gibi elde edilmektedir.

P_0	P_1	P_2	P_3	P_c	P_4	P_5	P_6	P_7
1	0	1	0	0.8645	1	0	1	0

Şekil 3.29. KT-1B-YIÖ metoduna göre ikili dizge

Şekil 3.29’da verilen karşılaştırma sonrası oluşan ikili kod onlu koda dönüştürülerek KT-1B-YIÖ metoduna göre P_c merkez değer için yeni bir değer elde edilmektedir (Şekil 3.30).

$$10101010=170$$

P_c								
0.9037	0.7876	1.0491	0.8514	170	0.9552	0.7002	0.9923	0.6120

Şekil 3.30. KT-1B-YIÖmetodu ile elde edilen onlu tabanlı etiket

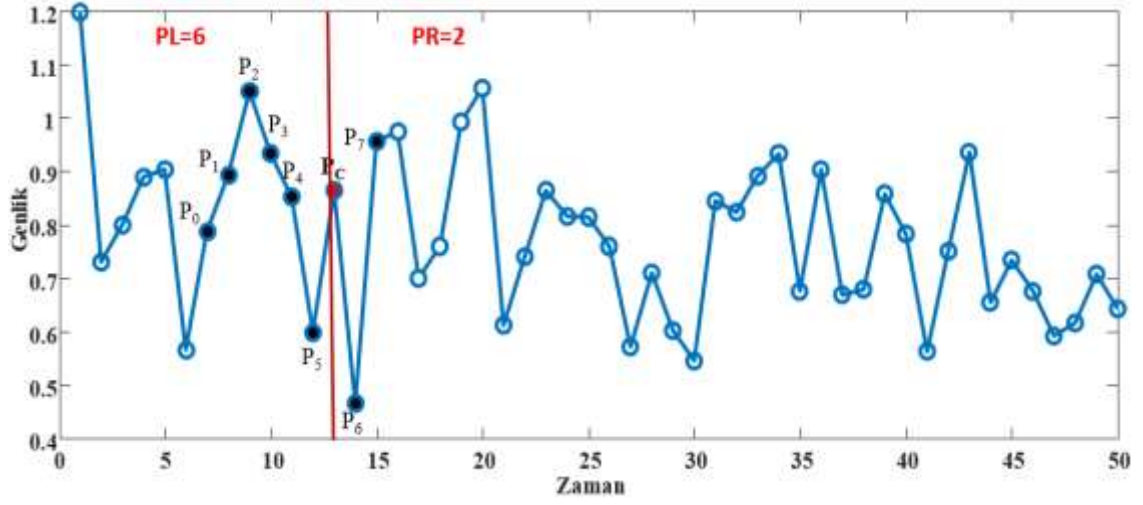
Şekil 3.30’da verildiği gibi merkez değerın önceki değeri 0.8645 iken KT-1B-YIÖ metodu ile oluşturulan yeni değeri 170 olmaktadır. KT-1B-YIÖ metodunda α ve β parametreleri değiştirilerek her bir değerin frekansı için bir örüntü oluşacağından dolayı, çok sayıda farklı örüntü elde etmek mümkündür. Uygulamaya göre yüksek başarımlı sağlayacak öznelik yapısı α ve β değerlerine göre değişmektedir. Sınıflandırma da kullanılan bu farklı örüntüler hız ve başarımlı arttırmaktadır. Karşılaştırma işlemi işaret üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulandığında, her değer için 0-255 arasında değerlere sahip KT-1B-YIÖ değeri elde edilmektedir.

3.2.8. Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler (K-1B-YİÖ)

Tez çalışması sürecinde geliştirilen öznitelik çıkarım yöntemlerinden bir diğeri de Kaydırmalı Bir Boyutlu Yerel İkili Örüntüler metodudur. K-1B-YİÖ metodu da 1B-YİÖ metoduna dayanılarak geliştirilmiştir. K-1B-YİÖ metodu uygulanarak öznitelik çıkarımı yapılırken Bir 1B-YİÖ modelinin merkez değeri (P_C) öncesinde ve sonrasında alınan komşuluk değeri kaydırılarak farklı örüntülerin oluşması sağlanmaktadır. 1B-YİÖ yönteminde P komşuluk değerine göre merkez değerden öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değeri dikkate alınırken, K-1B-YİÖ yönteminde ise merkez değeri öncesinde ve sonrasında farklı sayılarda olmak üzere toplamda 8 adet komşu değeri dikkate alınmaktadır.

K-1B-YİÖ metodunun çalışma prensibi, bir boyutlu dizilimli işaret üzerinde merkez değeri olarak belirlenen bir değeri kendinden önce ve kendinden sonra belirlenen toplam 8 komşu değeri ile karşılaştırmalar yapılarak ikili kodlar elde edilmesine dayanmaktadır. Bu işlem işaret üzerindeki tüm değerler teker teker merkez değeri seçilerek öncesinde ve sonrasında seçilecek komşu değerlerine göre tekrarlanmaktadır. 1B-YİÖ metodunda olduğu gibi elde edilen ikili kodlar onlu tabana çevrilerek K-1B-YİÖ işareti elde edilmektedir.

K-1B-YİÖ metoduna dayanarak öznitelik çıkarımı yapılırken P_C merkez değerden önce en yakın PL adet komşu değeri dikkate alınırken, sonrasında en yakın PR adet komşu değeri dikkate alınmaktadır. Şekil 3.31’de K-1B-YİÖ metoduna ait örnek işaret gösterilmektedir.



Şekil 3.31. $PL=6$ ve $PR=2$ alınarak K-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

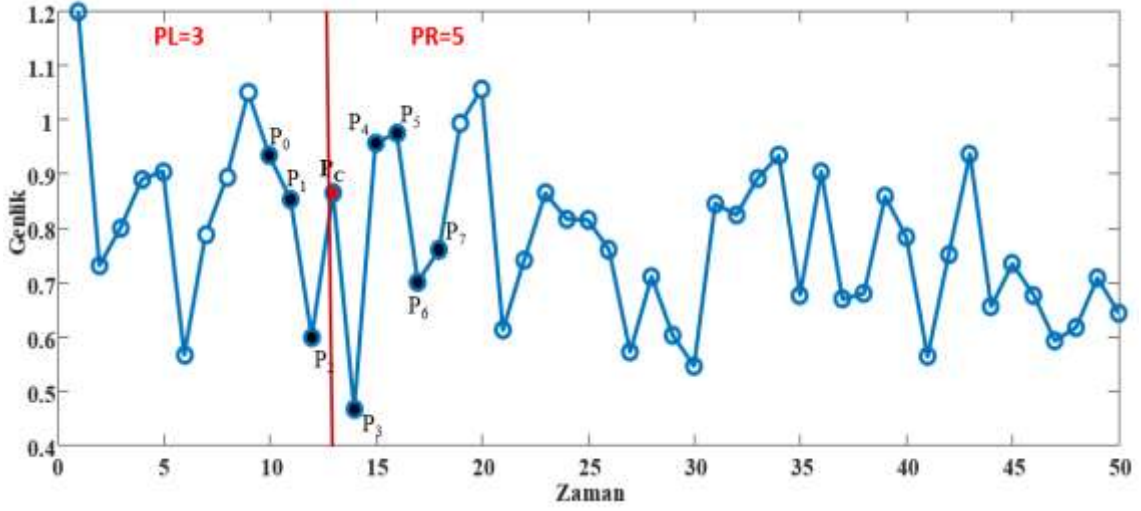
Şekil 3.31’de $PL=6$ ve $PR=2$ değerleri için bir örnek seçilmiş merkez değer ve K-1B-YİÖ yöntemine göre komşu değerler gösterilmiştir. Seçilen merkez değerden önce en yakın 6 komşu değer dikkate alınırken, merkez değerden sonra en yakın 2 komşu değer dikkate alınmaktadır.

Aşağıdaki örnekte P komşuluk değeri 8 alınarak K-1B-YİÖ etiketinin elde edilmesi ayrıntılı olarak açıklanmaktadır. Öncelikle P_C merkez değerden önce dikkate alınacak komşu değer sayısı $PL=k$ belirlenmektedir. Aşağıdaki örnek işaret için P_C merkez değerden önce dikkate alınacak komşu değer sayısı Denklem (3.19)’a göre $k=3$ olarak alınırken, P_C merkez değer sonrasında dikkate alınacak komşu değer sayısı Denklem (3.20)’ye göre $PR=5$ olmaktadır.

$$PL = k \quad (3.19)$$

$$PR = P - k \quad (3.20)$$

PL ve PR değerleri belirlendikten sonra Şekil 3.32’de gösterildiği gibi merkez değer ve komşu değerler seçilerek karşılaştırma işlemi gerçekleştirilmektedir.



Şekil 3.32. $PL=3$ ve $PR=5$ alınarak K-1B-YİÖ metodu kullanılarak öznitelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.32’de verilen işaret örneği üzerinde merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu değer belirlenerek karşılaştırmalar yapılmaktadır. P_C merkez değer öncesinde $PL=3$ ve sonrasında $PR=5$ kadar komşu değer alınmaktadır. P_C merkez değerden önce (P_0, P_1, P_2) ve sonra (P_3, P_4, P_5, P_6, P_7) değerleri bulunmaktadır. Seçilen merkez değer ve belirlenen komşu değerlere ait sayısal değerler Şekil 3.33’te gösterilmektedir.

P_0	P_1	P_2	P_C	P_3	P_4	P_5	P_6	P_7
0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002	0.7598

Şekil 3.33. $PL=3$ alınarak K-1B-YİÖ metoduna göre seçilen merkez değer ve komşu değerler

Şekil 3.33’te sayısal değerleri verilen merkez değer ve belirlenen komşu değerler Denklem (3.21) ve Denklem (3.22)’ye göre karşılaştırılarak ikili değerler elde edilmektedir. x ham işaret üzerindeki bir örnek merkez değer olmak üzere,

$$t = P_i - P_C \quad (3.21)$$

$$K-1B-YİÖ(x) = \sum_{i=0}^{p-1} f(t) 2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.22)$$

Burada sırasıyla P_i ve P_C değerleri merkez değerden önce ve sonra belirlenen komşuluk değer ile merkez değeri göstermektedir. Şekil 3.33'te verilen P_C merkez değer P_i komşu değerler ile karşılaştırıldığında P_i komşu değer P_C merkez değerden büyük veya eşit ise P_i komşu değer "1" olarak, değilse "0" olarak etiketlenmektedir. Bu şekilde belirlenen tüm komşu değerler seçilen merkez değer ile karşılaştırılarak Şekil 3.34'te verilen ikili kod elde edilmektedir.

P_0	P_1	P_2	P_C	P_3	P_4	P_5	P_6	P_7
1	0	0	0.8645	0	1	1	0	0

Şekil 3.34. $PL=3$ alınarak K-1B-YİÖ metoduna göre ikili dizge

Karşılaştırma sonrası oluşan ikili kod Şekil 3.34'te gösterilmektedir. Elde edilen bu ikili kod 1B-YİÖ metodunda olduğu gibi onlu koda dönüştürülerek K-1B-YİÖ metoduna göre P_C merkez değer için yeni bir değer elde edilmektedir (Şekil 3.35).

$$10001100=140$$

P_0	P_1	P_2	P_C	P_3	P_4	P_5	P_6	P_7
0.9331	0.8514	0.5988	140	0.4658	0.9552	0.9751	0.7002	0.7598


Şekil 3.35. K-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Şekil 3.35'te verildiği gibi merkez değerın önceki değeri 0.8645 iken K-1B-YİÖ metodu ile oluşturulan yeni değeri 140 olmaktadır. K-1B-YİÖ metoduna göre öznitelik çıkarımı yapılırken farklı denemeler yapılarak merkez değer öncesinde ve sonrasında seçilecek olan komşu değerlerine göre karşılaştırmalar yapılması farklı örüntülerin oluşmasını sağlamaktadır. Merkez değerden önce ve sonra seçilen komşu değerlere göre 0 ile 8 arasında 9 farklı durum oluşmaktadır. Üzerinde işlem yapılan veriye göre en uygun PL ve PR değerleri farklılık gösterebilmektedir. Bu sebeple her çalışma setine göre en uygun PL ve PR değerlerini bulmak için mümkün olan tüm kombinasyonlar denenmektedir. PL ve PR değerleri değiştikçe göz önünde bulundurulması gereken komşu değerlerde değişeceğinden dolayı her denemenin örüntüsü farklı olmaktadır. Farklı değerleri denemek maliyet açısından olumsuz olsa bile elde edilecek örüntünün başarısı bu olumsuzluğun göz ardı edilmesini sağlayabilmektedir.

Karşılaştırma işlemi işaret üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. Böylece seçilen bir merkez değeri için belirlenen PL değerine göre 0-255 arasında değerlere sahip K-1B-YİÖ etiketi elde edilmektedir. Elde edilen her bir değer frekansını bir örüntüyü ifade etmektedir.

3.2.9. Üçlü Desenli Bir Boyutlu Yerel İkili Örüntüler (ÜD-1B-YİÖ)

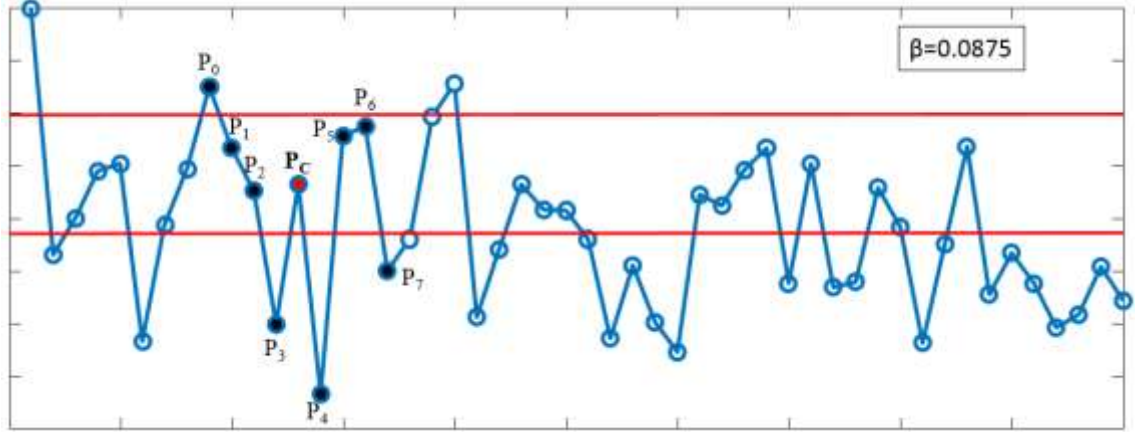
Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) metoduna dayanarak geliştirilen öznelik çıkarım yöntemlerinden bir diğeri ise Üçlü Desenli Bir Boyutlu Yerel İkili Örüntüler (ÜD-1B-YİÖ) metodudur. ÜD-1B-YİÖ metodunun çalışma prensibi, bir boyutlu dizilimli işaret üzerinde merkez değer olarak belirlenen bir değer kullanıcısı tarafından tanımlanan bir β değerine göre komşuları arasında karşılaştırmalar yapılarak, pozitif ve negatif olarak ikili kodlar oluşturulup alt ve üst özellikler grubunu üretmeye dayanmaktadır. Belirlenen değere göre karşılaştırma işlemi için dikkate alınan komşu değerlerin karşılaştırmaya etkisi değişmektedir. Şekil 3.36'da farklı β değerlerine göre filtreleme işlemleri verilmektedir.



Şekil 3.36. Farklı β değerlerine göre filtreleme (A) $\beta=0.050$ için filtreleme, (B) $\beta=0.0875$ için filtreleme, (C) $\beta=0.125$ için filtreleme

Şekil 3.36’da gösterildiği gibi β değerleri değiştikçe bantlar arasında kalan komşu değerlerinde değiştiği gözlenmektedir. Dikkate alınan komşu değerlerin bant genişliğine göre değişimleri karşılaştırma işlemi yapılırken farklı sonuçlar alınmasına imkan sağlamaktadır. Bu şekilde farklı örüntüler elde etmek mümkün olmaktadır.

Şekil 3.37’de $\beta=0.0875$ alınarak verilen örnek işaret üzerinde ÜD-1B-YİÖ işaretinin elde edilmesi aşağıda ayrıntılı olarak açıklanmaktadır.



Şekil 3.37. $\beta=0.0875$ alınarak ÜD-1B-YİÖ metodu ile öznelik çıkarımı L3(uzanma) hareketi işaretine ait bir bölüm

Şekil 3.37’de verilen işaret örneği üzerinde merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu belirlenerek, kullanıcı tarafından tanımlanan $\beta=0.0875$ değerine göre karşılaştırmalar yapılmaktadır. P_C merkez değer öncesinde $P/2$ ve sonrasında $P/2$ kadar komşusu alınmaktadır. P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri bulunmaktadır. Seçilen merkez değer ve belirlenen komşu değerlere ait sayısal veriler Şekil 3.38’de gösterilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.38. ÜD-1B-YİÖ metoduna göre seçilen merkez değer ve komşu değerler

Şekil 3.38’de sayısal değerleri verilen merkez değer ve belirlenen komşu değerler Denklem (3.23)’e göre karşılaştırılarak alt ve üst özellik kümelerinin oluşturulması için ikili değerler elde edilmektedir. x ham sinyal üzerindeki bir örnek sinyal olmak üzere,

$$\text{ÜD-1B-YİÖ}(x) = \begin{cases} 1, P_i > P_c + \beta \\ 0, P_i \leq P_c + \beta \text{ ve } P_i \geq P_c - \beta \\ -1, P_i < P_c - \beta \end{cases} \quad (3.23)$$

Burada sırasıyla P_i ve P_C değerleri komşuluk değer ile merkez değeri, β değeri ise kullanıcı tarafından tanımlanan değeri göstermektedir. P_i komşu değerler β değerine göre P_C merkez değer ile karşılaştırıldığında P_i komşu değer P_C merkez değer ve β değerinin

toplamından büyük ise ‘1’ olarak, P_i komşu değer P_C merkez değer ve β değerinin farkından küçük ise ‘-1’ olarak, P_i komşu değer P_C merkez değer ve β değerinin toplamından küçük veya eşit ve farkından büyük veya eşit ise ‘0’ olarak etiketlenmektedir. Bu şekilde tüm komşu değerler bant genişliğine göre merkez değer ile karşılaştırılarak ikili kod elde edilmektedir (Şekil 3.39).

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	0	0	-1	0.8645	-1	0	0	0

Şekil 3.39. Komşu değerlerin $\beta=0.0875$ değerine göre merkez değer ile karşılaştırılarak ikili dizgenin oluşturulması

Şekil 3.39’da verilen ikili dizgede pozitif ve negatif değerlerin mevcut olduğu görülmektedir. β parametresine göre karşılaştırma işleminden sonra iki farklı P_C değeri oluşmaktadır. Negatif olanlar ile alt özellikler üretilirken, pozitif olanlar ile üst özellikler üretilmektedir. Üst özellikler üretilirken Denklem (3.24) kullanılarak onlu kodlar oluşturulmaktadır.

$$\ddot{U}D - 1B - Y\ddot{I}\ddot{O}_{\ddot{U}ST}(x) = \begin{cases} 1, P_i > P_C + \beta \\ 0, P_i \leq P_C + \beta \end{cases} \quad (3.24)$$

Burada P_i i. komşu değer, P_C merkez değer ve β kullanıcı tarafından tanımlanan değeri göstermektedir. P_i komşu değeri P_C merkez değer ve β değerinin toplamından büyük ise “1” olarak değilse “0” olarak etiketlenmektedir. Bu şekilde belirlenen tüm komşu değerleri seçilen merkez değer ile karşılaştırıldığında elde edilen ikili tabandaki üst özellik grubu Şekil 3.40’ta gösterilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	0	0	0	0.8645	0	0	0	0

Şekil 3.40. Üst özellik grubuna ait ikili dizge

Merkez değer için elde edilen üst özellik grubuna ait ikili dizge onlu koda çevrilerek Şekil 3.41’de verilen yeni bir üst özellik operatörü oluşmaktadır.

10000000=128

P_C								
1.0491	0.9331	0.8514	0.5988	128	0.4658	0.9552	0.9751	0.7002

Şekil 3.41. ÜD-1B-YİÖ_{ÜST} metodu ile elde edilen onlu tabanlı etiket

Merkez değer için yeni oluşan değer Şekil 3.41’de de verildiği gibi 128 olmaktadır. Bu değer üst özellik değeri olarak etiketlenmektedir. Alt özellikler üretilirken Denklem (3.25)’e göre karşılaştırma yapılarak ikili kodlar oluşturulmaktadır.

$$ÜD-1B-YİÖ_{ALT}(x) = \begin{cases} 1, P_i < P_c - \beta \\ 0, P_i \geq P_c - \beta \end{cases} \quad (3.25)$$

Burada P_i i. komşu değer, P_c merkez değer ve β değeri kullanıcı tarafından tanımlanan bant genişliğini göstermektedir. P_i komşu değeri P_c merkez değer ve β değerinin farkından küçük ise 1 olarak değilse 0 olarak etiketlenmektedir. Karşılaştırma sonucu elde edilen ikili tabandaki alt özellik grubu Şekil 3.42’de gösterilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
0	0	0	1	0.8645	1	0	0	0

Şekil 3.42. Alt özellik grubuna ait ikili dizge

Elde edilen alt özellik grubuna ait ikili dizge onlu koda çevrilerek yeni bir alt özellik operatörü oluşmaktadır (Şekil3.43).

00011000=24

P_C								
1.0491	0.9331	0.8514	0.5988	24	0.4658	0.9552	0.9751	0.7002

Şekil 3.43. ÜD-1B-YİÖ_{ALT} metodu ile elde edilen onlu tabanlı etiket

Şekil 3.43’de belirtildiği gibi merkez değer için ikinci bir etiket daha oluşmaktadır. Bu şekilde merkez değer için alt ve üst özellik gruplarına ait iki farklı öznitelik değeri elde edilmektedir.

Karşılaştırma işlemi işaret üzerindeki her değer teker teker merkez değer seçilerek β parametresine bağlı olarak tüm değerlere uygulanmaktadır. Bu parametre işaretin genliğine göre kullanıcı tarafından belirlenmektedir. Ele alınan farklı işaretler için β parametresinin farklı değerlerinin denenmesi gerekmektedir. Elde edilen her bir değer frekansı bir örüntüyü ifade ettiğinden dolayı farklı örüntülerin yakalanması için β parametresi önemli olmaktadır. Üretilen her alt-üst farklı değerleri, merkez değer farklı değeri olarak saklanmaktadır. Bu farklı iki işaret grubunun histogramlarından alt ve üst şeklinde iki öznelik grubu elde edilmektedir. Geliştirilen bu yöntemde P ve β değerleri farklı örüntülerin elde edilmesi için önemli olmaktadır. Bu iki parametrenin değerlerine denemeler sonucunda karar verilmektedir.

3.2.10. İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler (İ-1B-YİÖ)

Bir Boyutlu Yerel İkili Örüntüler (1B-YİÖ) yönteminin çok sayıda veriye sahip işaretler üzerinde daha başarılı sonuçlar vermesi için öznelik sayısının artırılmasına dayalı olarak geliştirilen bir yöntem de İndirgenmiş Bir Boyutlu Yerel İkili Örüntüler (İ-1B-YİÖ) metodudur.


İ-1B-YİÖ metodu uygulaması, bir boyutlu dizilimli işaretle seçilen bir merkez değer (P_C) üzerinden 1B-YİÖ yöntemi uygulandıktan sonra indirgemeler yapılarak elde edilen yeni indirgenmiş işaret üzerinde merkez değer olarak belirlenen değerin belirli komşu değerleri ile karşılaştırmalar yapılarak ikili kodlar elde edilmesine dayanmaktadır. Bu işlem ham işaret ve indirgenmiş yeni işaretledeki tüm değerler için tekrarlanmaktadır. Böylece elde edilen ikili kodlar onlu tabana çevrilerek İ-1B-YİÖ işareti elde edilmektedir.

İ-1B-YİÖ metodu uygulanırken önemli 3 parametre tanımlanmaktadır. Bunlar indirgeme yapılırken kullanılacak örnekleme sayısını belirten pencere boyutu (PB), indirgeme yapılacak özellik türü (ortalama, minimum, maksimum, medyan) ve indirgeme sayısı (n)'dir.

Pencere boyutu (PB), indirgeme yapılırken her grup içerisinde kullanılacak olan işaret değer sayısını göstermektedir. PB çok büyük oranlarda tutulması halinde önemli veri kaybı gerçekleşebilmektedir. Bu sebeple PB değeri belirlenirken çok büyük değerler olmamasına dikkat edilmelidir. İ-1B-YİÖ metodu uygulanan bir çalışmada en uygun PB seçilmesi çeşitli denemeler yapılarak mümkün olmaktadır.

İndirgeme özelliği, seçilen PB değerine göre oluşturulan gruplardan işaretin seçilme kriteri hakkında bilgi vermektedir. PB içerisinde seçilecek olan işaret değeri PB elemanları arasında en küçük (EK), en büyük (EB), ortalama (ort) ve medyan (med) kriterlerinden birine göre belirlenmektedir. Bu kriterler, çalışma yapılan veriler üzerinde farklı etkiler göstermektedir. Çalışma yapılan veriye göre en uygun kriterin seçilmesi için denemeler yapılması gerekmektedir.

İ-1B-YİÖ metodu uygulamalarında kullanılan bir diğer parametre ise yapılacak olan indirgeme sayısı (n)'dir. Kullanıcı tarafından belirlenen n sayısına göre ham işaret üzerinde PB ve özellik kriterleri kullanılarak n aşamalı indirgeme yapılabilmektedir. Şekil 3.43'te $PB=4$, Özellik= ort ve $n=3$ alınarak İ-1B-YİÖ metodunun uygulanmasına örnek verilmiştir.




Şekil 3.44. İ-1B-YİÖ metodunun uygulanması (A) orijinal işaret, (B) 1. seviye indirgeme, (C) 2. seviye indirgeme

Şekil 3.44 (A)'da orijinal işaret gösterilmektedir. Orijinal işaret üzerinde 4'erli gruplar oluşturularak her bir grup içinde işaretlerin ortalama değeri alınarak indirgeme yapılması ile (B)'deki işaret grubu oluşmaktadır. (B)'de verilen işaret üzerinde tekrar indirgeme yapılarak (C)'deki işaret grubu elde edilmektedir.

İ-1B-YİÖ metodu uygulanırken ilk olarak ham işaret üzerinde seçilen bir merkez değer ve belirlenen en yakın 8 komşu değere (P_i) 1B-YİÖ metodu uygulanarak öznelik

çıkarmı yapılır. İkinci aşamada ise belirlenen PB 'li gruplar oluşturulur ve kullanıcı tarafından belirlenen özelliğe göre PB 'li gruplardan bir işaret değeri seçilir. Bu şekilde tüm PB 'li gruplardan bir işaret değeri seçilerek yeni bir işaret grubu oluşturulmaktadır. Yeni oluşturulan işaret grubu üzerinde 1B-YİÖ metodu uygulanarak yeni bir öznitelik grubu daha oluşturulmaktadır. Bu işlemler kullanıcı tarafından tanımlanan n sayısı kadar aşama da gerçekleştirilerek öznitelik grupları oluşturulmaktadır. İ-1B-YİÖ metodunun uygulanması maliyet açısından olumsuz etkilese de elde edilen özniteliklerin sonuçlara oldukça olumlu etki edebileceği düşünülmektedir.

Şekil 3.45'te verilen örnek işaret parçası üzerinde örnekleme sayısı $PB=4$ ve Özellik= EK alınarak $n=3$ aşamalı İ-1B-YİÖ işaretinin elde edilmesi aşağıda ayrıntılı olarak açıklanmaktadır.




Şekil 3.45. İ-1B-YİÖ metodunun $PB=4$, Özellik= EK , $n=3$ parametreleri ile uygulanması (A) orijinal işaret, (B)1. seviye indirgeme, (C)2. seviye indirgeme

Şekil 3.45'te verilen işaret grubu üzerinde indirgemeler yapılarak öznitelik çıkarmı adımları gösterilmektedir. (A)'da verilen orijinal işaret üzerinde 4'erli gruplar oluşturularak her bir grup içerisindeki en küçük değerli işaret seçilerek (B)'de verilen

işaret grubu oluşturulmaktadır. Benzer olarak (B)'de verilen işaret grubu üzerinde, belirtilen parametreler kullanılarak, indirgeme yapılması ile (C)'de verilen işaret grubu oluşmaktadır.

İ-1B-YİÖ metodu uygulamasında öncelikle orjinal işaret grubuna bir merkez değer seçilerek 1B-YİÖ metodu uygulanmaktadır (Şekil 3.46).



Şekil 3.46. İ-1B-YİÖ metodu ile öznelik çıkarımı için L3 (uzanma) hareketi işaretine ait bir bölüm

Şekil 3.46'da verilen işaret örneği üzerinde merkez değer (P_C) için öncesinde ve sonrasında toplam $P=8$ adet komşu değer belirlenerek karşılaştırmalar yapılmaktadır. P_C merkez değer öncesinde en yakın $P/2$ ve sonrasında en yakın $P/2$ kadar komşu değer alınmaktadır. P_C merkez değerden önce (P_0, P_1, P_2, P_3) ve sonra (P_4, P_5, P_6, P_7) değerleri bulunmaktadır. Seçilen merkez değer ve komşu değerlere ait sayısal bilgiler Şekil 3.47'de verilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1.0491	0.9331	0.8514	0.5988	0.8645	0.4658	0.9552	0.9751	0.7002

Şekil 3.47. İ-1B-YİÖ metoduna göre $n=1$ grubu için örnek seçilen merkez değer ve komşu değerler

Belirlenen merkez değer ve komşu değerler Denklem (3.26) ve Denklem (3.27)'ye göre karşılaştırılarak $n=1$ grubu için ikili değerler elde edilmektedir. x ham işaret üzerindeki bir örnek işaret olmak üzere,

$$t = P_i - P_c \quad (3.26)$$

$$\dot{I} - 1B - Y\ddot{O}_{n=1}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.27)$$

Burada sırasıyla P_i ve P_c değerleri komşuluk değer ile merkez değeri göstermektedir. P_c merkez değer P_i komşu değerler ile karşılaştırıldığında P_i komşu değer P_c merkez değerden büyük veya eşit ise P_i komşu değer “1” olarak, değilse “0” olarak etiketlenmektedir. Bu şekilde tüm komşu değerler merkez değer ile karşılaştırılarak $n=1$ grubu için ikili kod elde edilmektedir (Şekil 3.48).

P_0	P_1	P_2	P_3	P_c	P_4	P_5	P_6	P_7
1	1	0	0	0.8645	0	1	1	0

Şekil 3.48. $n=1$ grubu için İ-1B-YİÖmetoduna göre ikili dizge

Karşılaştırma sonrası oluşan ikili kod onlu koda dönüştürülerek $n=1$ grubu için İ-1B-YİÖ metoduna göre P_c merkez değer için yeni bir değer elde edilmektedir (Şekil 3.49).


$$11000110=198$$

P_c								
1.0491	0.9331	0.8514	0.5988	198	0.4658	0.9552	0.9751	0.7002

Şekil 3.49. $n=1$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Şekil 3.46’da verilen örnek işaret için daha fazla öznitelik elde edilmesini sağlamak amacıyla işaret üzerinde 4’erli alt gruplar oluşturularak indirgeme yapılmaktadır. İndirgeme yapılırken her 4’lü alt işaret grubu için indirgeme özelliği olarak alt grubun en küçük değerini alma özelliği kullanılmaktadır. Verilen parametrelere göre indirgeme yapıldığında Şekil 3.45 (B)’de verilen işaret grubu elde edilmektedir. Böylece $n=2$ grubu için işaretler oluşmaktadır.

Birinci aşamada tüm işaret değerlerine 1B-YİÖ metodu uygulandıktan sonra 0-255 arası değerlere sahip örüntüler oluşmaktadır. İkinci aşamada yine aynı şekilde indirgenmiş işaret grubuna 1B-YİÖ metodu uygulanmaktadır (Şekil 3.50).



Şekil 3.50. İ-1B-YİÖ metodu ile öznelik çıkarımı için indirgenmiş işarete ait bir bölüm

Şekil 3.50’de verilen indirgenmiş işaret grubu üzerinde örnek bir merkez değer ve bu merkez değere ait komşu değerler seçilerek 1B-YİÖ metodu uygulanmaktadır. Şekil 3.50’de verilen örnek işaret üzerinde seçilen merkez değer ve belirlenen komşu değerlere ait sayısal bilgiler Şekil 3.51’de verilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
0.6765	0.6685	0.5627	0.5920	0.6429	0.4486	0.7173	0.6149	0.6831

Şekil 3.51. İ-1B-YİÖ metoduna göre $n=2$ grubu için örnek seçilen merkez değer ve komşu değerler

Şekil 3.51’de verilen değerler Denklem (3.28) ve Denklem (3.29)’a göre karşılaştırılarak $n=2$ grubu için ikili dizge oluşturulmaktadır (Şekil 3.52). x indirgenmiş işaret üzerindeki bir örnek merkez işaret olmak üzere,

$$t = P_i - P_C \quad (3.28)$$

$$\hat{I}-1B-YI\ddot{O}_{n=2}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.29)$$

Burada sırasıyla P_i ve P_C değerleri indirgenmiş işaret üzerindeki komşuluk değer ile merkez değeri göstermektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
1	1	0	0	0.6429	0	1	0	1

Şekil 3.52. $n=2$ grubu için İ-1B-YİÖ metoduna göre ikili dizge


Şekil 3.52’de verilen ikili dizge onlu tabana çevrilerek $n=2$ grubu için Şekil 3.53’te verilen yeni bir İ-1B-YİÖ etiketi daha oluşturulmaktadır.

$$11000101=197$$

P_C								
0.6765	0.6685	0.5627	0.5920	197	0.4486	0.7173	0.6149	0.6831

Şekil 3.53. $n=2$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

İndirgenmiş işaret üzerinden tekrar indirgeme yapılabilmektedir. İndirgenmiş işaret üzerinde tekrar bir merkez değer seçilerek $n=3$ grubu için tekrar 1B-YİÖ metodu uygulanmaktadır. Verilen örnek üzerinde ikinci defa indirgeme yapılarak elde edilen yeni işaret grubu Şekil 3.54’te verilmektedir.



Şekil 3.54. İ-1B-YİÖ metodu ile öznetelik çıkarımı için ikinci defa indirgenmiş sensör işaretine ait bir bölüm

Şekil 3.54 incelendiğinde işlem yapılacak işaret değer sayısının azaldığı gözlenmektedir. Bunun sebebi seçilen indirgeme özelliğine göre belirlenen pencere boyutu kadar işaret değerleri arasında elemelerin yapılarak bir işaret değerinin seçilmesine dayanmaktadır. Şekil 3.54’de verilen ikinci defa indirgeme yapılarak elde

edilen indirgenmiş işaret grubu üzerinde örnek bir merkez değer ve bu merkez değere ait komşu değerler seçilerek üçüncü kez 1B-YİÖ metodu uygulanmaktadır (Şekil 3.55).

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
0.5454	0.5627	0.4486	0.6831	0.5565	0.7388	0.7749	0.6369	0.5957

Şekil 3.55. İ-1B-YİÖ metoduna göre $n=3$ grubu için örnek seçilen merkez değer ve komşu değerler

Şekil 3.55'te verilen değerler Denklem (3.30) ve Denklem (3.31)'e göre karşılaştırılarak $n=3$ grubu için ikili dizge oluşturulmaktadır.

x indirgenmiş işaret üzerindeki bir örnek merkez işaret olmak üzere,

$$t = P_i - P_C \quad (3.30)$$

$$\dot{I}-1B-YI\ddot{O}_{n=3}(x) = \sum_{i=0}^{p-1} f(t)2^i, f = \begin{cases} 1, t \geq 0 \\ 0, t < 0 \end{cases} \quad (3.31)$$

Burada sırasıyla P_i ve P_C değerleri ikinci kez indirgenmiş işaret üzerindeki komşuluk değer ile merkez değeri göstermektedir. Karşılaştırma sonrası oluşan yeni ikili dizge Şekil 3.56'da gösterilmektedir.

P_0	P_1	P_2	P_3	P_C	P_4	P_5	P_6	P_7
0	1	0	1	0.5565	1	1	1	1

Şekil 3.56. $n=3$ grubu için İ-1B-YİÖ metoduna göre ikili dizge

Oluşturulan ikili dizge onlu tabana çevrilerek $n=3$ grubu için Şekil 3.57'de verilen yeni bir İ-1B-YİÖ etiketi daha oluşturulmaktadır (Şekil 3.57).

01011111=95

P_C								
0.5454	0.5627	0.4486	0.6831	95	0.7388	0.7749	0.6369	0.5957

Şekil 3.57. $n=3$ grubu için İ-1B-YİÖ metodu ile elde edilen onlu tabanlı etiket

Karşılaştırma işlemi yine işaret üzerindeki her değer teker teker merkez değer seçilerek tüm değerlere uygulanmaktadır. İ-1B-YİÖ metodunun uygulanması ile n kere 2^P kadar öznitelik grubu oluşmaktadır. Böylece her işaret değeri için avantajlı öznitelik çıkarma operatörü oluşması mümkündür.

3.3. İstatistiksel Öznitelikler

Tez çalışması kapsamında üzerinde işlem yapılan veri setine ait 23 sütunlu işaret verileri bulunmaktadır. Sensörler aracılığı ile toplanan bu işaretler kümesine tez çalışması süresince geliştirilen öznitelik çıkarım metotları uygulandıktan sonra yeni oluşan işaretlerden istatistiksel öznitelikler elde edilmiştir. Daha sonra bu istatistiksel öznitelik vektörleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Kullanılan bu özniteliklerin sınıflandırma da performansı olumlu yönde etkileyeceği düşünülmektedir. Sınıflandırmada avantajlı olacağı düşünülen öznitelikler bu bölümde ayrıntılı olarak açıklanmaktadır.

3.3.1. Ortalama

Ortalama, bir sayısal veri serisinde bulunan tüm elemanların toplamının bu veri serisinde bulunan eleman sayısına oranını vermektedir. Ortalama istatistiksel özneliği hesaplanırken Denklem (3.32) kullanılmaktadır.

$$ortalama = \frac{\sum_{i=1}^N X_i}{N} \quad (3.32)$$

Burada N , serideki eleman sayısını ve X_i , i . elemanın değerini göstermektedir. Örneğin 3, 2, 5, 8, 13, 1 elemanlarından oluşan bir seri de ortalama hesaplanırken öncelikle serideki elemanların toplamı bulunarak eleman sayısına bölünmektedir. Örnek verilen seri de elemanların toplamı 32 olmaktadır. Bu toplam eleman sayısı olan 6'ya bölünerek ortalama değeri 5,33 olmaktadır.

3.3.2. Standart Sapma

Standart sapma, verilerin ortalamaya göre nasıl bir yayılım gösterdiğini bilgisini vermektedir. Standart sapma ile verilerin kaçının ortalama değerine yakın olduğu tahsil edilebilmektedir. Bu durumda standart sapma değerinin küçük olması verilerin ortalama değere yakın olacak şekilde bir dağılım gösterdiğini vermektedir. Standart sapma değerinin büyük olması ise serideki elemanların ortalama değerden uzak değerlerde dağılım gösterdiğini vermektedir. Standart sapma Denklem (3.33) kullanılarak hesaplanmaktadır.

$$\text{Standart Sapma} = \sqrt{\frac{\sum_{i=1}^N (X_i - \text{ort})^2}{N}} \quad (3.33)$$

Burada N , serideki eleman sayısını; X_i , i . elemanın değerini; ort , serideki elemanların ortalamasını göstermektedir. Seride bulunan tüm elemanlar eşit ise bu seriye ait standart sapma sıfır olmaktadır.

3.3.3. Enerji

Enerji, işaret gücünün bir ölçütü olarak serideki elemanların yoğunluğunun dağılımı hakkında bilgi vermektedir. Enerji Denklem (3.34) kullanılarak hesaplanmaktadır.

$$\text{Enerji} = \sqrt{\frac{\sum_{i=1}^N (X_i)^2}{N}} \quad (3.34)$$

Burada N , serideki eleman sayısını ve X_i , i . elemanın değerini vermektedir.

3.3.4. Entropi

Entropi, bir seride bulunan elemanların düzensizliğinin bir ölçütüdür. Seride bulunan elemanların düzensizliği arttıkça entropi artmaktadır. Seride bulunan elemanlar belli bir düzene sahip ise bu durumda seriye ait entropi değeri sıfır olmaktadır. Bu sebeple

entropi tahmini yapılırken ilk olarak histogramın elde edilmesi gerekmektedir. Entropi hesaplanırken Denklem (3.35) kullanılmaktadır.

$$Entropi = -\sum_{i=1}^N \frac{X_i}{E} \log\left(\frac{X_i}{E}\right) \quad (3.35)$$


Burada N , serideki eleman sayısını; X_i , i . elemanın değerini ve E , enerji değerini vermektedir.

3.3.5. Korelasyon

Korelasyon, değişkenler arasındaki ilişki hakkında bilgi vermektedir. Değişkenler arasında bulunan ilişkinin yönü ve şiddetini belirlemek amacıyla korelasyon kullanılmaktadır. Elemanlar arasında ilişki analizi yapılırken korelasyon katsayısı hesaplanmaktadır. Korelasyon katsayısı, -1 ile +1 arasında değerler almaktadır. Korelasyon katsayısı hesaplanırken Denklem (3.36) kullanılmaktadır.

$$r = \frac{\sum_{i=1}^N X_i Y_i - \frac{\sum_{i=1}^N X_i \sum_{i=1}^N Y_i}{N}}{\sqrt{\left(\sum_{i=1}^N X_i^2 - \frac{\left(\sum_{i=1}^N X_i\right)^2}{N}\right) \left(\sum_{i=1}^N Y_i^2 - \frac{\left(\sum_{i=1}^N Y_i\right)^2}{N}\right)}} \quad (3.36)$$

Burada X_i ve Y_i , aralarında ilişki tahlili yapılan iki değişken; r , korelasyon katsayısı; N , serideki eleman sayısını vermektedir. r değerinin pozitif çıkması değişkenler arasında aynı yönlü bir ilişki olduğunu, negatif değer çıkması ise değişkenler arasında zıt yönlü bir ilişki olduğunu göstermektedir. Korelasyon katsayısının sıfır çıkması durumu da değişkenler arasında herhangi bir ilişkinin olmadığını göstermektedir (Şekil 3.58).



Şekil 3.58. Korelasyon durumları (A) Değişkenler arası aynı yönlü ilişki, (B) Değişkenler arası zıt yönlü ilişki, (C) Değişkenler arası ilişki yok

3.3.6. Ardışık Mutlak Fark

Ardışık mutlak fark (AMF), seride bulunan elemanlardan iki ardışık eleman arasındaki mutlak farkların toplamının seride bulunan eleman sayısına oranını vermektedir. Bu değer seride bulunan elemanların dizilimleri hakkında bilgi vermektedir. Ardışık mutlak fark toplamı Denklem (3.37) ile elde edilmektedir.

$$AMF = \frac{\sum_{i=1}^N |X_{i+1} - X_i|}{N} \quad (3.37)$$

Burada AMF , ardışık mutlak farkları; N , serideki eleman sayısını; X_i , i . elemanın değerini göstermektedir.

3.3.7. Medyan

Medyan, bir serideki elemanların küçükten büyüğe doğru sıralanması ile oluşan sıralı dizgedeki ortanca elemanın değeridir. Medyan değerinin sırasının hesaplanması Denklem (3.38)'de verilmektedir.

$$Medyan\ Sırası = \frac{(Eleman\ sayısı + 1)}{2} \quad (3.38)$$

Örneğin 3, 2, 5, 8, 13, 1, 14 elemanlarından oluşan bir seride medyan hesaplanırken öncelikle serideki elemanların küçükten büyüğe doğru sıralanması yapılmaktadır. Verilen örnek seride bulunan elemanlar sıralandığında 1, 2, 3, 5, 8, 13, 14

dizisi elde edilmektedir. Elde edilen bu yeni dizinin ortanca elemanı yani medyanı 5 olmaktadır.

3.3.8. Çarpıklık

Çarpıklık, rastgele bir süreçteki dağılıma ilişkin bilgiyi vermektedir. Çarpıklık katsayısı (ÇK) hesaplanarak dağılımın çarpıklığının hangi yöne doğru olduğu tahlil edilebilmektedir. Çarpıklık katsayısı Denklem (3.39)'a göre hesaplanmaktadır.

$$\text{Çarpıklık} = \frac{\sum_{i=1}^N (X_i - \text{ort})^3 / N}{ss^3} \quad (3.39)$$

Burada N , serideki eleman sayısını; X_i , i . elemanın değerini; ort , serideki elemanların ortalamasını ve SS , serideki elemanların standart sapmasını vermektedir. ÇK sıfır çıktığı durum dağılımın simetrik olduğunu yani çarpıklık olmadığını göstermektedir. ÇK 'nin negatif çıkması durumu elemanların daha çok ortalamadan soluna doğru dağılmış olmasını yani sola çarpıklığı ifade ederken, pozitif çıkması dağılımın sağa çarpıklığını ifade etmektedir (Şekil 3.59).



Şekil 3.59. Çarpıklık durumları (A) Çarpıklık olmayan durum, (B) Pozitif çarpıklık durumu, (C) Negatif çarpıklık durumu

Bir seriye ait çarpıklık durumu hesaplanırken Denklem (3.40) kullanılmaktadır.

$$\text{Çarpıklık} = \frac{N-1}{(N-2)(N-2)} \left[(N+1) \left(\left(\frac{\frac{1}{N} \sum_{i=1}^N (X_i - \text{ort})^4}{\frac{1}{N} \sum_{i=1}^N (X_i - \text{ort})^2} \right) - 3 \right) + 6 \right] \quad (3.40)$$


Burada N , serideki eleman sayısını; X_i , i . elemanın değeri ve ort , serideki elemanların ortalamasını vermektedir.

3.3.9. Basıklık

Basıklık, bir dağılımın eğimi hakkında bilgi vermektedir. Basıklık durumu incelenirken basıklık katsayısına (BK) bakılmaktadır. Basıklık katsayısı hesaplanırken Denklem (3.41) kullanılmaktadır.

$$Basıklık = \frac{\sum_{i=1}^N (X_i - ort)^4}{ss^4} \cdot \frac{1}{N} - 3 \quad (3.41)$$

Burada N , serideki eleman sayısını; X_i , i . elemanın değerini; ort , serideki elemanların ortalamasını ve SS , serideki elemanların standart sapmasını vermektedir. BK sıfır olduğu durum normal dağılımı göstermektedir. Normal dağılımdan daha belirgin dağılımların BK değeri pozitif iken, normal dağılıma göre daha az belirgin dağılımların BK değeri negatif olmaktadır (Şekil 3.60).



Şekil 3.60. Basıklık durumları (A) $BK>0$ durumunda basıklık, (B) $BK=0$ durumunda normal dağılım, (C) $BK<0$ durumunda basıklık

Şekil 3.60 incelendiğinde (A)'da verilen şekil standart normal dağılıma göre daha sivri olmaktadır, (C)'de verilen şeklin daha basık olduğu görülmektedir. Bir seriye ait basıklık durumu hesaplanırken Denklem (3.42) kullanılmaktadır.

$$Basıklık = \frac{\sqrt{N(N-1)}}{N-2} \left(\frac{\frac{1}{N} \sum_{i=1}^N (X_i - ort)^3}{\frac{1}{N} \sum_{i=1}^N (X_i - ort)^2} \right)^{\frac{3}{2}} \quad (3.42)$$

Burada N , serideki eleman sayısını; X_i , i . elemanın değeri ve ort , serideki elemanların ortalamasını vermektedir.

3.3.10. Minimum

Minimum, bir serideki elemanların en küçüğünü göstermektedir. Serideki elemanlar küçükten büyüğe sıralandığında sıralı dizgenin ilk elemanı serideki minimum değeri vermektedir. Verilen serideki en küçük elemanı bulmak için Denklem (3.43) kullanılmaktadır.

$$EK = \min(X_1, X_2, X_3, \dots, X_N) \quad (3.43)$$

Burada EK , en küçük elemanı; X , serideki elemanları ve N , serideki eleman sayısını göstermektedir.

3.3.11. Maksimum

Maksimum, bir serideki elemanların en büyüğünü göstermektedir. Serideki elemanlar büyükten küçüğe sıralandığında sıralı dizgenin ilk elemanı serideki maksimum değeri vermektedir. Verilen serideki en büyük elemanı bulmak için Denklem (3.44) kullanılmaktadır.

$$EB = \max(X_1, X_2, X_3, \dots, X_N) \quad (3.44)$$

Burada EB , en büyük elemanı; X , serideki elemanları ve N , serideki eleman sayısını göstermektedir.

3.3.12. Varyasyon Katsayısı

Varyasyon, seri elemanları arasındaki dağılımın ortalamaya olan uzaklığını veren bir ölçüdür. Varyasyon katsayısı ise seri elemanlarının standart sapmasının ortalamaya göre gösterdiği değişim olarak tanımlanmaktadır. Varyasyon katsayısının hesaplanması Denklem (3.45)'te belirtilen şekilde yapılmaktadır.

$$CV = \frac{ort}{ss} \quad (3.45)$$

Burada CV , varyasyon katsayısı; ort , serideki elemanların ortalamasını ve SS , serideki elemanların standart sapmasını göstermektedir. Varyasyon katsayısı aynı zamanda standart sapmanın karesidir.

3.3.13. Hareketli Korelasyon

Hareketli korelasyon özelliği ile sensörlerden alınan verilerin belirlenen eksenler arasındaki korelasyon ilişkisi tanımlanmaktadır. Hareketli korelasyon değerleri hesaplanırken Denklem (3.46) kullanılmaktadır.

$$HK_n^{k,l} = corr(m_k, m_l) \quad (3.46)$$

Burada n , veri seti oluşturulurken kullanılan sensör tipini; HK , hareketli korelasyon özneliğini; k ve l değerleri sensörlere ait eksen türlerini vermektedir.

Çalışmada kullanılan veri setinin oluşturulduğu 3 eksenli jireskop, manyetometre ve ivmeölçer sensörlerine ait kombinasyonlar dikkate alındığında 21 farklı hareketli korelasyon özneliği ortaya çıkmaktadır.

3.4. Sınıflandırma

Tez çalışması kapsamında geliştirilen öznelik çıkarım yöntemlerinin uygulanması ile elde edilen özneliklerden, çeşitli istatistiksel öznelikler kullanılarak özneliklerin çıkarımı gerçekleştirilmektedir. Çıkarılan özneliklerin sınıflandırılması işleminde Rastgele Orman Algoritması kullanılmaktadır. Bu kısımda Rastgele Orman algoritması hakkında gerekli bilgiler verilmektedir.

3.4.1. Rastgele Orman Algoritmasının Tanımı ve Özellikleri


Rastgele Orman algoritması, denetimli öğrenme sağlayarak sınıflandırma ve regresyon problemlerinde kullanılmaktadır. RO ile problem çözümü yapılırken öncelikle problem ile ilgili olarak birden fazla karar ağacı oluşturulmaktadır. Bu karar ağaçları bir ormanı temsil etmektedir. Oluşturulan ağaç sayısı arttıkça doğru sonuç elde etme ihtimali de artmaktadır. Rastgele Orman, ağaçları büyütürken, modele ek rastgelelik katmaktadır. Bir düğümü alt düğümlere ayırırken rastgele bir öznelik alt kümesi seçilmektedir. Bu

nedenle, RO yönteminde, bir düğümün bölünmesi için algoritma tarafından özneliklerin sadece rastgele bir alt kümesi dikkate alınmaktadır. Bu da oluşturulacak ağaçların rastgeleliğini arttırmaktadır.

RF, 1996 yılında Leo Brieman tarafından geliştirilen Bagging yöntemi ve Kim Ho tarafından geliştirilen Random Subspace yönteminin birleşiminden yola çıkılarak 2001 yılında geliştirilmiştir (Breiman, 2001).

RO algoritması uygulanırken öncelikle veri setinden çok sayıda farklı alt setler seçilerek eğitim setleri oluşturulmaktadır. Daha sonra bu alt setlerden çok sayıda karar ağacı seçilerek her bir karar ağacının tahminde bulunması sağlanmaktadır. Sınıflandırma problemlerinde yapılan tahminler sonucunda en çok verilen cevap problemin çözümü olmaktadır. Aynı şekilde regresyon problemlerinde ise karar ağaçları tarafından yapılan tahminlerin ortalaması problemin çözümünü oluşturmaktadır.

RO algoritması ile oluşturulan karar ağaçlarının düğümlerini bölme ve kök düğüm bilgisine ulaşma işlemleri rastgele yapılmaktadır. RO algoritmasına ait oluşturulan örnek orman yapısı Şekil 3.61’de gösterilmektedir.



Şekil 3.61. RO algoritmasına ait ağaç ormanı

Şekil 3.61’de gösterildiği gibi RO algoritmasının yapısı eğitim veri setine ait çok sayıda karar ağacı içermektedir. Her bir karar ağacı bir başlangıç düğüm içermektedir. Bu başlangıç düğümüne dal olarak adlandırılan kısımlar aracılığıyla çocuk düğümler bağlanmaktadır. Dallanmalar yaprak düğümlere kadar devam etmektedir.

Karar ağaçlarından oluşan RO algoritması bilinen diğer makine öğrenmesi yöntemlerine göre modeli daha iyi yorumlayabilme ve mükemmel bir tahminde bulunma özelliğine sahiptir. Bunun sebebi rastgele örnekleme ve karar ağaçlarından oluşturulan ormanın iyileştirilmiş özellikler içermesidir. Böylece sapması düşük sonuçlar vererek

ağaçlar arasında düşük korelasyon sağlanmaktadır. Düşük korelasyonlu ağaçlar ile doğru sonuç alma ihtimali artmaktadır.

RO algoritması uygulanırken toplam tahminci sayısından çok düşük sayıda olmak üzere her düğüm ayrımında rastgele tahminci seçilmektedir. Oluşturulan her bir karar ağacı en geniş haliyle bırakılmaktadır (Breiman, 2001; Archer ve Kimes, 2013).

Sınıflandırma problemleri için karar ağaçları oluşturulurken, sadece bir sınıfın üyelerini içerecek şekilde yaprak düğümler kullanılmamaktadır. Regresyon problemleri için ise yaprak düğümdeki üye sayısı azalınca kadar ağaçların bölünmesine dikkat edilmelidir.

RO algoritması astronomi, biyomedikal, sağlık, eğitim, fizik, yazılım geliştirme, güvenlik sistemleri, finansal analiz gibi birçok alanda uygulanmaktadır. Uygulama alanlarına göre başarı durumu değişiklik göstermektedir.

3.4.2. RO Algoritma Yapısı

RO modelinin kullanıcı tarafından belirlenen temel iki parametresi bulunmaktadır. Bunlar orman için oluşturulacak ağaç sayısı (N) ve her düğüm ayrımında rastgele seçilecek olan tahminci sayısı (m)'dir. m tahminci sayısının toplam tahminci sayısından düşük olması gerekmektedir. Ağaçlar oluşturulurken, veri setine tahminciler eklenerek veri sayısı kadar örneklem oluşturularak bu örneklemelerin $2/3$ 'ü ağacı oluşturmak için kullanılan eğitim veri seti ve geriye kalan $1/3$ 'ü ise kurulan modeli test etmek için test veri setini oluşturacak şekilde ayrılmaktadır. RO algoritması aşağıda adım adım anlatılmaktadır:

- Öncelikle orjinal veri setine tahminciler eklenerek eğitim ve test veri setleri oluşturulmaktadır.
- Eğitim veri setinden en büyük genişlikte bir karar ağacı oluşturulur. Bu ağaç oluşturulurken her düğümün bölünmesinde m tahminci rastgele seçilmektedir.
- Eğitim ve test veri setlerindeki sınıfların homojenlik durumunu belirlemek amacı ile Gini indeksi, entropi, yanlış sınıflandırma hatası ve kazanç oranı kriterlerinden biri kullanılmaktadır. RO algoritmasında homojenlik durumunda Denklem (3.47)'de verilen Gini indeksi hesaplanmaktadır. Gini indeksinin değeri düştükçe sınıfların homojenlik durumu artmaktadır.

$$Gini = \sum_{i=1}^N \sum_{j=1}^N \left(\frac{f(C_j, T)}{|T|} \right)^2 \quad (3.47)$$

Burada T , eğitim veri setini; C_i , rastgele seçilen örneğin sınıfını; f , seçilen örneğin C_i sınıfına ait olma olasılığını vermektedir. Bir alt düğümün Gini indeksinin bir üst düğümün Gini indeksinden düşük olması o dalın başarılı olduğunu göstermektedir. Seçilen m değeri ile yeni oluşturulacak dal kalmayınca kadar hesaplanan Gini indeksine göre her düğüm için dallanma gerçekleştirilmektedir.

- Her yaprak düğüme bir sınıf atanarak ağaç yapısı veri seti ile test edilir. Test işlemi sonrası oluşan sınıflar kaydedilmektedir.
- Bu işlemler ormandaki tüm ağaçlar için tekrar edilmektedir.
- Kullanılmayan gözlemler ile bir değerlendirme yapılarak kullanılan gözlemlerin hangi kategorilerde kaç defa sınıflandırıldığı sayılır.
- Çıkan sonuçlar eğitim veri setindeki sınıflandırmalar ile karşılaştırılarak en uygun sınıflandırma yapılmaktadır.
- Her gözlem için ağaç setleri üzerinden belirlenen bir oy çoğunluğu ile sınıf ataması yapılmaktadır.

3.4.3. RO Modelinden Elde Edilen Çıkarımlar

RO modeli ile yapılan uygulamalardan bu modelin kullanımı ile 3 farklı parametre elde edilmektedir. Bu parametreler genelleme hatası, parametre ayarlama ve değişken önemidir.

3.4.3.1. Genelleme Hatası

Veri setinden rastgele gözlem seçildiğinden dolayı bazı gözlemler ağaç oluşturma sürecinde işleme alınmamaktadır. İşleme alınmayan bu gözlemler ile genelleme hatası tahmini yapılmaktadır. Genelleme hatası tahmini ile doğruluk analizi yapılabilmektedir. İşleme alınan her rastgele gözlemde aynı tipte olan gözlemlerin tüm gözlem sayısına oranı doğruluk oranını vermektedir.

3.4.3.2. Parametre Ayarlama

Düğümelerde kullanılan tahminci sayısı (m) belirlenirken ilk aşamada rastgele bir değer seçilmektedir. Daha sonra m 'ler hatalara göre değiştirilebilmektedir. Yapılan denemeler sonucu en uygun m değeri seçilmektedir. M adet değişken sayısının kareköküne sahip olarak alınan m değeri genel olarak en uygun m değerini temsil etmektedir (Breiman ve ark., 2002).

Orman oluşturulurken ağaç sayısı için bir değer bulunmamaktadır. Mümkün olan en fazla sayıda ağaç oluşturulabilmektedir.

3.4.3.3. Değişken Önemi

Değişken önemi, kullanılan değişkenlerin ne kadar önemli olduğunun ölçülmesi olarak tanımlanmaktadır. Bu ölçüm değişkenlerin yerleri değiştirilerek yapılabilmektedir. Değişimler sonucunda hesaplanan hata artışı, hata oranı, hata oranının artışı ve Gini düşüşü değişken ölçümlerinde değişkenin önem derecesini belirlerken kullanılmaktadır.

3.4.4. Avantaj ve Dezavantajları

RO algoritması ile oluşturulan modellerin birçok avantajı bulunmaktadır. Bu avantajlar;

- RO algoritmasının hem sınıflandırma hem de regresyon problemlerinde kullanılabilir olması büyük kazanç sağlamaktadır. Bu avantajı ile geniş bir uygulama alanına sahiptir.
- Karar ağacı uygulamalarında çok karşılaşılan aşırı uyum probleminin ortaya çıkma ihtimalini azaltmaktadır. Bunun sebebi eğitim için farklı veri setlerinin oluşturulmasıdır.
- Diğer makine öğrenmesi algoritmalarına göre RO algoritması daha kısa sürede çok daha iyi sonuçlar vermektedir.
- Çok sayıda sınıf etiketi ve değişkene sahip veri setlerinde kayıp veri veya düzensiz dağılım olsa bile RO algoritması ile sonuç üretilebilmektedir. RO algoritması, kendi içinde oluşturduğu bir algoritma ile kayıp verilerin veri setinde kalmasına imkan vermektedir. Bu algoritma ile öncelikle kayıp veri tespiti yapılmaktadır.

Kayıp verinin ait olduğu değişkenin sürekliliği incelenerek veriye atama yapılmaktadır. Değişken sürekli ise, bu değişkene ait eksiksiz verilerin medyan değeri kayıp veriye atanmaktadır. Değişken ayrık ise eldeki verilerden en yüksek kullanım oranına sahip olan gruba veri atanmaktadır.

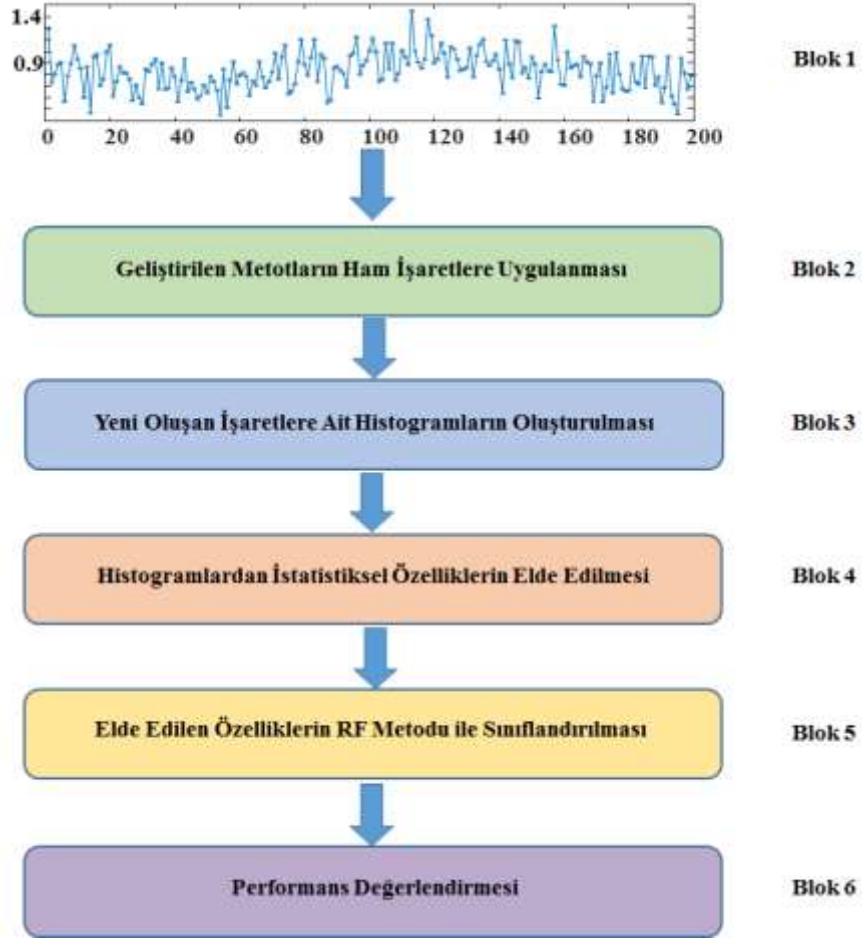
- Her bir özelliğin tahmin üzerindeki önemini ölçmeye imkân vermektedir. Bu da performansı yüksek özniteliklerin ayrıştırılmasına imkân sunmaktadır.
- Uygulama sürecinde birden fazla eğitim alt setleri oluşturduğu için sonuç alma ihtimalini azaltmaktadır.
- Kısa süre içinde mükemmel sonuçlar vermektedir.
- Her düğümde rastgele tahminciler ile dallanma gerçekleştiği için oluşan ağaçlar birbirinden bağımsız olmaktadır.

RO algoritması ile modellenen yapıların sahip oldukları çokça avantajın yanında az da olsa kısıtlamaları bulunmaktadır. Bu kısıtlamalar:

- Karar ağaçlarına göre daha karmaşık ve daha hesaplamalı bir yapıya sahiptir,
- Elde edilen sonuç için bir güven aralığı vermemektedir şeklinde sıralanabilir.

3.5. Önerilen Sistem

Tez çalışması kapsamında kullanılan veri setindeki hareketlerin sınıflandırılması için yeni yaklaşımlar önerilmiştir. Önerilen yaklaşımların uygulanmasına ait blok diyagramı Şekil 3.62'de verilmektedir.



Şekil 3.62. Önerilen metotların uygulanmasına ait blok diyagramı

Her blokta gerçekleştirilen işlemler aşağıda verilmiştir.

Blok 1: Bu aşamada çalışma sürecinde kullanılmak üzere gerekli olan veri setinin temini ve karmaşık halde bulunan veri setinin analizi yapılmaktadır. UCI kütüphanesinde yer alan MHealth isimli veri seti alınarak ham sensör işaret değerleri kullanılmaktadır.

Blok 2: Bu aşamada ham sensör işaretlerine 1B-YİÖ, OT-1B-YİÖ, MT-1B-YİÖ, ÇÖ-1B-YİÖ, A-1B-YİÖ, KT-1B-YİÖ, K-1B-YİÖ, ÜD-1B-YİÖ ve İ-1B-YİÖ metotları uygulanmaktadır. Metotların uygulanması ile farklı işaretler elde edilmektedir. Bu işaretler kullanılan metot ismi ile isimlendirilmektedir. Elde edilen işaretler incelendiğinde orijinal işaretlere göre daha anlamlı bir duruş sergiledikleri gözlemlenmektedir. Çünkü karışık ve uç değerlere sahip olan orijinal işaretler belirli bir değerin arasına indirgenerek hareket ayrıştırma daha belirgin bir hale gelmektedir.

Blok 3: Bu aşamada, önerilen metotlardan her birine ait her bir ilgili işaret grubundaki işaretlerin kullanım sıklığını gösteren histogramlar oluşturulmaktadır.

Histogramların her bir değeri öznitelik olarak değerlendirilmektedir. Sınıflandırma işlemleri için histogramlardan 2^P kadar örüntü grubu elde edilmektedir.

Blok 4: Bu aşamada, önerilen metotlar ile oluşturulan histogramlardan çıkarılan özniteliklerin sınıflandırma işleminde ayırt edilebilirliğe yüksek katkısı olduğu düşünülen çeşitli istatistiksel öznitelikler kullanılmaktadır. Kullanılan öznitelikler sınıflandırmanın kalitesini artırarak doğruluğu yüksek sonuçlar alınmasını sağlamaktadır. Sınıflandırma sürecinin doğru sonuçlar alınarak hızlandırılması açısından öznitelik seçiminin doğru yapılması gerekmektedir.

Blok 5: Bu aşamada, kullanılan veri setinde bulunan hareketlerin sınıflandırılması gerçekleşmektedir. Hareketlerin sınıflandırılması gerçekleşirken öncelikle 1B-YİÖ metoduna farklı makine öğrenmesi teknikleri uygulanarak sonuçlar gözlemlenmektedir. 1B-YİÖ metoduna göre yapılan sınıflandırmada en başarılı bulunan makine öğrenmesi tekniği kullanılarak, 10 katlı çapraz geçerlilik testine göre, geliştirilen öznitelik çıkarım yöntemlerinin tamamına uygulanmaktadır.

Blok 6: RO sınıflandırma metodu ile en başarılı sınıflandırmayı gerçekleştiren hareket türü, en kötü sınıflandırmayı gerçekleştiren hareket türü, en başarılı ve en başarısız sonuçları veren sensör türü, en başarılı ve en başarısız sınıflandırmayı veren eksen türü, en iyi ve en kötü sonucu veren istatistiksel öznitelik türü incelenerek sonuçlar verilmektedir.

3.6. Performans Ölçütleri

Önerilen metotların değerlendirilmesi aşamasında kullanılan performans ölçütleri doğruluk oranı, hata oranı, kesinlik, duyarlılık ve F-ölçütüdür. Başarı doğru sınıflandırılan örnek sayıları ve yanlış sınıflandırılan örnek sayıları göz önünde bulundurularak ölçülmektedir. Sınıflandırma sonucunda ulaşılan sonuçların bilgileri karışıklık matrisi ile ifade edilmektedir. Karışıklık matrisinde satırlar test kümesindeki örneklere ait gerçek sınıfları, kolonlar ise modelin tahminlemesi sonucunda bulunan sınıfları ifade etmektedir.

3.6.1. Doğruluk Oranı

Doğruluk oranı, önerilen metodun başarısının ölçülmesinde kullanılmaktadır. Doğru sınıflandırılmış örnek sayısının, toplam örnek sayısına oranıdır. Denklem (3.48) kullanılarak doğruluk oranı hesaplanmaktadır.

$$\text{Doğruluk oranı} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.48)$$

Burada TP , doğru pozitif sayısını; TN , doğru negatif sayısını; FP , yanlış pozitif sayısını; FN yanlış negatif sayısını göstermektedir.

3.6.2. Hata Oranı

Hata oranı, önerilen metodun başarısızlığının ölçülmesinde kullanılmaktadır. Yanlış sınıflandırılmış örnek sayısının, toplam örnek sayısına oranıdır. Denklem (3.49) kullanılarak doğruluk oranı hesaplanmaktadır.

$$\text{Hata oranı} = \frac{FP + FN}{TP + TN + FP + FN} \quad (3.49)$$

Burada TP , doğru pozitif sayısını; TN , doğru negatif sayısını; FP , yanlış pozitif sayısını; FN yanlış negatif sayısını göstermektedir.

3.6.3. Kesinlik

Kesinlik, doğru pozitif sınıflandırılmış örnek sayısının toplam pozitif sınıflandırılmış örnek sayısına oranını vermektedir. Kesinlik değeri Denklem (3.50) kullanılarak hesaplanmaktadır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.50)$$

Burada TP , doğru pozitif sayısını; FP , yanlış pozitif sayısını göstermektedir.

3.6.4. Duyarlılık

Duyarlilik, dogru sınıflandırılmış pozitif örnek sayısının gerçekten pozitif olan örnek sayısına oranını vermektedir. Denklem (3.51) kullanılarak duyarlilik hesaplanmaktadır.

$$Duyarlilik = \frac{TP}{TP + FN} \quad (3.51)$$

Burada TP , dogru pozitif sayısını; FN , yanlış negatif sayısını göstermektedir.

3.6.5. F ölçütü

F ölçütü, kesinlik ve duyarlilik ölçütleri kullanılarak yapılan bir hesaplama ölçütüdür. Sistemin kesinlik veya duyarlilik yönüne dogru optimize edilmesinde kullanılmaktadır. Denklem (3.52) kullanılarak F ölçütü hesaplanmaktadır.

$$F \text{ ölçütü} = \frac{2 * R * P}{R + P} \quad (3.52)$$

Burada R duyarlilik, P kesinlik ifade etmektedir.

4. BULGULAR ve TARTIŞMA

4.1. Başarı Oranları

Tez çalışması kapsamında kullanılan veri setindeki hareket işaretlerine geliştirilen öznelik çıkarım yöntemleri uygulanarak sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma işlemleri için açık kaynak bir yazılım olan Waikato Environment for Knowledge Analysis (WEKA) kullanılmıştır. Sınıflandırma işlemleri her yöntem için 10-katlı çapraz geçerlilik testine göre yapılmıştır. İlk olarak 1B-YİÖ metodunun MHealth veri setine uygulanması ile elde edilen öznelikler kullanılarak Bayes Net (BN), Naive Bayes (NB), Iterative Classifier Optimizer (ICO), Logit Boost (LB), Sequential Minimal Optimisation (SMO), Random Committee (RC), Random Sub Space (RSS), Simple Logistic (SL), Hoeffding Tree (HT), Logistic Model Tree (LMT) ve Rastgele Orman (RO) metotları ile sınıflandırma işlemi gerçekleştirilmiştir. Bunun amacı elde edilen özneliklerin farklı makine öğrenmesi algoritmaları ile sonuçlarının gözlenmesidir. Farklı makine öğrenmesi yöntemler ile gözlenen sonuçlar Tablo 4.1’de verilmiştir.

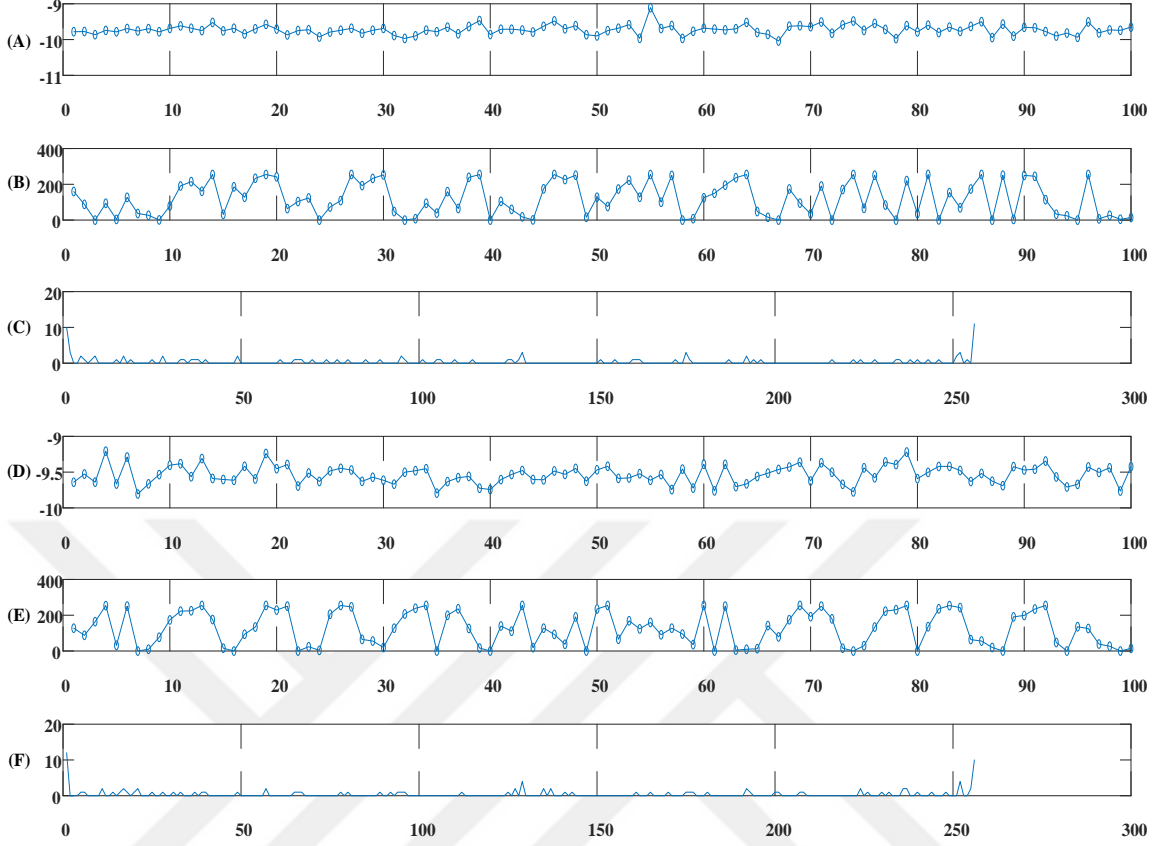
Tablo 4.1. 1B-YİÖ Yöntemine göre hareket tanıma başarı oranları (%)

İşaret	BN	NB	ICO	LB	SMO	RC	RSS	HT	LMT	RO
1B-YİÖ	90,00	82,50	87,50	86,66	81,66	82,50	85,83	83,33	83,33	91,66

Tablo 4.1’e bakılarak en yüksek başarı oranının RO sınıflandırma metodu ile gerçekleştiği gözlenmiştir. Bu tez çalışmasında bu aşamadan sonra geliştirilen öznelik çıkarım yöntemlerinden elde edilen özneliklere RO sınıflandırma metodu uygulanarak sonuçlar incelenmiştir.

4.1.1. 1B-YİÖ Metodunun Uygulanması

Bu bölümde 1B-YİÖ metodunun MHealth veri setine uygulanması ile elde edilen sonuçlar incelenmiştir. Şekil 4.1’de L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler, bu işaretlere 1B-YİÖ yönteminin uygulanması ile elde edilen işaretler ve işaretlere ait histogramlar verilmiştir.



Şekil 4.1. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait 1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketi işaretine ait 1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram

Şekil 4.1’de iki hareketin histogramlarının birbirinden ayrıştığı görülmektedir. Böylece 1B-YİÖ yöntemi işaret üzerinde gerçekleştirdiği dönüşüm ile işaretlerin birbirinden ayrıştırılması işlemini kolaylaştırdığı görülmektedir. Öncelikle 1B-YİÖ yöntemi tüm hareketlere ait işaretlere uygulandıktan sonra yeni oluşan işaretlerden istatistiksel öznelilikler elde edilmiştir. Daha sonra bu öznelilikler kullanılarak RO sınıflandırma metodu ile HT gerçekleştirilmiştir. 1B-YİÖ+RO ile elde edilen karışıklık matrisi Tablo 4.2’de, performans ölçütleri ise Tablo 4.3’te verilmiştir. Karışıklık matrisi hareketler arasında kaymaların tespiti için kullanılmıştır.

Tablo 4.2. 1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	0	1	0	0	0	0	0	0	0	0	0
L2	2	5	3	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	10	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.3. 1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP Rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,500	0,018	0,714	0,500	0,588
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,917	0,008	0,918	0,917	0,914

Tablo 4.2 ve Tablo 4.3'e göre 1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için doğru pozitif oranlarının 1,000 olarak hesaplanması ile %100 başarı oranında bir sınıflandırma gerçekleşmiştir. Sınıflandırmada en düşük başarı oranının %50 oranı ile L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir. L2 (oturma ve rahatlama) hareketi daha çok L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir.

4.1.2. OT-1B-YİÖ Metodunun Uygulanması

Tez çalışması sürecinde kullanılan veri setindeki L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareket işaretlerine OT-1B-YİÖ metodu uygulanarak elde edilen işaretler ve bu işaretlere ait histogramlar Şekil 4.2'de verilmiştir.



Şekil 4.2. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait OT-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait OT-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram

Şekil 4.2’de verildiği gibi orjinal işarete OT-1B-YİÖ metodunun uygulanması elde edilen yeni işaretin örneklerinin ayırt edilebilirliğinin daha yüksek olduğu görülmektedir. Şekil 4.1 (C) ve Şekil 4.2 (C) karşılaştırıldığında L1 (hareketsiz durma) hareketine ait histogram grafiklerinin birbirlerinden farklı oldukları ve Şekil 4.2 (C) deki grafiğin sınıflandırma işleminde daha büyük başarı oranı sağlayacağı görülmektedir. Şekil 4.2 (C) ve (F) de verilen histogramların farklı olması sınıflandırma işleminde bu iki hareketin bir birinden ayırt edilmesini kolaylaştıracaktır. OT-1B-YİÖ+RO ile gözlenen başarı oranları Tablo 4.4 ve Tablo 4.5’te verilmiştir.

Tablo 4.4. OT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	2	6	2	0	0	0	0	0	0	0	0	0
L3	0	3	7	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	10	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.5. OT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TPRate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,600	0,027	0,667	0,600	0,632
L3	0,700	0,018	0,778	0,700	0,737
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,925	0,007	0,925	0,925	0,923

Çalışmada kullanılan veri setine OT-1B-YİÖ metodu uygulanarak elde edilen özniteliklere RO sınıflandırma metoduna göre sınıflandırma yapılarak başarının %92,50 olduğu gözlenmiştir. Tablo 4.4. ve Tablo 4.5'e göre OT-1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L1 (hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için doğru pozitif oranlarının 1,000 olarak hesaplanması ile %100 başarı oranında bir sınıflandırma gerçekleşmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir. L2 (oturma ve rahatlama) hareketi daha çok L3 (uzanma) hareketine benzetilmiştir. Benzer sonuçlar 1B-YİÖ+RO ile elde edilmiştir. Bu iki hareketin kişilerin dinlenme durumlarını ifade ettiği anlaşılmaktadır.

4.1.3. MT-1B-YİÖ Metodunun Uygulanması

Veri setinden alınan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) örnek hareket işaretlerine MT-1B-YİÖ metodu uygulanarak elde edilen işaretler ve bu işaretlere ait histogramlar Şekil 4.3'te verilmiştir.



Şekil 4.3. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait MT-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketi işaretine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait MT-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketi işaretine ait histogram

Şekil 4.3 (B)'ye bakıldığında L1 (hareketsiz durma) hareketine ait MT-1B-YİÖ metodunun uygulanması ile elde edilen işaretin Şekil 4.3 (A)'da verilen orjinal işarete göre örneklerin ayırt edilebilir olduğu görülmektedir. Şekil 4.3 (C) ve (F) histogramlarının Şekil 4.2 (C) ve (F) histogramlarına oranla sınıflandırmada daha az bilgi verdiği gözlenmiştir. MT-1B-YİÖ+RO ile elde edilen başarı oranları Tablo 4.6 ve Tablo 4.7'de verilmiştir.

Tablo 4.6. MT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	2	4	4	0	0	0	0	0	0	0	0	0
L3	2	3	5	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	10	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.7. MT-1B-YİÖ yöntemine göre RO sınıflandırma metodu için performans sonuçları

Sınıflar	Doğru pozitif oranı (TPRate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,036	0,692	0,900	0,783
L2	0,400	0,036	0,500	0,400	0,444
L3	0,500	0,036	0,556	0,500	0,526
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,892	0,010	0,828	0,892	0,888

MT-1B-YİÖ metodu kullanılarak veri setinden elde edilen özelliklerin RO sınıflandırma algoritmasına göre %89,16 başarı oranında bir sınıflandırma gerçekleştirdiği gözlenmiştir. Tablo 4.6. ve Tablo 4.7 incelendiğinde MT-1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği gözlenmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) ve L3 (uzanma) hareketlerinde gerçekleştiği gözlenmiştir. L2 hareketi için %40, L3 hareketi için %50 başarı oranı gözlenmiştir. L2 (oturma ve rahatlama) hareketi daha çok L3 (uzanma) hareketine benzetildiği için düşük başarı elde edilmiştir.

4.1.4. ÇÖ-1B-YİÖ Metodunun Uygulanması

Geliştirilen bir diğer yöntem olan ÇÖ-1B-YİÖ metodu kullanılarak kullanıcı tarafından belirlenen komşuluk değeri sırasıyla 8, 10 ve 12 seçilerek elde edilen işaretler ve bu işaretlere ait histogramlar Şekil 4.4'te verilmiştir.



Şekil 4.4. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve ÇÖ-1B-YİÖ metodunun uygulanması (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait P=8 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (C) P=8 alınarak L1 (hareketsiz durma) hareketine ait histogram, (D) L1 (hareketsiz durma) hareketine ait P=10 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (E) P=10 alınarak L1 (hareketsiz durma) hareketi işaretine ait histogram, (F) L1 (hareketsiz durma) hareketine ait P=12 alınarak ÇÖ-1B-YİÖ metodu uygulanmış işaret, (G) P=12 alınarak L1 (hareketsiz durma) hareketi işaretine ait histogram

Şekil 4.4'te L1 (hareketsiz durma) hareketine ait orijinal işaret ve farklı komşuluk değerlerine göre ÇÖ-1B-YİÖ metodu uygulanmış işaretler bulunmaktadır. $P=12$ değeri için örneklerin orijinal işarete göre daha ayırt edilebilir olduğu görülmektedir. P parametresinin değeri arttığında yeni oluşan işaretlerin histogramları genişlemektedir. Diğer bir deyişle örüntü sayısı artmaktadır. Bu da sınıflandırma metodu için daha ayırt

edici özniteliklerin elde edilmesini sağlamaktadır. P 'nin küçük değerleri için histogram dikleşmektedir. Böylece daha az ancak büyük değerli özniteliklerin elde edilmesini sağlamaktadır.

ÇÖ-1B-YİÖ metodu kullanılarak komşuluk değer sırasıyla 8, 10 ve 12 seçilerek MHealth veri setinden elde edilen özniteliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile gerçekleşen başarı oranları Tablo 4.8'de gözlenmiştir.

Tablo 4.8. Farklı komşuluk değerlerine göre ÇÖ-1B-YİÖ metodu ile elde edilen başarı oranları

Komşuluk Değer(P)	$P=8$	$P=10$	$P=12$
Başarı Oranı(%)	91,66	91,66	92,50

Tablo 4.8'e bakılarak en yüksek başarı oranının ÇÖ-1B-YİÖ yöntemine göre komşuluk değerinin 12 olarak seçilmesi ile elde edilen özniteliklerin sınıflandırılmasında %92,50 başarı ile gerçekleştiği gözlenmiştir. $P=12$ alındığında ÇÖ-1B-YİÖ+RO ile elde edilen karışıklık matrisi Tablo 4.9'da ve performans ölçütleri Tablo 4.10'da verilmiştir.

Tablo 4.9. ÇÖ-1B-YİÖ yöntemine göre $P=12$ için RO sınıflandırma metodu karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	1	6	3	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	9	0	0	1	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	1	9	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.10. ÇÖ-1B-YİÖ yöntemine göre $P=12$ için RO sınıflandırma metodu performans sonuçları

Sınıflar	Doğru pozitif oranı (TPRate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,009	0,909	1,000	0,952
L2	0,600	0,018	0,750	0,600	0,667
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,000	1,000	1,000	1,000
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,009	0,909	1,000	0,952
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,009	0,900	0,900	0,900
L11	0,900	0,009	0,900	0,900	0,900
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,925	0,007	0,925	0,925	0,923

Tablo 4.9 ve Tablo 4.10 incelendiğinde L1 (hareketsiz durma), L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği gözlenmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir. L2 (oturma ve rahatlama) hareketi sınıflandırma işleminde daha çok L3 (uzanma) hareketine benzetilmiştir. L2 hareketi için %60, L3 hareketi için ise %80 başarı oranı gözlenmiştir.

4.1.5. A-1B-YİÖ Metodunun Uygulanması

Çalışmada kullanılan veri setine ait L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine A-1B-YİÖ metodu uygulanarak elde edilen örnek işaretler ve bu işaretlere ait histogramlar Şekil 4.5'te verilmiştir.



Şekil 4.5. Çalışmada kullanılan L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) hareketlerine ait örnek işaretler (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) L1 (hareketsiz durma) hareketine ait A-1B-YİÖ metodu uygulanmış işaret, (C) L1 (hareketsiz durma) hareketine ait histogram, (D) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (E) L2 (oturma ve rahatlama) hareketine ait A-1B-YİÖ metodu uygulanmış işaret, (F) L2 (oturma ve rahatlama) hareketine ait histogram

Şekil 4.5'e bakıldığında L1 (hareketsiz durma) hareketine ait orijinal işaret ve A-1B-YİÖ metodunun uygulanması ile oluşan işaretin birbirinden büyük oranda farklı olduğu görülmektedir. Aynı şekilde L2 (oturma ve rahatlama) hareketine ait orijinal işaret ile A-1B-YİÖ metodunun uygulanması ile oluşan işaretin küçük oranda da olsa birbirinden farklı oldukları görülmektedir. A-1B-YİÖ ile elde edilen özneliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.11'de ve performans ölçütleri Tablo 4.12'de verilmiştir.

Tablo 4.11. A-1B-YİÖ yöntemine göre RO sınıflandırma metodu karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	1	6	3	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	10	0	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.12. A-1B-YİÖ yöntemine göre RO sınıflandırma metodu performans sonuçları

Sınıflar	Doğru pozitif oranı(TPRate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,009	0,900	0,900	0,900
L2	0,600	0,027	0,667	0,600	0,632
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,018	0,833	1,000	0,909
L11	0,800	0,000	1,000	0,800	0,889
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,925	0,007	0,927	0,925	0,924


A-1B-YİÖ metodu uygulanarak elde edilen özneliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile %92,50 başarı oranı gerçekleştiği gözlenmiştir. A-1B-YİÖ metodunun uygulanmasına ait Tablo 4.11 ve Tablo 4.12 incelendiğinde RO sınıflandırma metoduna göre L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L10 (tempolu yürüyüş yapma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği görülmektedir. Sınıflandırmada en düşük başarı oranının L1 (Hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmesi ile elde edilen L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir. En düşük sınıflandırmayı gerçekleştiren L2 (oturma ve rahatlama) hareketinin başarısı %60 olarak bulunmuştur.

4.1.6. KT-1B-YİÖ Metodunun Uygulanması

Çalışma kapsamında geliştirilen yöntemlerden biri olan KT-1B-YİÖ metodunun farklı α ve β değerleri için veri setine uygulanması ile elde edilen işaretler ve bu işaretlere ait histogramlar Şekil 4.6 ve Şekil 4.7’de verilmiştir. Kullanıcı tarafından tanımlanan α ve β parametrelerinin farklı değerlerine göre farklı örüntüler elde edilmektedir.



Şekil 4.6. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve farklı α ve β değerleri kullanılarak KT-1B-YİÖ metodunun uygulanması (A) L1(hareketsiz durma) hareketine ait örnek işaret, (B) $\alpha=1$; $\beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (C) $\alpha=1$; $\beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (D) $\alpha=1$; $\beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (E) $\alpha=2$; $\beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (F) $\alpha=2$; $\beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (G) $\alpha=2$; $\beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (H) $\alpha=3$; $\beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (I) $\alpha=3$; $\beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaret, (J) $\alpha=3$; $\beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaret



Şekil 4.7. (A) $\alpha=1; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (B) $\alpha=1; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (C) $\alpha=1; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (D) $\alpha=2; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (E) $\alpha=2; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (F) $\alpha=2; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (G) $\alpha=3; \beta=1$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı, (H) $\alpha=3; \beta=2$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı (I) $\alpha=3; \beta=3$ alınarak KT-1B-YİÖ metodu uygulanmış işaretin histogramı

L1 (hareketsiz durma) hareketine ait orijinal işarete farklı α ve β değerleri kullanılarak KT-1B-YİÖ metodunun uygulanması ile oluşan yeni işaretlerin bir birinden farklı oldukları Şekil 4.6'da görülmektedir. Şekil 4.7'ye bakıldığında histogramların küçük farklılıklar gösterdikleri gözlenmiştir. Ancak farklı parametre değerleri ile farklı öznelilikler gözlemlendiği anlaşılmaktadır. KT-1B-YİÖ metodu kullanılarak farklı α ve β değerleri için veri setinden elde edilen özneliliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile gerçekleşen başarı oranları Tablo 4.13'de verilmiştir.

Tablo 4.13. Farklı α ve β değerleri için KT-1B-YİÖ yöntemine göre elde edilen başarı oranları

$\alpha; \beta$	1	2	3
1	92,50	86,67	90,00
2	93,33	90,83	89,16
3	91,66	90,83	90,83

Tablo 4.13 incelendiğinde en yüksek başarı oranının $\alpha=2$ ve $\beta=1$ alınarak KT-1B-YİÖ yöntemine göre elde edilen özneliliklerin sınıflandırılmasında %93,33 başarı ile gerçekleştiği gözlenmiştir. Çalışma sürecinde kullanılan veri seti üzerinde α ve β parametrelerinin sınıflandırma başarısı üzerinde anlamlı bir etkilerinin olmadığı gözlenmiştir. Veri setine bağlı olarak en uygun α ve β parametrelerinin seçilmesi denemeler sonucunda gerçekleşmektedir. $\alpha=2$ ve $\beta=1$ olması durumunda KT-1B-YİÖ+RO ile gözlenen karışıklık matrisi Tablo 4.14'te ve performans ölçütleri Tablo 4.15'te verilmiştir.

Tablo 4.14. $\alpha=2$ ve $\beta=1$ alınarak KT-1B-YİÖ yöntemine göre RO sınıflandırma metodu karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	1	7	2	0	0	0	0	0	0	0	0	0
L3	0	0	10	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	9	0	1	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	2	0	7	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	10	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.15. $\alpha=2$ ve $\beta=1$ alınarak KT-1B-YİÖ yöntemine göre RO sınıflandırmada performans sonuçları

Sınıflar	Doğru pozitif oranı(TPRate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,009	0,909	1,000	0,952
L2	0,700	0,000	1,000	0,700	0,824
L3	1,000	0,018	0,833	1,000	0,909
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	0,900	0,018	0,818	0,900	0,857
L7	1,000	0,000	1,000	1,000	1,000
L8	0,700	0,009	0,875	0,700	0,778
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,933	0,006	0,938	0,933	0,931


Tablo 4.14 ve Tablo 4.15 incelendiğinde L1 (hareketsiz durma), L3 (uzanma), L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği gözlenmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) ve L8 (çömelme) hareketlerinde gerçekleştiği gözlenmiştir. Bu hareketler için başarı oranı %70 olarak elde edilmiştir.

4.1.7. K-1B-YİÖ Metodunun Uygulanması

Merkez değerın kaydırılması ile oluşturulan K-1B-YİÖ metodunun farklı PL ve PR değerleri alınarak veri setine uygulanması ile elde edilen işaretler ve bu işaretlere ait histogramlar Şekil 4.8 ve Şekil 4.9’da verilmiştir. PL işaret üzerinde ele alınan noktanın solundan, PR ise sağından alınan komşu değer sayısını ifade etmektedir.



Şekil 4.8. Çalışmada kullanılan L1(hareketsiz durma) hareketine ait örnek işaret ve farklı PL değerleri kullanılarak K-1B-YİÖ metodunun uygulanması (A) L1(hareketsiz durma) hareketine ait örnek işaret, (B) $PL=0$; $PR=8$ değerleri örneği, (C) $PL=1$; $PR=7$ değerleri örneği, (D) $PL=2$; $PR=6$ değerleri örneği, (E) $PL=3$; $PR=5$ değerleri örneği, (F) $PL=4$; $PR=4$ değerleri örneği, (G) $PL=5$; $PR=3$ değerleri örneği, (H) $PL=6$; $PR=2$ değerleri örneği, (I) $PL=7$; $PR=1$ değerleri örneği, (J) $PL=8$; $PR=0$ değerleri örneği



Şekil 4.9. (A) $PL=0; PR=8$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (B) $PL=1; PR=7$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (C) $PL=2; PR=6$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (D) $PL=3; PR=5$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (E) $PL=4; PR=4$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (F) $PL=5; PR=3$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (G) $PL=6; PR=2$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı, (H) $PL=7; PR=1$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı (I) $PL=8; PR=0$ alınarak K-1B-YİÖ metodu uygulanmış işaretin histogramı

Şekil 4.8’de L1 (hareketsiz durma) hareketine ait orijinal işarete farklı PL değerleri kullanılarak K-1B-YİÖ metodunun uygulanması ile oluşan yeni işaretler verilmiştir. Şekil 4.8(C), (E), (F), (G) ve (H) işaretlerinin örneklerinin diğer işaretlere göre daha ayırt edilebilir olduğu görülmektedir. Şekil 4.9’da verilen histogramların birbirinden farklı oldukları gözlenmiştir.

K-1B-YİÖ metodu kullanılarak PL ve PR komşuluk değerlerinin toplamda 8 olacak şekilde sırasıyla 0-8 arasında seçilmesi ile elde edilen özelliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile gerçekleşen başarı oranları Tablo 4.16’da verilmiştir.

Tablo 4.16. Farklı *PL* ve *PR* değerleri alınarak K-1B-YİÖ yöntemine göre başarı oranları

K-1B-YİÖ	RO Başarı Oranı(%)
<i>PL=0;PR=8</i>	87,50
<i>PL=1;PR=7</i>	90,00
<i>PL=2;PR=6</i>	89,16
<i>PL=3;PR=5</i>	90,00
<i>PL=4;PR=4</i>	91,66
<i>PL=5;PR=3</i>	90,00
<i>PL=6;PR=2</i>	90,83
<i>PL=7;PR=1</i>	87,50
<i>PL=8;PR=0</i>	88,33

Tablo 4.16 incelendiğinde en yüksek başarı oranının *PL=4* ve *PR=4* olarak seçilmesi ile %91.66 oranında olduğu gözlenmektedir. Merkez değerın kaydırılması yöntemine dayanarak geliştirilen yöntemden elde edilen işaretlerin merkez değerden önce ve sonra alınan değerlere göre çalışmada kullanılan veri seti üzerinde herhangi bir kararlılık göstermediği görülmektedir.

PL=4 ve *PR=4* alındığında K-1B-YİÖ+RO ile gözlenen karışıklık matrisi Tablo 4.17’de ve performans ölçütleri Tablo 4.18’de verilmiştir.

Tablo 4.17. *PL=4* ve *PR=4* alınarak K-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	0	1	0	0	0	0	0	0	0	0	0
L2	2	5	3	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	10	0
L12	0	0	0	0	0	0	0	0	0	0	0	10


Tablo 4.18. $PL=4$ ve $PR=4$ alınarak K-1B-YİÖ yöntemine göre RO sınıflandırmada performans sonuçları

Sınıflar	Doğru pozitif oranı(TPRate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,500	0,018	0,714	0,500	0,588
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,000	1,000	0,900	0,947
L11	1,000	0,009	0,909	1,000	0,952
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,917	0,008	0,918	0,917	0,914

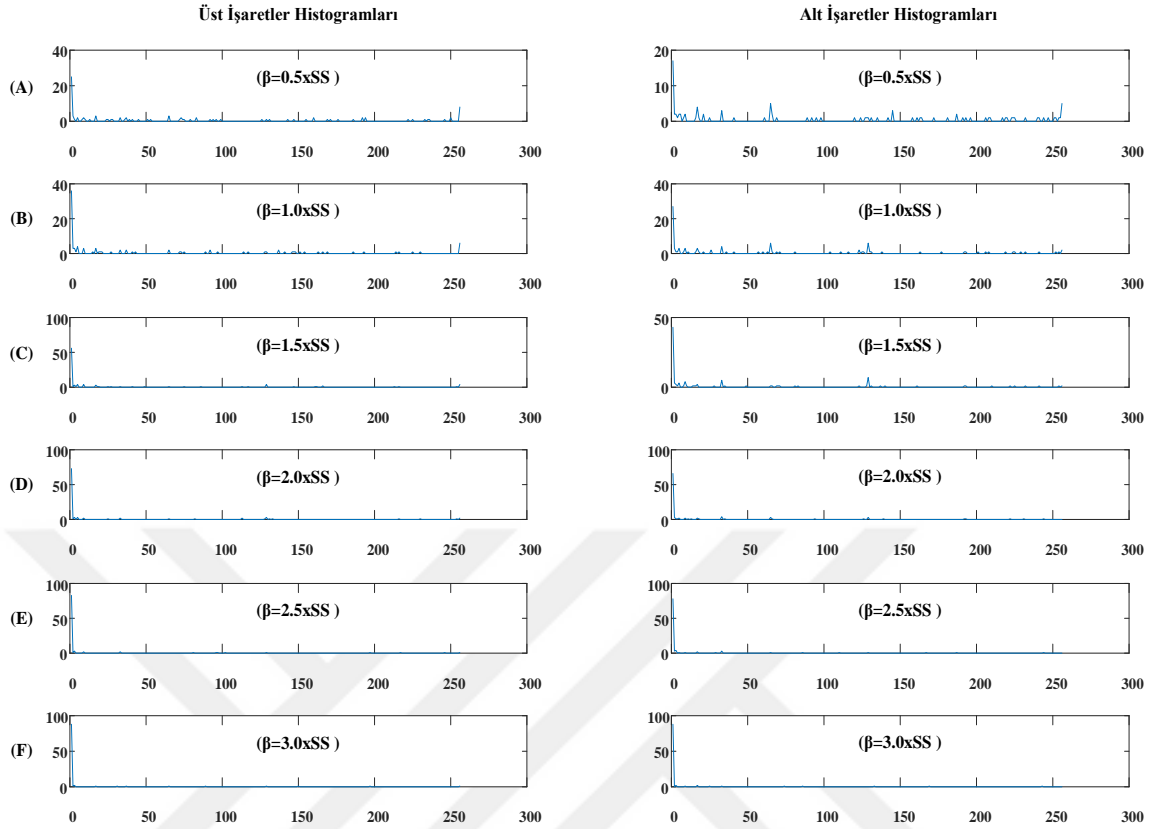
Tablo 4.17. ve Tablo 4.18'e göre K-1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleşmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir. L2 (oturma ve rahatlama) hareketi daha çok L1 (Hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. Bu hareket için %20 başarı oranı gözlenmiştir. Diğer en düşük oran L3(uzanma) hareketi için %80 olarak gözlenmiştir.

4.1.8. ÜD-1B-YİÖ Metodunun Uygulanması

Farklı β değerleri kullanılarak ÜD-1B-YİÖ metodunun veri setine uygulanması ile elde edilen alt ve üst işaretler ve bu alt ve üst işaretlere ait histogramlar Şekil 4.10 ve Şekil 4.11'de verilmiştir.



Şekil 4.10. Çalışmada kullanılan L1 (hareketsiz durma) hareketine ait örnek işaret ve farklı β değerleri kullanılarak ÜD-1B-YİÖ metodunun uygulanması (A) L1 (hareketsiz durma) hareketine ait örnek işaret, (B) $\beta=0.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (C) $\beta=1.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (D) $\beta=1.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (E) $\beta=2.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (F) $\beta=2.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler, (G) $\beta=3.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretler



Şekil 4.11. (A) $\beta=0.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (B) $\beta=1.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (C) $\beta=1.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (D) $\beta=2.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (E) $\beta=2.5xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar, (F) $\beta=3.0xSS$ alınarak ÜD-1B-YİÖ metodu uygulanmış üst ve alt işaretlere ait histogramlar

Şekil 4.10’da L1 (hareketsiz durma) hareketine ait orijinal işarete farklı β değerleri ile ÜD-1B-YİÖ metodunun uygulanması ile elde edilen üst ve alt işaretler verilmiştir. Oluşan üst ve alt işaretlerin orijinal işarete göre farklı oldukları ve Şekil 4.11’de verilen histogramlarında birbirinden farklı oldukları görülmektedir.

ÜD-1B-YİÖ metodu kullanılarak β değeri sırasıyla 0.5xSS, 1.0xSS, 1.5xSS, 2.0xSS, 2.5xSS, 3.0xSS alınarak elde edilen alt ve üst özelliklere RO sınıflandırma metodu uygulanarak Tablo 4.19’da verilen başarı oranları elde edilmiştir.

Tablo 4.19. Farklı β değeri alınarak ÜD-1B-YİÖ yöntemine göre başarı oranları

Öznitelikler	$\beta=0.5xSS$	$\beta=1xSS$	$\beta=1.5xSS$	$\beta=2xSS$	$\beta=2.5xSS$	$\beta=3xSS$
Alt Öznitelikler	87,50	87,50	88,33	86,66	86,66	85,00
Üst Öznitelikler	85,83	85,00	81,66	85,83	91,66	82,50

Tablo 4.19 incelendiğinde %91,66 değeri ile en yüksek başarımın $\beta=2.5 \times SS$ alınarak üst özellikler grubunda elde edildiği görülmektedir. Çalışmada kullanılan veri setine farklı β değerleri ile uygulanan ÜD-1B-YİÖ metodu ile oluşan hem üst işaret grubunun hem de alt işaret grubunun sınıflandırma başarısında belirli bir kararlılık göstermediği görülmektedir. $\beta=2.5 \times SS$ alınarak üst özneliklerin kullanılması ÜD-1B-YİÖ+RO ile gözlenen karışıklık matrisi Tablo 4.20’de ve performans ölçütleri Tablo 4.21’de verilmiştir.

Tablo 4.20. $\beta=2.5 \times SS$ alınarak ÜD-1B-YİÖ yöntemine göre Üst öznelik grubuna RO sınıflandırma uygulanarak elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	3	7	0	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	0	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	1	9	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.21. $\beta=2.5 \times SS$ alınarak ÜD-1B-YİÖ yöntemine göre Üst öznelik grubuna RO sınıflandırma uygulanarak elde edilen karışıklık matrisi


Sınıflar	Doğru pozitif oranı(TPRate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,027	0,750	0,900	0,818
L2	0,700	0,027	0,700	0,700	0,700
L3	0,800	0,000	1,000	0,800	0,889
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,009	0,889	0,800	0,842
L11	0,900	0,018	0,818	0,900	0,857
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,917	0,008	0,922	0,917	0,917

Tablo 4.20 ve Tablo 4.21’deki sonuçlar incelendiğinde L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketlerinde %100 başarılı sınıflandırma yapıldığı

gözlenmektedir. En başarısız sınıflandırmada L2 (oturma ve rahatlama) hareketinin sınıflandırmasında %70 olarak gerçekleşmiştir.

4.1.9. İ-1B-YİÖ Metodunun Uygulanması

Çalışmada kullanılan veri setine İ-1B-YİÖ metodu farklı parametreler kullanılarak uygulanmıştır. Şekil 4.12’de L1 (hareketsiz durma) hareketine $PB=4$ ve indirgeme özelliği ortalama seçilerek 3 seviyede gerçekleşen İ-1B-YİÖ işaretleri ve bu işaretlere ait histogramlar verilmiştir.




Şekil 4.12. Çalışmada kullanılan L1(hareketsiz durma) hareketine ait örnek işaret ve bu işarete $PB=4$ ve ortalama özelliğine göre İ-1B-YİÖ metodunun uygulanması (A) L1(hareketsiz durma) hareketine ait örnek işaret, (B) Birinci aşamada elde edilen işaret ve bu işarete ait histogram, (C) İkinci aşamada elde edilen işaret ve bu işarete ait histogram, (D) Üçüncü aşamada elde edilen işaret ve bu işarete ait histogram

Şekil 4.12’de $PB=4$ ve indirgeme özelliği ortalama alınarak İ-1B-YİÖ metodunun gerçekleştiği gözlenmiştir. Şekil 4.12(A)’da L1 (hareketsiz durma) hareketine ait orijinal işaret bulunmaktadır. (B)’deki grafikler ise bir kere İ-1B-YİÖ metodunun ortalama verileri kullanılarak uygulanması ile oluşan yeni işaret ve bu işarete ait histogramdır.

Şekil (C) ise (B)'deki işaretlere bir kez daha ortalama verileri kullanılarak İ-1B-YİÖ metodunun uygulanması sonucu oluşan işaretleri ve bu işaretlere ait histogramı göstermektedir. Şekil (C)'deki işaretlere tekrar İ-1B-YİÖ metodu ortalama verisi kullanılarak uygulandığında ise (D)'deki işaretler ve bu işaretlere ait histogram oluşmaktadır. Şekil 4.12'de de görüldüğü gibi her aşamadan sonra elde edilen işaret grubunda örneklerin sayısı azalmaktadır.

Şekil 4.13'te L2 (oturma ve rahatlama) hareketine $PB=6$ ve indirgeme özelliği en büyük seçilerek 3 aşamada gerçekleşen İ-1B-YİÖ işaretleri ve bu işaretlere ait histogramlar verilmiştir.



Şekil 4.13. Çalışmada kullanılan L2(oturma ve rahatlama) hareketine ait örnek işaret ve bu işarete $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ metodunun uygulanması (A) L2 (oturma ve rahatlama) hareketine ait örnek işaret, (B) Birinci aşamada elde edilen işaret ve bu işarete ait histogram, (C) İkinci aşamada elde edilen işaret ve bu işarete ait histogram, (D) Üçüncü aşamada elde edilen işaret ve bu işarete ait histogram

Şekil 4.12 ve Şekil 4.13 incelendiğinde İ-1B-YİÖ metodun her uygulanması sonucu yeni oluşan işaretlerin boyutunun azaldığı görülmektedir. İ-1B-YİÖ metodu her

seviyede işaretlere 1B-YİÖ metodunun uygulanmasıdır. Her seviyede 1B-YİÖ metodu uygulanarak daha fazla örüntü elde edilmiştir. Bu örüntüler işaretlerin birbirinden ayırt edilebilirliğini sağlamaktadır. İ-1B-YİÖ metodunda uygulanan seviye sayısı kullanıcıya göre değişkenlik gösterebilmektedir. İşaretin yeteri kadar uzunlukta olmaması seviye sayısı arttıkça örüntü kaybına sebep olacaktır.

İ-1B-YİÖ metodunun üç önemli parametresi bulunmaktadır. Birinci parametresi seviye sayısıdır. Şekil 4.12 ve Şekil 4.13'te uygulanan örneklerde seviye sayısının 3 olduğu görülmektedir. İkinci parametre ise PB'dir. Şekil 4.12 de $PB=4$ iken Şekil 4.13'teki örnekte $PB=6$ olarak uygulanmıştır. Son parametre ise bir pencere içerisine giren örnek değerlerin hangi hesaplama sonucu oluşan değeri bir üst seviyeye taşıyacağımız ile ilgili parametredir. Pencere içerisine giren değerlerin en küçüğü, en büyüğü, medyanları veya ortalamaları alınarak bir üst seviyeye değerler taşınmaktadır. Şekil 4.12 de bu parametre ortalama özelliği olarak seçilmişken Şekil 4.13'te ise en büyük özellik olarak seçilmiştir.

İşaretlere her seviyede 1B-YİÖ metodu uygulanarak öznitelik sayısı artırılmıştır. Hesaplama maliyeti artıyor gibi gözükse de başarı oranını etkileyecek örüntülerin sağlanması önemli bir avantajdır.

İ-1B-YİÖ metodunda pencere boyutu sırasıyla 4, 5, 6, 7 ve 8 alınarak en büyük, en küçük, ortalama ve medyan indirgeme özelliğine göre 3 seviyede elde edilen özelliklerin RO sınıflandırma metodu ile sınıflandırılmasında oluşan başarı oranları Tablo 4.22'de verilmiştir.

Tablo 4.22. Farklı parametrelere göre İ-1B-YİÖ metodu uygulaması başarı oranları (%)

PB	En Büyük	En Küçük	Ortalama	Medyan
4	90,83	88,33	91,66	90,00
5	94,16	91,66	93,33	94,16
6	95,83	87,50	91,66	89,16
7	90,00	89,16	94,16	91,66
8	91,66	92,50	93,33	90,00

Tablo 4.22 incelendiğinde en yüksek başarı oranının pencere boyutu 6 olarak seçilmesi ile en büyük değerlere göre indirgeme yapıldığında %95,83 olduğu gözlenmektedir. İ-1B-YİÖ metodu uygulanırken kullanıcı tarafından belirlenen parametrelerin değerlerinin değişiminin başarı oranı ile bir ilişkisinin olmadığı

görülmektedir. Elde edilen karışıklık matrisi ve performans ölçütleri Tablo 4.23 ve Tablo 4.24'te verilmiştir.

Tablo 4.23. $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ yöntemine göre RO sınıflandırma metodu için karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	0	8	2	0	0	0	0	0	0	0	0	0
L3	1	1	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	10	0	0
L11	0	0	0	0	0	0	0	0	0	1	9	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.24. $PB=6$ ve indirgeme özelliği en büyük alınarak İ-1B-YİÖ yöntemine göre RO sınıflandırma metodu performans sonuçları

Sınıflar	Doğru pozitif oranı (TPRate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,009	0,909	1,000	0,952
L2	0,800	0,009	0,889	0,800	0,842
L3	0,800	0,018	0,800	0,800	0,800
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,009	0,909	1,000	0,952
L11	0,900	0,000	1,000	0,900	0,947
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,958	0,004	0,959	0,958	0,958

Tablo 4.23 ve Tablo 4.24'teki sonuçlar incelendiğinde L1 (Hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L10 (tempolu yürüyüş yapma) ve L12 (öne ve arkaya zıplama) hareketlerinde %100 başarılı sınıflandırma yapıldığı gözlenmektedir. En başarısız sınıflandırma işlemi L2 (oturma ve rahatlama) ve L3 (uzanma) hareketleri için %80 olarak gerçekleşmiştir. En kötü sınıflandırmaların başarı oranları göz önünde bulundurulduğunda İ-1B-YİÖ metodunun en kötü durumda bile yüksek başarı verdiği gözlenmektedir.

4.2. Yöntemlerin Karşılaştırılması

Çalışma sürecinde geliştirilen 9 yeni öznitelik çıkarım yönteminin materyal olarak kullanılan veri setindeki hareket işaretlerine uygulanması ile elde edilen özniteliklerin RO sınıflandırması ile gerçekleşen başarı oranları Tablo 4.25'te verilmiştir.

Tablo 4.25. Geliştirilen yöntemlerin RO sınıflandırma metoduna göre karşılaştırılması

Yöntem	RO Başarı Oranı(%)	Geçen Zaman(sn)
1B-YİÖ	91,66	147.255229
OT-1B-YİÖ	92,50	245.233210
MT-1B-YİÖ	89,16	261.707642
ÇÖ-1B-YİÖ ($P=12$)	92,50	178.178795
A-1B-YİÖ	92,50	262.522884
KT-1B-YİÖ ($\alpha=2;\beta=1$)	93,33	157.323485
K-1B-YİÖ ($PL=4;PR=4$)	91,66	149.732748
İ-1B-YİÖ ($PB=6$;Özellik=EB)	95,83	171.168491
ÜD-1B-YİÖ ($\beta=2,5$;SS;Üst Özellikler)	91,66	343.818415

Tablo 4.25'te verilen yöntemlerin çalışmada kullanılan veri setine uygulanması ile elde edilen özniteliklerin RO sınıflandırma metoduna göre sınıflandırılması sonucunda en yüksek başarının İ-1B-YİÖ yönteminde gerçekleştiği görülmüştür. İ-1B-YİÖ yönteminde pencere boyutu 6 alınarak ve indirgeme özelliği en büyük olarak seçilmesi ile 3 seviyede elde edilen özniteliklerin RO sınıflandırma metoduna göre sınıflandırılması %95,83 başarı oranı sağlamıştır. En düşük başarının %89,16 oranı ile MT-1B-YİÖ'de gerçekleştiği gözlenmiştir. Genel olarak, 1B-YİÖ metoduna dayalı geliştirilen yöntemlerin başarısının 1B-YİÖ metodunun başarısından yüksek olduğu gözlenmektedir.

Ayrıca Tablo 4.25'te verildiği gibi yöntemler arasında işlem süresinin en kısa olarak 1B-YİÖ metodunun uygulanmasında gerçekleştiği gözlenmiştir. 1B-YİÖ metodu ile özniteliklerin elde edilmesinde gerçekleşen sürenin diğer metotlara göre daha kısa olması 1B-YİÖ metodunun uygulanmasının maliyet açısından daha avantajlı olduğunu göstermektedir.

Geliştirilen yöntemlerin en iyi parametreleri seçilerek uygulanmasında kullanılan veri setindeki hareket türlerine göre başarı oranlarının karşılaştırılması Tablo 4.26'da verilmiştir.

Tablo 4.26. Hareket türüne göre yöntemlerin başarı oranları (%)

Aktivite	1B-YİÖ	OT-1B-YİÖ	MT-1B-YİÖ	ÇÖ-1B-YİÖ	A-1B-YİÖ	KT-1B-YİÖ	K-1B-YİÖ	ÜD-1B-YİÖ	İ-1B-YİÖ
L1	90	100	90	100	90	100	90	90	100
L2	50	60	40	60	60	70	50	70	80
L3	80	70	50	80	80	100	80	80	80
L4	100	100	100	100	100	100	100	100	100
L5	90	100	100	90	100	100	90	100	100
L6	100	100	100	100	100	90	100	100	100
L7	100	100	100	100	100	100	100	100	100
L8	100	90	100	100	100	70	100	90	100
L9	100	100	100	100	100	100	100	100	100
L10	90	90	90	90	100	90	90	80	100
L11	100	100	100	90	80	100	100	90	90
L12	100	100	100	100	100	100	100	100	100

Tablo 4.26 incelendiğinde geliştirilen metotlardan elde edilen özneliklerin sınıflandırılması ile tüm metotlar için her denemede L4 (yürüme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri %100 başarılı bulunarak en ayırt edilebilir hareketler olarak gözlenmiştir. Bu hareketlerden sonra en yüksek başarının geliştirilen 9 metot arasında 8 metotta %100 başarı elde edilen L6 (öne eğilme) hareketinde gerçekleştiği gözlenmektedir. Sınıflandırma aşamasında en kötü performansı her denemede en başarısız sonucu veren L2 (oturma ve rahatlama) hareketi göstermiştir. L2 (oturma ve rahatlama) hareketini başarısızlık sırasında L3 (uzanma) hareketi takip etmektedir.

4.3. En İyi Yöntemin İncelenmesi

Tablo 4.25’te verildiği gibi en yüksek başarı oranı İ-1B-YİÖ yönteminde pencere boyutu 6 ve indirgeme parametresi en büyük olarak seçilmesi ile 3 seviyede elde edilmiştir. Bu bölümde çalışma sürecinde kullanılan veri setinin sensör türlerine göre, eksenlerine göre ve istatistiksel özneliklerine göre başarı oranlarının değerlendirilmesi yapılmıştır.

4.3.1. Sensör Türlerine Göre Başarı Oranları

Çalışma sürecinde kullanılan veriseti ivmeölçer (acceleration), jireskop (gyro), manyetometre (magnetometer) sensörlerinden ve EKG işaretlerinden elde edilerek oluşturulmuştur. İvmeölçer sensörleri bağlı oldukları cihaz veya kişilerin ivme

bilgisini ölçmektedir. Jireskop sensörler yön tespiti veya ölçümünde kullanılmaktadır. Manyetometreler bağlı buldukları kişi veya cihazın manyetik alan gücünün tespitini sağlamaktadır. EKG ölçümleri ise kalpte meydana gelen elektriksel faaliyetler hakkında bilgi vermektedir. En başarılı yöntemden elde edilen öznelikler kullanılan sensör türüne göre gruplandırılıp RO sınıflandırma metodu ile sınıflandırma işlemleri gerçekleştirilmiştir. Sensör türlerine göre yapılan değerlendirmeler sonucu elde edilen karışıklık matrisleri ve performans oranları Tablo 4.27–Tablo 4.34 arasındaki tablolarda verilmiştir.

Tablo 4.27. İvme sensörleri için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	7	3	0	0	0	0	0	0	0	0	0	0
L2	1	6	3	0	0	0	0	0	0	0	0	0
L3	1	1	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	10	0	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.28. İvme sensörleri için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Keskinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,700	0,018	0,778	0,700	0,737
L2	0,600	0,036	0,600	0,600	0,600
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,018	0,833	1,000	0,909
L11	0,800	0,000	1,000	0,800	0,889
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,900	0,009	0,904	0,900	0,900

Tablo 4.27 ve Tablo 4.28 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanarak ivmeölçer sensörlerinden elde edilen özneliklerin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9

(bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) aktivitesi için bulunmuştur. L2 (oturma ve rahatlama) hareketi daha çok L1 (Hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilmiştir. İvme sensörlerine göre yapılan sınıflandırma işleminde %90 başarı oranı gözlenmiştir.

Jireskop işaretlerinden elde edilen özneliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.29’da ve performans ölçütleri Tablo 4.30’da verilmiştir.

Tablo 4.29. Jireskop(Gyro) sensörleri için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	3	3	4	0	0	0	0	0	0	0	0	0
L2	3	4	3	0	0	0	0	0	0	0	0	0
L3	4	2	4	0	0	0	0	0	0	0	0	0
L4	0	0	0	9	0	0	0	0	0	1	0	0
L5	0	0	0	0	9	1	0	0	0	0	0	0
L6	0	0	0	0	0	9	0	1	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	8	1	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	6	4	0
L11	0	0	0	0	0	0	0	0	0	3	7	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.30. Jireskop(Gyro) sensörleri için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,300	0,064	0,300	0,300	0,300
L2	0,400	0,045	0,344	0,400	0,421
L3	0,400	0,064	0,364	0,400	0,381
L4	0,900	0,000	1,000	0,900	0,947
L5	0,900	0,000	1,000	0,900	0,947
L6	0,900	0,018	0,818	0,900	0,857
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,009	0,889	0,800	0,842
L9	1,000	0,009	0,909	1,000	0,952
L10	0,600	0,036	0,600	0,600	0,600
L11	0,700	0,036	0,636	0,700	0,667
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,742	0,023	0,747	0,742	0,743

Tablo 4.29 ve Tablo 4.30 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak jireskop sensörlerinden elde edilen özneliklerin sınıflandırılmasında L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L1 (Hareketsiz

durma) aktivitesi için bulunmuştur. Jireskop sensörlerine göre yapılan sınıflandırma işleminde %74,16 başarı oranı gözlenmiştir.

Manyetometre işaretlerinden elde edilen özneliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.31’de ve performans ölçütleri Tablo 4.32’de verilmiştir.

Tablo 4.31. Manyetometre (Magnetometer) sensörleri için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	0	6	4	0	0	0	0	0	0	0	0	0
L3	0	1	9	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	1	8	0	1	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	7	3	0
L11	0	0	0	0	0	0	0	0	0	4	6	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.32. Manyetometre (Magnetometer) sensörleri için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,000	1,000	1,000	1,000
L2	0,600	0,009	0,857	0,600	0,706
L3	0,900	0,036	0,692	0,900	0,783
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	0,800	0,009	0,889	0,800	0,842
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	0,700	0,036	0,636	0,700	0,667
L11	0,600	0,027	0,667	0,600	0,632
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,875	0,011	0,879	0,875	0,873

Tablo 4.31 ve Tablo 4.32 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Manyetometre sensörlerinden elde edilen özelliklerin sınıflandırılmasında L1 (hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) ve L11

(koşma) aktiviteleri için bulunmuştur. Manyetometre sensörlerine göre yapılan sınıflandırma işleminde %87,5 başarı oranı gözlenmiştir.

EKG işaretlerinden elde edilen özneliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.33’de ve performans ölçütleri Tablo 4.34’te verilmiştir.

Tablo 4.33. EKG İşaretleri için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	0	5	2	2	0	0	0	0	0	1	0	0
L2	3	3	2	2	0	0	0	0	0	0	0	0
L3	0	2	7	0	0	0	0	0	0	0	1	0
L4	1	2	0	4	1	0	0	0	2	0	0	0
L5	0	1	0	1	6	0	0	0	1	1	0	0
L6	0	0	0	2	1	1	2	3	0	0	1	0
L7	0	1	0	1	1	1	4	1	0	1	0	0
L8	0	0	0	1	2	3	2	0	0	2	0	0
L9	0	1	0	1	2	0	0	0	4	1	1	0
L10	0	0	0	0	3	0	0	0	0	2	5	0
L11	0	0	0	0	0	0	0	0	1	3	6	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.34. EKG İşaretleri için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,000	0,036	0,000	0,000	0,000
L2	0,300	0,109	0,200	0,300	0,240
L3	0,700	0,036	0,636	0,700	0,667
L4	0,400	0,091	0,286	0,400	0,333
L5	0,600	0,091	0,375	0,600	0,462
L6	0,100	0,036	0,200	0,100	0,133
L7	0,400	0,036	0,500	0,400	0,444
L8	0,000	0,036	0,000	0,000	0,000
L9	0,400	0,036	0,500	0,400	0,444
L10	0,200	0,082	0,182	0,200	0,190
L11	0,600	0,073	0,429	0,600	0,500
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,392	0,055	0,359	0,392	0,368

Tablo 4.33 ve Tablo 4.34 incelendiğinde EKG işaretlerinden elde edilen öznelikler kullanılarak sadece L12 (öne ve arkaya zıplama) hareketi için %100 başarı oranı gözlenmiştir. En düşük sınıflandırma oranı %0 oran ile L1 (hareketsiz durma) ve L8 (dizleri bükme) aktiviteleri için bulunmuştur. EKG işaretlerine göre yapılan sınıflandırma işleminde %39,16 başarı oranı gözlenmiştir.

İ-1B-YİÖ yöntemine dayalı olarak ivmeölçer, jireskop, Manyetometre ve EKG sensör ve işaretlerden elde edilen öznitelikler kullanılarak RO sınıflandırma metodu ile gerçekleştirilen sınıflandırmalarda elde edilen başarı oranları Tablo 4.35’te verilmiştir.

Tablo 4.35. Sensör türlerine göre başarı oranları

Sensör Türü	İvme	Jireskop	Manyetometre	EKG İşaretleri
Başarı Oranı(%)	90,00	74,16	87,50	39,16

Tablo 4.35’te görüldüğü gibi en yüksek başarı oranı %90 başarı ile ivmeölçer sensörlerinden elde edilen özniteliklerin kullanılmasında bulunmuştur. En düşük başarı oranı ise %39,16 başarı ile EKG işaretlerinden elde edilen özniteliklerin kullanılmasında bulunmuştur. Veri setinde EKG işaretlerinin kanal sayısının az olması ve EKG kayışının takıldığı göğüs bölgesinin hareketler üzerinde çok etkisinin olmaması düşük başarı elde edilmesine sebep olmuştur. İvme sensörlerinde elde edilen öznitelikler HT’da çok daha başarılı olmuştur. Diğer en başarılı sensör işaretleri Manyetometre sensörlerinden elde edilen öznitelik grubunun sınıflandırılmasında olarak gözlenmiştir.

4.3.2. Eksenlerine Göre Başarı Oranları

Çalışma sürecinde kullanılan veri seti 3 eksenli sensörlerden elde edilmiştir. Sensörlerin X eksen, Y eksen ve Z ekseninden elde edilen özniteliklerin RO sınıflandırma metodu ile sınıflandırma işlemleri gerçekleştirilmiştir. Eksenlerden elde edilen özniteliklere göre yapılan değerlendirmeler sonucu elde edilen karışıklık matrisleri ve performans oranları Tablo 4.36– Tablo 4.41 arasındaki tablolarda verilmiştir.

Tablo 4.36. X Eksen için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	2	5	3	0	0	0	0	0	0	0	0	0
L3	0	0	10	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	1	0	8	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.37. X Ekseni için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,500	0,000	1,000	0,500	0,667
L3	1,000	0,027	0,769	1,000	0,870
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,018	0,818	0,900	0,857
L11	0,800	0,009	0,889	0,800	0,842
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,917	0,008	0,927	0,917	0,912

Tablo 4.36 ve Tablo 4.37 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak sensörlerin X ekseninden elde edilen özneliklerin sınıflandırılmasında L1 (Hareketsiz durma), L3 (uzanma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme)ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) aktivitesinde bulunmuştur. Sensörlerin X ekseninden elde edilen özneliklere göre yapılan sınıflandırma işleminde %91,66 başarı oranı ile yüksek başarı gözlenmiştir.

Sensörlerin Y eksenlerinden elde edilen özneliklerin RO sınıflandırma metoduna göre sınıflandırılmasından elde edilen karışıklık matrisi Tablo 4.38’de ve performans oranları Tablo 4.39’da gösterilmiştir.

Tablo 4.38. Y Ekseni için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	2	7	1	0	0	0	0	0	0	0	0	0
L3	2	4	4	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	0	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.39. Y Eksenini için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,036	0,692	0,900	0,783
L2	0,700	0,045	0,583	0,700	0,636
L3	0,400	0,009	0,800	0,400	0,533
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,018	0,800	0,800	0,800
L11	0,800	0,018	0,800	0,800	0,800
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,875	0,011	0,882	0,875	0,871

Tablo 4.38 ve Tablo 4.39 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak sensörlerin Y ekseninden elde edilen özneliklerin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L3 (uzanma) aktivitesinde bulunmuştur. Sensörlerin Y ekseninden elde edilen özneliklere göre yapılan sınıflandırma işleminde %87,5 başarı oranı gözlenmiştir.

Sensörlerin Z eksenlerinden elde edilen özneliklerin RO sınıflandırma metoduna göre sınıflandırılmasından elde edilen karışıklık matrisi Tablo 4.39’da ve performans oranları Tablo 4.40’ta gösterilmiştir.

Tablo 4.40. Z Eksenini için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	1	8	1	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	6	4	0
L11	0	0	0	0	0	0	0	0	0	4	6	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.41. Z Eksenine için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Keskinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,009	0,900	0,900	0,900
L2	0,800	0,027	0,727	0,800	0,762
L3	0,800	0,009	0,889	0,800	0,842
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,600	0,036	0,600	0,600	0,600
L11	0,600	0,036	0,600	0,600	0,600
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,892	0,010	0,893	0,892	0,892

Tablo 4.40 ve Tablo 4.41 incelendiğinde en yüksek başarının elde edildiği yöntem kullanılarak sensörlerin Z ekseninden elde edilen özneliklerin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L10 (tempolu yürüyüş yapma) ve L11 (koşma) hareketlerinde gerçekleşmiştir. Sensörlerin Z ekseninden elde edilen özneliklere göre yapılan sınıflandırma işleminde %89,16 başarı oranı gözlenmiştir.

Tablo 4.42. Eksen türlerine göre başarı oranları

Eksen Türü	X Eksenine	Y Eksenine	Z Eksenine
Başarı Oranı(%)	91,66	87,5	89,16

Tablo 4.42’de belirtildiği gibi sensörlerin eksenlerinden elde edilen özneliklere göre yapılan sınıflandırma işlemlerinde en yüksek başarının %91,66 başarı oranı ile X ekseninden alınan özneliklerden gerçekleştiği ve eksen türlerine göre yapılan incelemede tüm eksenlerden elde edilen başarı oranlarının yüksek olduğu gözlenmiştir. En düşük başarı oranı %87,5 olarak Y eksenine ait işaretlerden elde edilen öznelikler ile elde edilmiştir.

4.3.3. İstatistiksel Özniteliklere Göre Başarı Oranları

Çalışmada kullanılan veri setine geliştirilen en iyi yöntemin uygulanması ile elde edilen özniteliklerin istatistiksel özniteliklerin her biri için incelenmesi ile gerçekleşen durumlar Tablo 4.43 – Tablo 4.66 arasındaki tablolarda verilmiştir. İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden ortalama özniteliğin elde edilmesi ile gözlenen başarı oranları Tablo 4.43’te verilmiştir.

Tablo 4.43. Ortalama öznitelikleri için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	5	2	3	0	0	0	0	0	0	0	0	0
L2	4	4	2	0	0	0	0	0	0	0	0	0
L3	7	1	2	0	0	0	0	0	0	0	0	0
L4	0	0	0	9	1	0	0	0	0	0	0	0
L5	0	0	0	1	6	2	0	1	0	0	0	0
L6	0	0	0	0	1	7	0	2	0	0	0	0
L7	0	0	0	0	0	0	9	1	0	0	0	0
L8	0	0	0	0	0	3	0	7	0	0	0	0
L9	0	0	0	0	0	0	0	2	8	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	2	5	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.44. Ortalama öznitelikleri için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,500	0,100	0,313	0,500	0,385
L2	0,400	0,027	0,571	0,400	0,471
L3	0,200	0,045	0,286	0,200	0,235
L4	0,900	0,027	0,750	0,900	0,818
L5	0,600	0,027	0,667	0,600	0,632
L6	0,700	0,045	0,583	0,700	0,636
L7	0,900	0,000	1,000	0,900	0,947
L8	0,700	0,055	0,538	0,700	0,609
L9	0,800	0,000	1,000	0,800	0,889
L10	0,800	0,018	0,800	0,800	0,800
L11	0,500	0,018	0,714	0,500	0,588
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,667	0,030	0,685	0,667	0,667

İşaretlerden elde edilen istatistiksel özniteliklerin ortalama özniteliği kullanılarak RO ile %66,7 başarı oranı gözlenmiştir. L12 (öne ve arkaya zıplama) hareketi için %100 başarı oranı bulunmuştur. En düşük başarı %20 başarı oranı ile L3 (uzanma) hareketinde gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden standart sapma özneliğın elde edilmesi ile gözlenen başarı oranları Tablo 4.45 ve Tablo4.46’da verilmiştir.

Tablo 4.45. Standart Sapma için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	1	6	3	0	0	0	0	0	0	0	0	0
L3	1	1	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	9	0	1	0	0	0	0
L7	0	0	0	0	0	1	9	0	0	0	0	0
L8	0	0	0	1	0	0	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.46. Standart Sapma için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,600	0,009	0,857	0,600	0,706
L3	0,800	0,027	0,727	0,800	0,762
L4	1,000	0,009	0,909	1,000	0,952
L5	1,000	0,000	1,000	1,000	1,000
L6	0,900	0,009	0,900	0,900	0,900
L7	0,900	0,000	1,000	0,900	0,947
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,018	0,818	0,900	0,857
L11	0,800	0,009	0,889	0,800	0,842
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,900	0,009	0,903	0,900	0,898

Tablo 4.45 ve Tablo 4.46 incelendiğinde en yüksek başarının elde edildiği yöntem kullanılarak Standart Sapma istatistiksel özneliklerinin sınıflandırılmasında L1 (Hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Standart sapma istatistiksel özneliklerine göre yapılan sınıflandırma işleminde %90 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden enerji özniteliğın elde edilmesi ile gözlenen başarı oranları Tablo 4.47 ve Tablo 4.48’de verilmiştir.

Tablo 4.47. Enerji için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	0	6	4	0	0	0	0	0	0	0	0	0
L3	1	1	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	1	9	0	0	0	0	0
L8	0	0	0	1	1	0	0	8	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.48. Enerji için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,009	0,900	0,900	0,900
L2	0,600	0,018	0,750	0,600	0,667
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,009	0,909	1,000	0,952
L5	1,000	0,009	0,909	1,000	0,952
L6	1,000	0,009	0,909	1,000	0,952
L7	0,900	0,000	1,000	0,900	0,947
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,018	0,818	0,900	0,857
L11	0,800	0,009	0,889	0,800	0,842
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,892	0,010	0,896	0,892	0,891

Tablo 4.47 ve Tablo 4.48 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Enerji istatistiksel özniteliklerinin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Enerji istatistiksel özelliklere göre yapılan sınıflandırma işleminde %89,16 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden entropi özneliğinin elde edilmesi ile gözlenen başarı oranları Tablo 4.49 ve Tablo 4.50’de verilmiştir.

Tablo 4.49. Entropi için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	1	0	0	0	0	0	0	0	0	0	0
L2	2	6	2	0	0	0	0	0	0	0	0	0
L3	0	4	6	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.50. Entropi için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,600	0,045	0,545	0,600	0,571
L3	0,600	0,018	0,750	0,600	0,667
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,018	0,800	0,800	0,800
L11	0,800	0,018	0,800	0,800	0,800
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,892	0,010	0,893	0,892	0,891

Tablo 4.49 ve Tablo 4.50 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Entropi istatistiksel özneliklerinin sınıflandırılmasında L4(yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) ve L3 (uzanma) hareketlerinde gerçekleşmiştir. Entropi istatistiksel özneliklerine göre yapılan sınıflandırma işleminde %89,16 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden korelasyon özneteliğinin elde edilmesi ile gözlenen başarı oranları Tablo 4.51 ve Tablo 4.52’de verilmiştir.

Tablo 4.51. Korelasyon için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	3	5	2	0	0	0	0	0	0	0	0	0
L2	4	4	2	0	0	0	0	0	0	0	0	0
L3	1	2	7	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	2	0	8	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	3	6	1
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.52. Korelasyon için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,300	0,045	0,375	0,300	0,333
L2	0,400	0,064	0,364	0,400	0,381
L3	0,700	0,036	0,636	0,700	0,667
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	1,000	0,018	0,833	1,000	0,909
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,027	0,750	0,900	0,818
L11	0,600	0,009	0,857	0,600	0,706
L12	1,000	0,009	0,909	1,000	0,952
Ortalama	0,808	0,017	0,810	0,808	0,805

Tablo 4.51 ve Tablo 4.52 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Korelasyon özneteliğinin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L1 (hareketsiz durma) hareketinde gerçekleşmiştir. Korelasyon özneteliği ile yapılan sınıflandırma işleminde %80,83 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden ardışık mutlak fark özneliğın elde edilmesi ile gözlenen başarı oranları Tablo 4.53 ve Tablo 4.54'te verilmiştir.

Tablo 4.53. Ardışık mutlak fark için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	2	3	5	0	0	0	0	0	0	0	0	0
L3	1	3	6	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	1	9	0	0	0	0	0
L8	0	0	0	0	2	2	0	6	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	2	8	1
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.54. Ardışık mutlak fark için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,027	0,769	1,000	0,870
L2	0,300	0,027	0,500	0,300	0,375
L3	0,600	0,045	0,545	0,600	0,571
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,018	0,833	1,000	0,909
L6	1,000	0,027	0,769	1,000	0,870
L7	0,900	0,000	1,000	0,900	0,947
L8	0,600	0,000	1,000	0,600	0,750
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,018	0,818	0,900	0,857
L11	0,800	0,009	0,889	0,800	0,842
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,842	0,014	0,844	0,842	0,833

Tablo 4.53 ve Tablo 4.54 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Ardışık Mutlak Farklar özneliğının sınıflandırılmasında L1 (Hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Ardışık Mutlak Farklar özneliğine göre yapılan sınıflandırma işleminde %84,16 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden medyan özniteliğın elde edilmesi ile gözlenen başarı oranları Tablo 4.55 ve Tablo 4.56’da verilmiştir.

Tablo 4.55. Medyan için RO ile elde edilen karşıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	8	1	1	0	0	0	0	0	0	0	0	0
L2	1	6	3	0	0	0	0	0	0	0	0	0
L3	1	3	6	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	2	2	0	6	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	6	4	0
L11	0	0	0	0	0	0	0	0	0	8	2	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.56. Medyan için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,800	0,018	0,800	0,800	0,800
L2	0,600	0,036	0,600	0,600	0,600
L3	0,600	0,036	0,600	0,600	0,600
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,018	0,818	0,900	0,857
L6	1,000	0,018	0,833	1,000	0,909
L7	1,000	0,000	1,000	1,000	1,000
L8	0,600	0,000	1,000	0,600	0,750
L9	1,000	0,000	1,000	1,000	1,000
L10	0,600	0,073	0,429	0,600	0,500
L11	0,200	0,036	0,333	0,200	0,250
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,775	0,020	0,777	0,775	0,768

Tablo 4.55 ve Tablo 4.56 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Medyan istatistiksel özelliğinden elde edilen özniteliklerin sınıflandırılmasında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L11 (koşma) hareketinde gerçekleşmiştir. Medyan istatistiksel özelliği ile elde edilen özniteliklere göre yapılan sınıflandırma işleminde %77,5 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden çarpıklık özneliğinin elde edilmesi ile gözlenen başarı oranları Tablo 4.57 ve Tablo 4.58’de verilmiştir.

Tablo 4.57. Çarpıklık için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	3	5	2	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	0	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	1	9	1
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.58. Çarpıklık için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FP Rate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,027	0,769	1,000	0,870
L2	0,500	0,018	0,714	0,500	0,588
L3	0,800	0,018	0,800	0,800	0,800
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,009	0,900	0,900	0,900
L6	1,000	0,000	1,000	1,000	1,000
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,000	1,000	0,900	0,947
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,009	0,900	0,900	0,900
L11	0,900	0,009	0,900	0,900	0,900
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,908	0,008	0,908	0,908	0,905

Tablo 4.57 ve Tablo 4.58 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Çarpıklık istatistiksel özelliğinden elde edilen özneliklerin sınıflandırılmasında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Çarpıklık istatistiksel özelliği ile elde edilen özelliklere göre yapılan sınıflandırma işleminde %90,83 başarı oranı ile oldukça yüksek başarı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden basıklık özneteliğın elde edilmesi ile gözlenen başarı oranları Tablo 4.59 ve Tablo 4.60'ta verilmiştir.

Tablo 4.59. Basıklık için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	0	1	0	0	0	0	0	0	0	0	0
L2	3	4	3	0	0	0	0	0	0	0	0	0
L3	0	2	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	9	0	0	1	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	3	7	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.60. Basıklık için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,027	0,750	0,900	0,818
L2	0,400	0,018	0,667	0,400	0,500
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,000	1,000	1,000	1,000
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,027	0,727	0,800	0,800
L11	0,700	0,018	0,778	0,700	0,700
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,867	0,012	0,866	0,867	0,862

Tablo 4.59 ve Tablo 4.60 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Basıklık özneteliğının sınıflandırılmasında L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Basıklık özneteliğine göre yapılan sınıflandırma işleminde %86,66 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden minimum özneliğin elde edilmesi ile gözlenen başarı oranları Tablo 4.61 ve Tablo 4.62’de verilmiştir.

Tablo 4.61. Minimum için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	4	3	3	0	0	0	0	0	0	0	0	0
L2	4	5	1	0	0	0	0	0	0	0	0	0
L3	4	3	3	0	0	0	0	0	0	0	0	0
L4	0	0	0	6	0	1	0	1	1	0	1	0
L5	0	0	0	0	6	2	0	0	1	0	1	0
L6	0	0	0	0	2	3	0	5	0	0	0	0
L7	0	0	0	0	0	0	8	0	0	2	0	0
L8	0	0	0	0	1	4	0	4	1	0	0	0
L9	0	0	0	1	0	0	0	0	9	0	0	0
L10	0	0	0	0	1	0	0	0	0	6	3	0
L11	0	0	0	1	0	1	0	0	0	2	6	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.62. Minimum için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin Oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,400	0,073	0,333	0,400	0,364
L2	0,500	0,055	0,455	0,500	0,476
L3	0,300	0,036	0,429	0,300	0,353
L4	0,600	0,018	0,750	0,600	0,667
L5	0,600	0,036	0,600	0,600	0,600
L6	0,300	0,073	0,273	0,300	0,286
L7	0,800	0,000	1,000	0,800	0,889
L8	0,400	0,055	0,400	0,400	0,400
L9	0,900	0,027	0,750	0,900	0,818
L10	0,600	0,036	0,600	0,600	0,600
L11	0,600	0,045	0,545	0,600	0,571
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,583	0,038	0,595	0,583	0,585

Tablo 4.61 ve Tablo 4.62 incelendiğinde minimum özneliğine göre RO algoritması ile sınıflandırma yapıldığında %58,3 başarı oranı gözlenmiştir. L12 (öne ve arkaya zıplama) hareketi için %100 başarı oranı bulunmuştur. En düşük başarı %30 oranı ile L3 (uzanma) ve L6 (öne eğilme) hareketlerinde gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden maksimum özneliğin elde edilmesi ile gözlenen başarı oranları Tablo 4.63 ve Tablo 4.64’te verilmiştir.

Tablo 4.63. Maksimum için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	0	1	0	0	0	0	0	0	0	0	0
L2	4	2	4	0	0	0	0	0	0	0	0	0
L3	0	3	7	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	1	9	0	0	0	0	0
L8	0	0	0	0	0	0	0	10	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.64. Maksimum için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,036	0,692	0,900	0,783
L2	0,200	0,027	0,400	0,200	0,267
L3	0,700	0,045	0,583	0,700	0,636
L4	1,000	0,009	0,909	1,000	0,952
L5	0,900	0,000	1,000	0,900	0,947
L6	1,000	0,009	0,909	1,000	0,952
L7	0,900	0,000	1,000	0,900	0,947
L8	1,000	0,000	1,000	1,000	1,000
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,018	0,800	0,800	0,800
L11	0,800	0,018	0,800	0,800	0,800
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,850	0,014	0,841	0,850	0,840

Tablo 4.63 ve Tablo 4.64 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Maksimum özniteliğinin sınıflandırılmasında L4 (yürüme), L6 (öne eğilme), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En kötü sınıflandırma %20 başarı oranı ile L2(oturma ve rahatlama) hareketinde gerçekleşmiştir. Maksimum istatistiksel özniteliğine göre yapılan sınıflandırma işleminde %85,00 başarı oranı gözlenmiştir.

İşaretlere İ-1B-YİÖ uygulandıktan sonra yeni oluşan işaretlerden varyasyon katsayısı özniteliğinin elde edilmesi ile gözlenen başarı oranları Tablo 4.65 ve Tablo 4.66'da verilmiştir.

Tablo 4.65. Varyasyon katsayısı için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	1	5	4	0	0	0	0	0	0	0	0	0
L3	1	1	8	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	9	0	1	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	10	0	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.66. Varyasyon katsayısı için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,500	0,009	0,833	0,500	0,625
L3	0,800	0,036	0,667	0,800	0,727
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	0,900	0,009	0,900	0,900	0,900
L7	1,000	0,000	1,000	1,000	1,000
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	1,000	0,018	0,833	1,000	0,909
L11	0,800	0,000	1,000	0,800	0,889
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,908	0,008	0,914	0,908	0,905

Tablo 4.65 ve Tablo 4.66 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak Varyasyon Katsayısı istatistiksel özelliğinden elde edilen özniteliklerin sınıflandırılmasında L1 (Hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L10 (tempolu yürüyüş yapma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) hareketinde gerçekleşmiştir. Varyasyon Katsayısı istatistiksel özelliği ile elde edilen özniteliklere göre yapılan sınıflandırma işleminde %90,83 başarı oranı gözlenmiştir.

En yüksek başarımın elde edildiği yöntem kullanılarak tüm istatistiksel özniteliklerin ayrı ayrı sınıflandırılmasıyla gerçekleşen başarılar Tablo 4.67’de verilmiştir.

Tablo 4.67. İstatistiksel Özniteliklere Göre Başarı Oranları

Öznitelikler	Başarı Oranı (%)
Ortalama	66,66
Standart Sapma	90,00
Enerji	89,16
Entropi	89,16
Korelasyon	80,83
Ardışık Mutlak Farklar	84,16
Medyan	77,50
Çarpıklık	90,83
Basıklık	86,66
Minimum	58,33
Maximum	85,00
Varyasyon Katsayısı	90,83

Tablo 4.67 incelendiğinde Çarpıklık ve Varyasyon Katsayısı istatistiksel özniteliklerine dayalı olarak yapılan sınıflandırmada %90,83 oranı ile en yüksek başarı elde edildiği gözlenmiştir. Daha sonra gerçekleşen en iyi başarı ise %90 oranı ile Standart Sapma istatistiksel özniteliğine dayalı olarak yapılan sınıflandırmada gerçekleşmektedir. En düşük başarı oranı ise %58.33 oranı ile Minimum istatistiksel özniteliğine dayalı olarak yapılan sınıflandırmada gerçekleştiği gözlenmiştir.

4.3.4. Sensörlerin Bağlandığı Vücut Bölgelerine Göre Başarı Oranları

Çalışma sürecinde kullanılan veri seti deneklerin göğüs bölgesine, sol ayak bileğine ve sağ el bileğine bağlanan ivmeölçer (acceleration), jireskop (gyro), manyetometre (magnetometer) sensörlerinden ve EKG işaretlerinden elde edilerek oluşturulmuştur. En başarılı yöntemden elde edilen öznitelikler vücuda bağlandığı gölgeye göre gruplandırılıp RO sınıflandırma metodu ile sınıflandırma işlemleri gerçekleştirilmiştir. Sensörlerin takıldığı vücut bölgesine göre yapılan değerlendirmeler sonucu elde edilen karışıklık matrisleri ve performans oranları Tablo 4.68– Tablo 4.73 arasındaki tablolarda verilmiştir.

Tablo 4.68. Göğüs bölgesinden elde edilen öznelilikler için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	3	4	3	0	0	0	0	0	0	0	0	0
L2	5	4	1	0	0	0	0	0	0	0	0	0
L3	1	3	6	0	0	0	0	0	0	0	0	0
L4	0	0	0	9	1	0	0	0	0	0	0	0
L5	0	0	0	1	8	0	0	0	0	0	1	0
L6	0	0	0	0	0	10	0	0	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	1	1	0	8	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	8	2	0
L11	0	0	0	0	1	0	0	0	0	2	7	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.69. Göğüs bölgesinden elde edilen öznelilikler için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,300	0,055	0,333	0,300	0,316
L2	0,400	0,064	0,364	0,400	0,381
L3	0,600	0,036	0,600	0,600	0,600
L4	0,900	0,009	0,900	0,900	0,900
L5	0,800	0,027	0,727	0,800	0,762
L6	1,000	0,009	0,909	1,000	0,952
L7	1,000	0,000	1,000	1,000	1,000
L8	0,800	0,000	1,000	0,800	0,889
L9	1,000	0,000	1,000	1,000	1,000
L10	0,800	0,018	0,800	0,800	0,800
L11	0,700	0,027	0,700	0,700	0,700
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,775	0,020	0,778	0,775	0,775

Tablo 4.68 ve Tablo 4.69 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanarak deneklerin göğüs bölgesine takılan sensörlerden elde edilen özneliliklerin sınıflandırılmasında L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L1 (hareketsiz durma) ve L2 (oturma ve rahatlama) aktivitesi için bulunmuştur. Göğüs bölgesine takılan sensörlerden elde edilen özneliliklere göre yapılan sınıflandırma işleminde %77,50 başarı oranı gözlenmiştir.

Deneklerin sol ayak bileği bölgesine takılan sensörlerden elde edilen özneliliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.70’te ve performans ölçütleri Tablo 4.71’de verilmiştir.

Tablo 4.70. Sol ayak bileğinden elde edilen öznitelikler için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	9	0	0	0	0	0	1	0	0	0	0	0
L2	2	3	5	0	0	0	0	0	0	0	0	0
L3	0	1	9	0	0	0	0	0	0	0	0	0
L4	0	0	0	10	0	0	0	0	0	0	0	0
L5	0	0	0	0	10	0	0	0	0	0	0	0
L6	0	0	0	0	0	9	0	1	0	0	0	0
L7	0	0	0	0	0	0	10	0	0	0	0	0
L8	0	0	0	0	0	1	0	9	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	0	9	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.71. Sol ayak bileğinden elde edilen öznitelikler için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı (TP Rate)	Yanlış negatiflerin oranı (FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	0,900	0,018	0,818	0,900	0,857
L2	0,300	0,009	0,750	0,300	0,429
L3	0,900	0,045	0,643	0,900	0,750
L4	1,000	0,000	1,000	1,000	1,000
L5	1,000	0,000	1,000	1,000	1,000
L6	0,900	0,009	0,900	0,900	0,900
L7	1,000	0,009	0,909	1,000	0,952
L8	0,900	0,009	0,900	0,900	0,900
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,009	0,900	0,900	0,900
L11	0,900	0,009	0,900	0,900	0,900
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,892	0,010	0,893	0,892	0,882

Tablo 4.70 ve Tablo 4.71 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak sol ayak bileğine takılan sensörlerden elde edilen özniteliklerin sınıflandırılmasında L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) için bulunmuştur. Sol ayak bileğine takılan sensörlerden elde edilen özniteliklere göre yapılan sınıflandırma işleminde %89,16 başarı oranı gözlenmiştir.

Deneklerin sağ el bileği bölgesine takılan sensörlerden elde edilen özniteliklerin kullanılması ile RO ile gözlenen karışıklık matrisi Tablo 4.72’de ve performans ölçütleri Tablo 4.73’te verilmiştir.

Tablo 4.72. Sağ el bileğinden elde edilen öznitelikler için RO ile elde edilen karışıklık matrisi

Aktivite	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12
L1	10	0	0	0	0	0	0	0	0	0	0	0
L2	2	4	4	0	0	0	0	0	0	0	0	0
L3	0	6	4	0	0	0	0	0	0	0	0	0
L4	0	0	0	8	2	0	0	0	0	0	0	0
L5	0	0	0	1	9	0	0	0	0	0	0	0
L6	0	0	0	0	0	2	1	7	0	0	0	0
L7	0	0	0	0	0	1	9	0	0	0	0	0
L8	0	0	0	1	0	5	0	4	0	0	0	0
L9	0	0	0	0	0	0	0	0	10	0	0	0
L10	0	0	0	0	0	0	0	0	0	9	1	0
L11	0	0	0	0	0	0	0	0	0	2	8	0
L12	0	0	0	0	0	0	0	0	0	0	0	10

Tablo 4.73. Sağ el bileğinden elde edilen öznitelikler için RO ile elde edilen performans oranları

Sınıflar	Doğru pozitif oranı(TP Rate)	Yanlış negatiflerin oranı(FPrate)	Kesinlik (Precision)	Duyarlılık (Recall)	F-ölçütü (F-measure)
L1	1,000	0,018	0,833	1,000	0,909
L2	0,400	0,055	0,400	0,400	0,400
L3	0,400	0,036	0,500	0,400	0,444
L4	0,800	0,018	0,800	0,800	0,800
L5	0,900	0,018	0,818	0,900	0,857
L6	0,200	0,055	0,250	0,200	0,222
L7	0,900	0,009	0,900	0,900	0,900
L8	0,400	0,064	0,364	0,400	0,381
L9	1,000	0,000	1,000	1,000	1,000
L10	0,900	0,018	0,818	0,900	0,857
L11	0,800	0,009	0,889	0,800	0,842
L12	1,000	0,000	1,000	1,000	1,000
Ortalama	0,725	0,025	0,714	0,725	0,718

Tablo 4.72 ve Tablo 4.73 incelendiğinde en yüksek başarımın elde edildiği yöntem kullanılarak sağ el bileğine takılan sensörlerden elde edilen özniteliklerin sınıflandırılmasında L1 (hareketsiz durma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 sınıflandırma oranı bulunmuştur. En düşük sınıflandırma oranı L2 (oturma ve rahatlama) ve L8 (dizleri bükme) aktiviteleri için bulunmuştur. sağ el bileğine takılan sensörlerden elde edilen özniteliklerin sınıflandırılması işleminde %72,50 başarı oranı gözlenmiştir.

İ-1B-YİÖ yöntemine dayalı olarak göğüs bölgesi, sol ayak bileği ve sağ el bileği bölgelerine takılan sensörlerden elde edilen öznitelikler kullanılarak RO sınıflandırma metodu ile gerçekleştirilen sınıflandırmalarda elde edilen başarı oranları Tablo 4.74'te verilmiştir.

Tablo 4.74. Sensörlerin bağlandığı vücut bölgelerine göre başarı oranları

Vücut Bölgesi	Göğüs bölgesi	Sol ayak bileği	Sağ el bileği
Başarı Oranı(%)	77,50	89,16	72,50

Tablo 4.74'te görüldüğü gibi en yüksek başarı oranı %89,16 başarı ile sol ayak bileğine takılan sensörlerden elde edilen özneliklerin kullanılmasında bulunmuştur. En düşük başarı oranı ise %72,50 başarı ile sağ el bileğine takılan sensörler işaretlerinden elde edilen özneliklerin kullanılmasında bulunmuştur.

4.4. En İyi Yöntemin Farklı Sınıflandırıcılar ile Sınıflandırılması

Çalışma sürecinde geliştirilen yöntemler arasında materyal olarak kullanılan veri seti üzerinde en başarılı sonucu veren İ-1B-YİÖ ($PB=6;özellik=EB$) metodu farklı sınıflandırma metotlarına göre sınıflandırılarak sonuçlar Tablo 4.75'te verilmiştir.

Tablo 4.75. En iyi yöntemin farklı metotlarda hareket tanıma başarı oranları (%)

İşaret	BN	NB	ICO	LB	SMO	SL	RSS	HT	LMT	RO
İ-1B-YİÖ (PB=6;Data=0)	89,16	90,00	87,50	87,50	86,66	90,83	86,66	88,33	90,83	95,83

Tablo 4.75'te görüldüğü gibi en iyi sınıflandırma oranı RO sınıflandırma metodu ile gerçekleşmiştir. En kötü sınıflandırma ise %86,66 oranı ile RSS sınıflandırma metodunda gerçekleşmiştir. Genel olarak Tablo 4.75'te verilen sınıflandırma metotlarının başarı oranlarının yüksek olduğu gözlenmiştir.

5. SONUÇLAR ve ÖNERİLER

Son yıllarda algılama ve hesaplama teknolojilerinin gelişmesi, insanların çevresiyle olan etkileşiminin gözlemlenmesine büyük katkı sağlamıştır. İnsan hareketleri doğası gereği değişmez ve hiyerarşiktir. Çeşitli uygulama alanlarındaki yaygın etkisi nedeniyle dikkat çeken bir alan olan insan hareketlerini tanıma ve insan faaliyetlerin anlaşılması için birçok araştırmacının dikkatini çekmiştir (Ronaldo ve Cho, 2016). Son yıllarda, insanların günlük yaşamlarındaki hareketlerini farklı uygulamalar kullanarak insan etkinliği hakkında derinlemesine bilgi edinmekle alakalı birçok çalışmanın yapıldığı görülmektedir. Başarılı bir hareket tanıma uygulaması ile ev davranış analizi (Vepakomma ve ark., 2015), video gözetimi (Qin ve ark., 2016), yürüyüş analizi (Hammerla ve ark., 2016) ve jest tanıma (Kim ve Toomajian, 2016) gibi birçok farklı alanda kullanım alanı mevcuttur. Video tabanlı HT ve sensör tabanlı HT olmak üzere iki tür HT vardır (Cook ve ark., 2013). Video tabanlı HT, kameradaki insan hareketlerini içeren videoları veya görüntüleri analiz ederken (Sung ve ark., 2011), sensör tabanlı HT, bir ivmeölçer, jiroskop, Bluetooth, ses sensörleri ve benzeri gibi akıllı sensörlerden gelen hareket verilerine kullanılmaktadır. Sensör teknolojisinin ve yaygın bilgisayar teknolojisinin gelişen gelişimi nedeniyle, sensör tabanlı HT daha popüler hale gelerek yaygın olarak kullanılmaktadır (Alvarez ve ark., 2013; Al Jeroudi ve ark., 2015; Tural ve Erdoğan, 2017).

Sensör tabanlı HT sistemleri, kişinin vücuduna bağlı heterojen sensörleri kullanarak ve insan eylemlerinin durumunu yansıtan birçok fizyolojik sinyalin sürekli izlenmesine izin vererek kullanıcının ve çevresinin durumunu yakalamayı hedeflemektedir. Özellikle son yıllarda belirgin bir şekilde gelişen özel sensörlerin ve mobil cihazların hareket tanıma uygulamalarında kullanılmasıyla mikroelektronik ve bilgisayar sistemlerinde çok önemli ölçüde gelişim gösterdiği görülmüştür (Györbíró ve ark. 2009).

Hareket tanıma sistemleri havacılık, sanayi, sağlık, ofis senaryoları, eğitim, robotik, akıllı evler, eğlence sektörü, spor, askeri, güvenlik, müzik vb. birçok farklı alanlarda fayda sağlamak için hem akademik hem de endüstriyel alanda yaygın olarak kullanıldığı görülmüştür (Jain ve Kanhangad, 2018).

Bu tez çalışması sürecinde vücut sensörlerinden alınan veriler yardımıyla insan fiziksel aktivitelerinin tanınması amaçlanmıştır. Çalışmada insan fiziksel aktivitelerinin sınıflandırılması için gerekli aşamalar incelenmiştir. İnsan fiziksel aktivitelerinin sınıflandırılmasında öznitelik çıkarımı önemli bir yere sahiptir. Sınıflandırmada etkili öznitelikler kullanılması doğru sınıflandırma performansını arttırmaktadır. Çalışma sürecinde insan hareketlerinin sınıflandırılmasında ayırt ediciliği yüksek öznitelik gruplarının oluşturulması için literatürde bulunmayan 9 farklı yeni metot önerilmiştir. Görüntü işleme uygulamalarında sıkça kullanılan YİÖ metoduna dayanarak geliştirilen bu yöntemler 1B-YİÖ, OT-1B-YİÖ, MT-1B-YİÖ, ÇÖ-1B-YİÖ, A-1B-YİÖ, KT-1B-YİÖ, K-1B-YİÖ, ÜD-1B-YİÖ, İ-1B-YİÖ yöntemleridir. Bu yöntemler ile etkin öznitelikler oluşturularak hareket tanıma işlemi gerçekleştirilmiştir. Önerilen bu yeni metotlar sensör işaretlerine uygulanarak elde edilen öznitelik grupları sınıflandırılarak performans analizi gerçekleştirilmiştir.

Önerilen metotların performansını değerlendirmek amacıyla UCI veri kütüphanesinden temin edilen MHealth isimli veri seti kullanılmıştır (Banos ve ark.,2015; Banos ve ark.,2015). Bu veri seti 10 gönüllünün göğüs bölgesi, sağ el bileği ve sol ayak bileğine çok eksenli sensörler takılarak belirli aralıklarda 12 fiziksel hareketi (hareketsiz durma, oturma ve rahatlama, uzanma, yürüme, merdiven tırmanma, öne eğilme, kolların yukarı doğru kaldırılması, dizlerin bükülmesi (çömelme), bisiklet sürme, tempolu yürüyüş, koşma, ön ve arkaya zıplama) gerçekleştirilmesi ile elde edilen işaret kayıtlarından oluşmaktadır. Önerilen öznitelik çıkarım yöntemlerinin değerlendirilmesi amacıyla bu 12 hareketin sınıflandırılması gerçekleştirilmiştir.

Çalışmanın ilk aşamasında üzerinde çalışılan veri setine 1B-YİÖ metodu uygulanarak öznitelik grupları oluşturulmuştur. Elde edilen öznitelikler açık kaynak yazılım olan WEKA'da sınıflandırılmıştır. Çalışmada 1B-YİÖ metodundan elde edilen öznitelikler farklı sınıflandırma algoritmalarına göre sınıflandırılarak en başarılı on sınıflandırmayı gerçekleştiren algoritmalar belirtilmiştir. Bu on sınıflandırma algoritması (BN, NB, ICO, LB, SMO, RC, RSS, HT, LMT, RO) kullanılarak aralarında en başarılı sonucu %91.66 başarı oranı ile RO algoritması gerçekleştirmiştir. 1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için doğru pozitif oranlarının 1.000 olarak hesaplanması ile

%100 başarı oranında bir sınıflandırma gerçekleştirilmiştir. Sınıflandırmada en düşük başarı oranının %50 oranı ile L1 (hareketsiz durma) ve L3 (uzanma) hareketlerine benzetilen L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir (Tablo 4.2 ve 4.3). Bu aşamadan sonra çalışma boyunca geliştirilen diğer yöntemlerin performanslarını değerlendirmek amacıyla RO algoritması kullanılmıştır.

RO algoritması kullanılarak OT-1B-YİÖ metodu ile elde edilen öznitelikler ile %92,5 oranında bir başarı elde edilmiştir. OT-1B-YİÖ yöntemi kullanılarak RO sınıflandırma metoduna göre L1 (Hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştirilmiştir. Sınıflandırmada en düşük başarı oranının L3 (uzanma) hareketine benzetilerek L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir (Tablo 4.4 ve Tablo 4.5).

MT-1B-YİÖ metodu ile elde edilen öznitelik gruplarının RO algoritması ile sınıflandırılmasında %89,16 başarı elde edilmiştir. Sınıflandırmada L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği gözlenmiştir. En kötü sınıflandırmanın L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir (Tablo 4.6 ve Tablo 4.7).

ÇÖ-1B-YİÖ metodunda komşuluk değer parametresi 8, 10 ve 12 alınarak farklı öznitelik grupları oluşturulmuş ve oluşturulan bu öznitelik grupları RO algoritmasına göre sınıflandırılmıştır. Yapılan sınıflandırmalar sonucunda en başarılı sınıflandırmanın %92,5 oranında komşuluk değer 12 olarak alınması ile gerçekleştiği gözlenmiştir (Tablo 4.8). Komşuluk değer 12 alınarak ÇÖ-1B-YİÖ metodundan elde edilen özniteliklerin RO algoritması ile sınıflandırılmasında L1 (Hareketsiz durma), L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı oranında bir sınıflandırma gerçekleştiği gözlenmiştir. Sınıflandırmada en düşük başarı oranının L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir (Tablo 4.9 ve Tablo 4.10).

A-1B-YİÖ metodu ile edinilen öznitelik gruplarının RO algoritmasına göre sınıflandırılmasında %92,5 başarı elde edilmiştir. Sınıflandırmada L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9

(bisiklet sürme), L10 (tempolu yürüyüş yapma) ve L12 (öne ve arkaya zıplama) hareketleri için %100 başarı elde edilmiştir. En düşük başarının L2 (oturma ve rahatlama) hareketinde gerçekleştiği gözlenmiştir (Tablo 4.11 ve Tablo 4.12).

Geliştirilen bir başka yöntem olan K-1B-YİÖ metodunda α ve β parametreleri sırasıyla (1,1), (1,2), (1,3), (2,1), (2,2), (2,3), (3,1), (3,2), (3,3) değerlerini alarak farklı öznitelik grupları elde edilerek RO algoritmasına göre sınıflandırması gerçekleştirilmiştir. Yapılan gözlemler sonucunda en başarılı sonucu %93,33 oranı ile $\alpha=2$ ve $\beta=1$ parametreleri kullanılarak elde edilen öznitelik grubunun sağladığı gözlenmiştir (Tablo 4.13). Bu değerler ile yapılan sınıflandırmada en başarılı sınıflandırmayı gerçekleştiren hareketler %100 başarı oranı ile L1 (Hareketsiz durma), L3 (uzanma), L4 (yürüme), L5 (merdiven çıkma), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketleri olmuştur. En kötü sınıflandırma L2 (oturma ve rahatlama) hareketinde gözlenmiştir (Tablo 4.14 ve Tablo 4.15).

Merkez değerden önce ve sonra alınan komşuluk değerlerin kaydırılarak K-1B-YİÖ metodundan elde edilen öznitelik grupları RO algoritmasına göre sınıflandırıldığında en yüksek başarı %91,66 oranı ile $PL=4$ ve $PR=4$ parametre değerlerinin kullanılmasından elde edilmiştir (Tablo 4.16). Bu parametre değerleri ile elde edilen özniteliklerin sınıflandırılmasında en başarılı sınıflandırma %100 oranında başarı gösteren L4 (yürüme), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L11 (koşma) ve L12 (öne ve arkaya zıplama) hareketlerinde gözlenmiştir. En kötü sınıflandırma ise L2(oturma ve rahatlama) hareketinde gerçekleşmiştir (Tablo 4.17 ve Tablo 4.18).

Önerilen bir diğer yöntem olan ÜD-1B-YİÖ metodundan elde edilen özniteliklerin sınıflandırmada gösterdiği performansı değerlendirmek amacıyla farklı bant genişlikleri kullanılarak alt ve üst grup öznitelikler elde edilmiştir. Bu öznitelikler RO algoritmasına göre sınıflandırılarak performans değerlendirmesi yapılmıştır. Yapılan değerlendirmede en başarılı sonucun %91,66 oranı ile $\beta=2.5 \times SS$ alınarak üst özellik grubundan elde edilen özniteliklerle gerçekleştiği gözlenmiştir (Tablo 4.19). En başarılı sınıflandırmada L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketlerinde %100

başarı olduğu gözlenmiştir. En kötü sınıflandırmanın ise L2 (oturma ve rahatlama) hareketinde gerçekleştiği görülmüştür (Tablo 4.20 ve Tablo 4.21).

Oluşturulacak öznitelik sayısını artırıcı etkisi olduğu düşünülen İ-1B-YİÖ metodunda 3 aşamalı indirgeme yapılarak pencere boyutu 4, 5, 6, 7 ve 8 alındığında dört farklı indirgeme özelliğine (en büyük, en küçük, ortalama ve medyan) göre öznitelik grupları oluşturulup RO algoritmasına göre sınıflandırma gerçekleştirilmiştir. En yüksek başarının %95.83 oranı ile pencere boyutunun 6 ve indirgeme özelliğinin en büyük olarak seçilmesi ile elde edilen öznitelik gruplarının sınıflandırılması ile gerçekleştiği gözlenmiştir (Tablo 4.22). En başarılı sınıflandırmanın gerçekleştiği durumda L1 (hareketsiz durma), L4 (yürüme), L5 (merdiven çıkma), L6 (öne eğilme), L7 (kolları yukarı kaldırma), L8 (dizleri bükme), L9 (bisiklet sürme), L10 (tempolu yürüyüş yapma) ve L12 (öne ve arkaya zıplama) hareketlerinin sınıflandırılmasında %100 başarı elde edilmiştir. En kötü sınıflandırma ise L2 (oturma ve rahatlama) ve L3 (uzanma) hareketlerinde gerçekleşmiştir (Tablo 4.23 ve Tablo 4.24).

Genel olarak incelendiğinde geliştirilen metotlardan elde edilen öznitelik gruplarının sınıflandırılmasında en yüksek başarının %95,83 oranı ile İ-1B-YİÖ metodunda pencere boyutu 6 ve indirgeme özelliği en büyük olarak seçilmesi ile 3 aşamada elde edilen özniteliklerden gerçekleştiği gözlenmiştir. En kötü performans ise %89,16 başarı oranı ile MT-1B-YİÖ metodundan elde edilen özniteliklerin sınıflandırılmasında gerçekleşmiştir. Geliştirilen metotların uygulanmasında en kısa işlem süresinin 1B-YİÖ metodunun uygulanmasında gerçekleştiği görülmüştür (Tablo 4.25). Geliştirilen metotların sınıflandırmada oldukça başarılı olduğu gözlenmiştir.

Geliştirilen metotlardan elde edilen özniteliklerin sınıflandırılması sürecinde her denemede L4 (yürüme), L7 (kolları yukarı kaldırma), L9 (bisiklet sürme) ve L12 (öne ve arkaya zıplama) hareketleri %100 başarıyla bulunarak en ayırt edilebilir hareketler olarak gözlenmiştir. Sınıflandırma aşamasında en kötü performansı her denemede en başarısız sonucu veren L2 (oturma ve rahatlama) hareketi göstermiştir (Tablo 4.26). Genellikle L2 (oturma ve rahatlama) hareketi ile L3 (uzanma) hareketi birbirine benzetilmiştir.

En başarılı bulunan yöntem(İ-1B-YİÖ_{PB=6;Özellik=EB}) ile elde edilen öznitelikler kullanılan sensör türlerine göre sınıflandırılarak başarı oranları incelenmiştir. MHealth veri kümesi elde edilirken kişilerin göğüs bölgesine, sağ el bileği ve sol ayak bileklerine bağlanan jireskop, ivmeölçer ve manyetometre sensörlerinden ve göğüs bölgesinden

alınan EKG işaretlerinden elde edilen özniteliklerin ayrı ayrı RO algoritması ile sınıflandırmaları gerçekleştirilmiştir. Yalnızca ivmeölçer sensörlerinden elde edilen öznitelik grubunun kullanılması ile %90 başarı oranı gözlenmiştir. Jireskop sensörlerinden elde edilen öznitelik gruplarının RO algoritması ile sınıflandırılmasında ise %74.16 başarı elde edilmiştir. Manyetometre sensörlerinden elde edilen öznitelik gruplarının kullanılması durumunda ise %87,5 başarı oranı gözlenmiştir. Son olarak göğüs bölgesinden alınan EKG işaretlerinden elde edilen öznitelik grubu ile %39,16 başarı oranı gözlenmiştir (Tablo 4.35). Sensör türlerine göre sınıflandırma işlemlerinde inceleme yapıldığında en başarılı sonucun ivmeölçer sensörlerinden elde edilen öznitelik gruplarının sınıflandırılmasında gerçekleştiği gözlenmiştir. En kötü sonuç ise EKG işaretlerinden elde edilen özniteliklerin sınıflandırılmasında görülmüştür. Veri setinde EKG işaretlerine ait kanal sayısının az olması EKG işaretlerinden elde edilen başarının düşük olmasına neden olmuştur.

Çalışmada ayrıca en iyi yöntemden elde edilen özniteliklerin kullanılan her üç sensörün X, Y ve Z eksenlerinden elde edilen öznitelik gruplarına göre ayrı ayrı RO algoritması ile sınıflandırmaları gerçekleştirilmiştir. Yalnızca X eksenini ile elde edilen özniteliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile %91,66 oranında bir başarı gözlenmiştir. Y ekseninden elde edilen özniteliklerin RO sınıflandırma algoritmasına göre sınıflandırılması ile %87,5 oranında bir başarı gözlenmiştir. Sensörlerin yalnızca Z ekseninden elde edilen öznitelik grubu kullanılarak sınıflandırma yapıldığında %89,5 başarı gözlenmiştir. Eksenlerden elde edilen özniteliklerin sınıflandırma işlemleri karşılaştırıldığında en başarılı sonucun X ekseninden alınan öznitelik grubunda gerçekleştiği gözlenmiştir (Tablo 4.42).

Çalışmanın sonraki aşamasında ise en iyi yöntemden elde edilen özniteliklerin kullanılan istatistiksel özellik gruplarına göre ayrı ayrı sınıflandırmaları yapılarak sonuçlar incelenmiştir. Ortalama özneliğin kullanılması ile %66,66, standart sapma ile elde edilen özniteliklerin sınıflandırılmasında %90, enerji ile elde edilen özniteliklerin sınıflandırılmasında %89,16, entropi ile elde edilen özniteliklerin sınıflandırılmasında %89,16, korelasyon ile elde edilen özniteliklerin sınıflandırılmasında %80,83, ardışık mutlak farklar ile elde edilen özniteliklerin sınıflandırılmasında %84,16, medyan ile elde edilen özniteliklerin sınıflandırılmasında %77,50, çarpıklık ile elde edilen özniteliklerin sınıflandırılmasında %90,83, basıklık ile elde edilen özniteliklerin sınıflandırılmasında

%86,66, minimum ile elde edilen özniteliklerin sınıflandırılmasında %58,33, maksimum ile elde edilen özniteliklerin sınıflandırılmasında %85, varyasyon katsayısı ile elde edilen özniteliklerin sınıflandırılmasında %90,83 başarı bulunmuştur. Kullanılan istatistiksel özellikler içinde en başarılı sonuç çarpıklık ve varyasyon katsayısı ile elde edilen öznitelik gruplarının sınıflandırılmasında gerçekleşmiştir (Tablo 4.67).

Çalışmada gerçekleştirilen bir diğer karşılaştırma kriteri ise sensörlerin denekler üzerinde takıldığı vücut bölgelerinden elde edilen işaretlere göre sınıflandırmada gerçekleşen başarı oranlarına göre yapılmıştır. Vücut bölgelerinden elde edilen işaretlerle gerçekleştirilen sınıflandırma işlemlerinde göğüs bölgesinden elde edilen işaretlerin sınıflandırılmasında %77,50 başarı oranı, sol ayak bileklerinden alınan işaretlerin sınıflandırılmasında %89,16 başarı oranı ve sağ el bileklerinden alınan işaretlerin sınıflandırılmasında ise %72,50 başarı oranı gözlenmiştir. En yüksek başarının sol ayak bileğinden alınan işaretler ile gerçekleştiği görülmüştür (Tablo 4.74).

Çalışmanın son aşamasında en iyi yöntem ile elde edilen öznitelik grubunun farklı sınıflandırma algoritmalarına göre sınıflandırılması gerçekleşmiştir. Yapılan sınıflandırmaların başarı oranlarının yüksek olduğu gözlemlenerek en iyi performansın RO algoritması ile yapılan sınıflandırmada gerçekleştiği görülmüştür (Tablo 4.75).

Bu tez çalışmasında kullanılan veri setinden (MHealth) elde edilen başarı oranı, aynı veri setini kullanarak hareket tanıma uygulamaları yapan diğer çalışmalardan daha üstün ve yüksek başarı elde edildiği yapılan literatür çalışmasından anlaşılmıştır (Khatun ve Morshed, 2018; Chen ve ark., 2019; Wang ve ark., 2019).

Bu tez çalışmasında önerilen öznitelik çıkarım yöntemleri farklı metotların oluşturulmasına zemin hazırlamıştır. 1B-YİÖ metodu baz alınarak işaret üzerinde seçilen değerler ve buna komşu değerler arasında farklı ilişkiler kurularak yeni metotların oluşturulması düşünülmüştür. Ayrıca derin öğrenme yönteminin içinde geliştirilen öznitelik çıkarım yöntemlerinin kullanılması düşünülmüştür.

6. KAYNAKLAR

- Al Jeroudi, Ali, M.A., Latief, M., Akmeliawati, R., 2015. Online Sequential Extreme Learning Machine Algorithm Based Human Activity Recognition Using Inertial Data, *Control Conference (ASCC)*, 10th Asian, Kota Kinabalu, Malaysia.
- Allen, F., Ambikairajah, E., Lovell, N., Celler, B., An adapted gaussian mixture model approach to Accelerometry-Based movement classification using Time-Domain features, in EMBS '06, 2006, pp. 3600–3603.
- Altun, K. ve Barshan, B., 2010. Human activity recognition using inertial/ magnetic sensor units, in Human Behavior Understanding, *Lecture Notes in Computer Science*, 38–51.
- Alvarez, A., Alonso, J.M., Trivino, G., 2013. Human activity recognition in indoor environments through fusing information extracted from the intensity of WiFi signal and accelerations, *Information Sciences*, 233, 162-182.
- Archer, K. J. ve Kimes, R. V., 2008. Empirical characterization of random forest variable importance measures. *Computational Statistics & Data Analysis*, 52 (4), 2249-2260.
- Atallah, L., Lo, B., King, R., Yang, G.Z., 2011. Sensor positioning for activity recognition using wearable accelerometers, *IEEE Transactions on Biomedical Circuits and Systems*, 5 (4), 320–329.
- Avci, A., Bosch, S., Marin-Perianu, M., Marin-Perianu, R., Havinga, P., 2010. Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey, *In Proceedings of the 23rd International Conference on Architecture of Computing Systems (ARCS)*, Hannover, Germany, 1–10.
- Baig, M.M., Gholamhosseini, H., Connolly, M.J., 2013. A comprehensive survey of wearable and wireless ECG monitoring systems for older adults, *Medical & biological engineering & computing*, 51 (5), 485-495.
- Banos, O., Moral-Munoz, J., Diaz-Reyes, I., Arroyo-Morales, M., Damas, M., Herrera-Viedma, E., & Villalonga, C., 2015. mDurance: a novel mobile health system to support trunk endurance assessment. *Sensors*, 15 (6), 13159-13183.
- Banos, O., Villalonga, C., Garcia, R., Saez, A., Damas, M., Holgado-Terriza, J. A., & Rojas, I., 2015. Design, implementation and validation of a novel open framework

- for agile development of mobile health applications. *Biomedical engineering online*, 14 (2), S6.
- Bao L., Intille, S.S., 2004. Activity recognition from User-Annotated acceleration data, *in Pervasive Computing*, 1–17.
- Barnes, K., Kauffman, V., Connolly, C., 2014. Health wearables: Early days, *PwC Health Research Institute Report*.
- Bayat, A., Pomplun, M., Tran, D. A., 2014. A study on human activity recognition using accelerometer data from smartphones, *Procedia Computer Science*, vol. 34, pp. 450–457.
- Berchtold, M., Budde, M., Gordon, D., Schmidtke, H.R., Beigl, M., 2010. ActiServ: activity recognition service formobile phones, *in Proceedings of the 14th IEEE International Symposium on Wearable Computers (ISWC '10)*, South Korea, 1-8.
- Berchtold, M., Budde, M., Schmidtke, H., Beigl, M., 2010. An extensible modular recognition concept that makes activity recognition practical, *in Advances in Artificial Intelligence, Lecture Notes in Computer Science*, Berlin, 400–409.
- Breiman, L., 2001. Random forests. *Machine learning*, 45 (1), 5-32.
- Brezmes, T., Gorricho, J.L., Cotrina, J., 2009. Activity recognition from accelerometer data on a mobile phone, *Lecture Notes in Computer Science*, 5518, 796-799.
- Briem, G. J., Benediktsson, J. A., Sveinsson, J. R., 2002. Multiple classifiers applied to multisource remote sensing data. *IEEE transactions on geoscience and remote sensing*, 40 (10), 2291-2299.
- Capela, N.A., Lemaire, E.D., Baddour, N., Feature Selection for Wearable Smartphone-Based Human Activity Recognition with Able-bodied, Elderly, and Stroke Patients, *PLOS ONE*, 10 (4).
- Caros, J.S., Chetelat, O., Celka, P., Dasen, S., CmÁral, J., 2005. Very low complexity algorithm for ambulatory activity classification, *in EMBEC*.
- Chan, M., EstèVe, D., Fourniols, J. Y., Escriba, C., Campo, E., 2012. Smart wearable systems: Current status and future challenges, *Artificial intelligence in medicine*, 56 (3), 137-156.
- Chen, Y.P., Yang, J.Y., Liou, S.N., Lee, G.Y., Wang, J.S., 2008. Online classifier construction algorithm for human activity detection using a tri-axial accelerometer, *Applied Mathematics and Computation*, 205 (2), 849–860.

- Chen, G.C., Huang, C.N., Chiang, C.Y., Hsieh, C.J., Chan, C.T., 2010. A reliable fall detection system based on wearable sensor and signal magnitude area for elderly residents, In International Conference on Smart Homes and Health Telematics, Berlin, 267-270.
- Chen, Y., Wang, J., Huang, M., & Yu, H., 2019. Cross-position activity recognition with stratified transfer learning. *Pervasive and Mobile Computing*.
- Cheng, J., Amft, O., Lukowicz, P., 2010. Active capacitive sensing: Exploring a new wearable sensing modality for activity recognition, in *Pervasive Computing*, 6030 of Lecture Notes in Computer Science, 319–336.
- Chernbumroong, S., Cang, S., Atkins, A., Yu, H., Elderly activities recognition and classification for applications in assisted living, *Expert Systems with Applications*, 40 (5), 1662-1674.
- Choudhury, T., Borriello, G., Landay, J.A., LeGrand, L., Lester, J., Rahimi, A., Harrison, B., 2008. The mobile sensing platform: An embedded activity recognition system, *IEEE Pervasive Computing*, 7 (2), 32-41.
- Cook, D., Feuz, K.D., Krishnan, N.C., 2013. Transfer learning for activity recognition: A survey. *Knowledge and information systems*, 36, 537–556.
- Damaševičius, R., Vasiljevas, M., Šalkevičius, J., Woźniak, M., 2016. Human Activity Recognition in AAL Environments Using Random Projections, *Computational and Mathematical Methods in Medicine*.
- Dougherty, J., Kohavi, R., Sahami, M., 1995. Supervised and unsupervised discretization of continuous features, Proceedings of the Twelfth International Conference on Machine Learning, 194-202.
- Elvira, V., Naazabal-Renteria, A., Artes-Rodrigues, A., 2014. A novel feature extraction technique for human activity recognition, *Statistical Signal Processing (SSP)*, IEEE, Gold Coast, VIC, Australia.
- Ermes, M., Parkka, J., Cluitmans, L., 2008. Advancing from offline to online activity recognition with wearable sensors, in *Engineering in Medicine and Biology Society. 30th Annual International Conference of the IEEE*, 4451–4454.
- Foerster, F., Fahrenberg, J., 2000. Motion pattern and posture: Correctly assessed by calibrated accelerometers, *Behavior Research Methods, Instruments, & Computers*, 32 (3), 450-457.

- Gupta P., Dallas, T., 2014. Feature selection and activity recognition system using a single triaxial accelerometer, *IEEE Transactions on Biomedical Engineering*, 61 (6), 1780-1786.
- Györbíró, N., Fábíán, A., Hományi, G., 2009. An activity recognition system for mobile phones, *Mobile Networks and Applications*, 14 (1), 82-91
- Hammerla, N.Y., Halloran, S., Ploetz, T., 2016. Deep, convolutional, and recurrent models for human activity recognition using wearables, *in: IJCAI*.
- Hanai, Y., Nishimura, J., Kuroda, T., 2009. Haar-like filtering for human activity recognition using 3d accelerometer, *in IEEE 13th Digital Signal Processing Workshop and 5th IEEE Signal Processing Education Workshop*, 675–678.
- Hassan, M.M., Uddin, M.Z., Mohamed, A., Almogren, A., 2018. A robust human activity recognition system using smartphone sensors and deep learning, *Future Generation Computer Systems*, 81 , 307-313.
- He, Z. Y., Jin, L.W., 2008. Activity recognition from acceleration data using ar model representation and svm, *in International Conference on Machine Learning and Cybernetics*, 4, 2245–2250.
- He, Z., Jin, L., Zhen, L., Huang, J., 2008. Gesture recognition based on 3D accelerometer for cell phones interaction, in *Circuits and Systems, 2008. APCCAS 2008. IEEE Asia Pacific Conference on, 2008*, 217–220.
- He, Z., Jin, L., 2009. Activity recognition from acceleration data based on discrete cosine transform and svm, *in IEEE International Conference on Systems, Man and Cybernetics*, 5041–5044.
- Heinz, E., Kunze, K., Gruber, M., Bannach, D., Lukowicz, P., 2006. Using wearable sensors for Real-Time recognition tasks in games of martial arts - an initial experiment, *in CIG*, 98–102.
- Henpraserttae, A., Thiemjarus, S., Marukatat, S., 2011. Accurate activity recognition using a mobile phone regardless of device orientation and location, *in Proceedings of the International Conference on Body Sensor Networks (BSN '11)*, Dallas, Tex, USA, 41–46.
- Hoque E., Stankovic, J., 2012. AALO: activity recognition in smart homes using Active Learning in the presence of Overlapped activities, *in Proceedings of the 6th*

- International Conference on Pervasive Computing Technologies for Healthcare and Workshops (PervasiveHealth '12)*, 139–146.
- Howcroft, J., Kofman, J., Lemaire, E.D., 2017. Feature selection for elderly faller classification based on wearable sensors, *Journal of Neuro-Engineering and Rehabilitation*, 14 (47).
- Ibrahim, R., Ambikairajah, E., Celler, B., Lovell, N., Time-Frequency based features for classification of walking patterns, in *DSP '09, 2007*, pp. 187–190.
- Iso T., Yamazaki, K., 2006. Gait analyzer based on a cell phone with a single three-axis accelerometer, in *Proceedings of the 8th International Conference on Human-Computer Interaction with Mobile Devices and Services (MobileHCI '06)*, Espoo, Finland, 141–144.
- Jain, A., V. Kanhangad, 2018. Human Activity Classification in Smartphones Using Accelerometer and Gyroscope Sensors, *IEEE Sensors Journal*, 18 (3), 1169-1177.
- Jafari, R., Li, W., Bajcsy, R., Glaser, S., Sastry, S., 2007. Physical activity monitoring for assisted living at home, in *(BSN '07)*, 213–219.
- Jatoba, L.C., Grossmann, U., Kunze, C., Ottenbacher, J., Stork, W., 2008. Context-aware mobile health monitoring: Evaluation of different pattern recognition methods for classification of physical activity, in *30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5250–5253.
- Jordao, A., Torres, L.A.B., Schwartz, W.R., 2018. Novel approaches to human activity recognition based on accelerometer data, *Signal, Image and Video Processing*, 12, (7), 1-8.
- Kao, T.P., Lin, C.W., Wang, J.S., 2009. Development of a portable activity detector for daily activity recognition, in *IEEE International Symposium on Industrial Electronics*, 115–120.
- Karantonis, D., Narayanan, M., Mathie, M., Lovell, N., Celler, B., 2006. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring, *TITB*, 10 (1), 156–167.
- Kaya, Y., Uyar, M., Tekin, R., Yildirim, S., 2014. 1D-local binary pattern based feature extraction for classification of epileptic EEG signals, *Applied Mathematics and Computation*, 243, 209-219.

- Kaya, Y., 2015. Hidden pattern discovery on epileptic EEG with 1-D local binary patterns and epileptic seizures detection by grey relational analysis, *Australasian Physical & Engineering Sciences in Medicine*, 38 (3), 435-446.
- Kaya, Y., Ertuğrul, Ö. F., Tekin, R., 2015. Two novel local binary pattern descriptors for texture analysis. *Applied Soft Computing*, 34, 728-735.
- Kaya, Y., & Ertuğrul, Ö. F., 2016. A novel feature extraction approach for text-based language identification: Binary patterns. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31 (4).
- Khan, A., Lee, Y.K., Lee, S., Kim, T.S., 2010. A triaxial accelerometer based physical-activity recognition via augmented-signal features and a hierarchical recognizer, *IEEE Trans. Inf. Technol. Biomed.*, 14 (5), 1166–1172.
- Khatun, S., Morshed, B. I., 2018, May. Fully-Automated Human Activity Recognition with Transition Awareness from Wearable Sensor Data for mHealth. *In 2018 IEEE International Conference on Electro/Information Technology (EIT)*, (pp. 0934-0938). IEEE.
- Kim, Y., Toomajian, B., 2016. Hand gesture recognition using micro-doppler signatures with convolutional neural network. *IEEE Access*.
- Kose, M., Incel, O.D., Ersoy, C., 2012. Online human activity recognition on smart phones, *in Proceedings of the Workshop on Mobile Sensing: From Smartphones and Wearables to BigData (Colocated with IPSN)*, Beijing, China, 11–15.
- Kuncan, F., Kaya, Y., Kuncan, M., 2019. A Novel Approach for Activity Recognition with Down-Sampling 1D Local Binary Pattern Features. *Advances in Electrical and Computer Engineering*, 19 (1), 35-44.
- Kurban, O.C., 2014. Classification of human activities with wearable sensors without feature extraction, Master Thesis, *Yıldız Technical University, Institute of Science*, İstanbul, Turkey.
- Kwapisz, J.R., Weiss, G.M., Moore, S.A., 2011. Activity recognition using cell phone accelerometers, *ACM SIGKDD Explorations Newsletter*, 12 (2), 74-82.
- Lane, N., Mohammad, M., Lin et al. M., 2012. Bewell: a smartphone application to monitor, model and promote wellbeing, *in Proceedings of the 5th International ICST Conference on Pervasive Computing Technologies for Healthcare*, 23–26.

- Lara, O.D., Perez, A.J., Labrador, M.A., Posada, J.D., 2011. Centinela: A human activity recognition system based on acceleration and vital sign data, *Journal on Pervasive and Mobile Computing*, 8 (5), 717-729.
- Lara O.D. ve Labrador M.A., 2013. A survey on human activity recognition using wearable sensors, *IEEE Communications Surveys & Tutorials*, 15 (3), 1192–1209.
- Lee Y.S. ve Cho, S., 2011. Activity recognition using hierarchical hidden markov models on a smartphone with 3d accelerometer, in *Hybrid Artificial Intelligent Systems: 6th International Conference*, Wroclaw, Poland, 6678, Berlin, 460–467.
- Lester, J., Choudhury, T., Borriello, G., 2006. A practical approach to recognizing physical activities, in *Pervasive Computing*, 1–16.
- Lin, C.C., Lin, P.Y., Lu, P.K., Hsieh, G.Y., Lee, W. L., Lee, R.G., 2008. A healthcare integration system for disease assessment and safety monitoring of dementia patients, *IEEE Transactions on information Technology in Biomedicine*, 12 (5), 579-586.
- Lombriser, C., Bharatula, N.B., Roggen, D., Tröster, G., 2007. On-body activity recognition in a dynamic sensor network, in *BodyNets*, Florence, Italy, 1–6.
- Mannini, A., Sabatini, A.M., 2010. Machine learning methods for classifying human physical activity from on-body accelerometers, *Sensors*, 10 (2), 1154–1175.
- Mantjarvi, J., Himberg, J., Seppanen, T., 2001. Recognizing human motion with multiple acceleration sensors, in *Proceedings of the IEEE International Conference on Systems, Man and Cybernetics*, 747–52.
- Mathie, M., Coster, A., Lovell, N., Celler, B., 2003. Detection of daily physical activities using a triaxial accelerometer, *MBEC*, 41 (3), 296–301.
- Mathie, M.J., Celler, B.G., Lovell, N.H., Coster, A.C.F., 2004. Classification of basic daily movements using a triaxial accelerometer, *Medical and Biological Engineering and Computing*, 42 (5), 679–687.
- Mathie, M., Lovell, N., Coster, A., Celler, B., 2002. Determining activity using a triaxial accelerometer, in *EMBS/BMES*, 3, 2481–2482.
- Maurer, U., Smailagic, A., Siewiorek, D.P., Deisher, M., 2006. Activity recognition and monitoring using multiple sensors on different body positions, in *Wearable and Implantable Body Sensor Networks (BSN 06)*, USA, 113–116.

- McGlynn, D., Madden, M.G., 2011. An ensemble dynamic time warping classifier with application to activity recognition, *in Research and Development in Intelligent Systems XXVII*, 339–352.
- Miluzzo, E., Lane, N.D., Fodor, K., Peterson, R.A., Lu, H., Musolesi, M., Eisenman, S.B., Zheng, X., Campbell, A.T., 2008. Sensing meets mobile social networks: the design, implementation and evaluation of the CenceMe application, *in Proceedings of the 6th ACM Conference on Embedded Networked Sensor Systems (SenSys '08)*, Raleigh, NC, USA, 337–350.
- Minnen, D., Westeyn, T., Ashbrook, D., Presti, P., Starner, T., 2007. Recognizing soldier activities in the field, in 4th International Workshop on Wearable and Implantable Body Sensor Networks, 13, 236– 241.
- Nweke, H.F., Teh, Y.W., Al-Garadi, M.A., Alo, U.R., 2018. Deep Learning Algorithms for Human Activity Recognition using Mobile and Wearable Sensor Networks: State of the Art and Research Challenges, *Expert Systems with Applications*, 105, 233-261.
- Ojala, T., Pietikinen, M., Harwood, D., 1996. A comparative study of texture measures with classification based on featured distribution, *Pattern Recognition*, 51-59.
- Ojala, T. ve Pietikinen, M., 2000. Gray scale and rotation invariant texture classification with local binary patterns, Computer Vision, ECCV Proceedings, *Lecture Notes in Computer Science, Springer*, 404-420.
- Ojala T. ve Pietikinen M., 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Trans.Pattern Anal. Mach. Intell*, 971-987.
- Parkka, J., Ermes, M., Korpipaa, P., Mantyjarvi, J., Peltola, J., Korhonen, I., 2006. Activity classification using realistic data from wearable sensors, *IEEE Transactions on Information Technology in Biomedicine*, 10 (1), 119–128.
- Pham, N., Abdelzaher, T., 2008. Robust dynamic human activity recognition based on relative energy allocation, *in Distributed Computing in Sensor Systems*, 5067 of Lecture Notes in Computer Science, Berlin, 525–530.
- Ponce, H., Martinez–Villasenor, M.L., Miralles-Pechuan, L., 2016. A Novel Wearable Sensor-Based Human Activity Recognition Approach Using Artificial Hydrocarbon Networks, *Sensors*, 16 (7).

- Qin, J., Liu, L., Zhang, Z., Wang, Y., Shao, L., 2016. Compressive sequential learning for action similarity labeling. *IEEE Transactions on Image Processing*, 25, 756–769.
- Ravi, N., Dandekar, N., Mysore, P., Littman, M.L., 2005. Activity recognition from accelerometer data, in *National Conference on Artificial Intelligence*, 20, 1541.
- Riboni, D., Bettini, C., 2011. Cosar: hybrid reasoning for context-aware activity recognition, *Personal and Ubiquitous Computing*, 15, 271–289.
- Ronao, C. A., Cho, S. B., 2016. Human activity recognition with smartphone sensors using deep learning neural networks. *Expert systems with applications*, 59, 235–244.
- San-Segundo, R., Blunck, H., Moreno-Pimentel, J., Stisen, A., Gil-Martín, M., 2018. Robust Human Activity Recognition using smartwatches and smartphones, *Engineering Applications of Artificial Intelligence*, 72, 190–202.
- Saponas, T.S., Lester, J., Froehlich, J., Fogarty, J., Landay, J., 2008. iLearn on the iPhone: Real-Time Human Activity Classification on Commodity Mobile Phones.
- Siirtola, P., Röning, J., 2012. Recognizing human activities user-independently on smartphones based on accelerometer data, *IJIMAI*, 1 (5), 38–45.
- Sohn, T., Varshavsky, A., LaMarca, A., Chen, M.Y., Choudhury, T., Smith, I.E., Consolvo, S., Hightower, J., Griswold, W.G., Lara, E., 2006. Mobility detection using everyday GSM traces, in *UbiComp 2006: Ubiquitous Computing: 8th International Conference*, Lecture Notes in Computer Science, 4206, 212–224.
- Sung, J., Ponce, C., Selman, B., Saxena, A., 2011. Human activity detection from RGBD images, In *Proceedings of the AAAI Workshop on Plan, Activity, and Intent Recognition*.
- Tamura, T., Suda, Y., Sekine, M., Kimura, Y., Uchiyama, T., 2013. A Wearable Motion Sensor for Evaluating Walking Performance in Parkinson’s Disease with Treatments, In *Converging Clinical and Engineering Research on Neurorehabilitation*, Berlin, 717–720.
- Tapia, E.M., Intille, S.S., Haskell, W., Larson, K., Wright, J., King, A., Friedman, R., 2007. Real-time recognition of physical activities and their intensities using wireless accelerometers and a heart monitor, in *Proc. International Symposium on Wearable Computers*.

- Tharwat, A., Mahdi, H., Elhoseny, M., Hassanien, A.E., 2018. Recognizing human activity in mobile crowdsensing environment using the optimized KNN algorithm, *Expert Systems With Applications*, 107, 32-44.
- Tunçel, O., Altun, K., Barshan, B., 2009. Jiroskop Sinyallerinin İşlenmesiyle Bacak Hareketlerinin Sınıflandırılması, *Conference: IEEE 17th Conference on Signal Processing, Communications, and Applications (SIU 2009)*, Antalya.
- Tural, K., Akdoğan, E., 2017. Classification of Human Movements with Artificial Neural Networks using the data of smartphone detectors, *Automatic Control Turkish National Conference, TOK2017*.
- Vepakomma, P., De, D., Das, S.K., Bhansali, S., 2015. A-wristocracy: Deep learning on wrist-worn sensing for recognition of user complex activities, in: 2015 IEEE 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN), IEEE. pp. 1–6.
- Vinh, L., Lee, S., Le, H., Ngo, H., Kim, H., Han, M., Lee, Y.K., 2011. Semimarkov conditional random fields for accelerometer-based activity recognition, *Applied Intelligence*, 35, 226–241.
- Wang, J., Chen, Y., Hao, S., Peng, X., & Hu, L., 2019. Deep learning for sensor-based activity recognition: A survey. *Pattern Recognition Letters*, 119, 3-11.
- Wang, S., Yang, J., Chen, N., Chen, X., Zhang, Q., 2005. Human activity recognition with user-free accelerometers in the sensor networks, in *ICNN&B '05*, 2, 1212–1217.
- Wang, X., Rosenblum, D., Wang, Y., 2012. Context-aware mobile music recommendation for daily activities, *In Proceedings of the 20th ACM international conference on Multimedia ACM*, Japan, 99-108.
- Ward, J.A., Lukowicz, P., Tröster, G., Starner, T.E., 2006. Activity recognition of assembly tasks using Body- Worn microphones and accelerometers, *The IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28 (10), 1553-1567.
- Wu, J., Osuntogun, A., Choudhury, T., Philipose, M., Rehg, J. M., 2007. A scalable approach to activity recognition based on object use, *In 2007 IEEE 11th international conference on computer vision*, Brazil, 1-8.

- Wu, W.H., Bui, A.A., Batalin, M.A., Au, L.K., Binney, J.D, Kaiser, W.J., 2008. MEDIC: medical embedded device for individualized care, *Artificial Intelligence in Medicine*, 42 (2), 137–152.
- Yang, J., Wang, J., Chen, Y., 2008. Using acceleration measurements for activity recognition: An effective learning algorithm for constructing neural classifiers, *Pattern Recognition Letters*, 29 (16), 2213–2220.
- Yang, J., 2009. Toward physical activity diary: motion recognition using simple acceleration features with mobile phones, *Proceedings of the 1st International Workshop on Interactive Multimedia for Consumer Electronics (IMCE '09)*, 1-10.
- Yin, J., Yang, Q., Pan, J.J., 2007. Sensor-based abnormal human-activity detection, *IEEE Transactions on Knowledge & Data Engineering*, 20 (8), 1082-1090.
- Zappi, P., Lombriser, C., Stiefmeier, T., Farella, E., Roggen, D., Benini, L., Tröster, G., 2008. Activity recognition from On-Body sensors: Accuracy-Power Trade-Off by dynamic sensor selection, in *Wireless Sensor Networks*, Berlin, 17–33.
- Zhu, C., Sheng, W., 2009. Human daily activity recognition in robotassisted living using multi-sensor fusion, in *IEEE International Conference on Robotics and Automation*, 2154–2159.
- Zhu, C., Sheng, W., 2011. Motion- and location-based online human daily activity recognition, *Pervasive and Mobile Computing*, 7 (2), 256–269.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Fatma KUNCAN
Doğum Yeri ve Tarihi : Batman - 1987
Telefon : (0484) 212-1111 / 3033
E-posta : fatmakuncan@siirt.edu.tr

EĞİTİM

Derece		Bitirme Yılı
Lise	: Batman Lisesi, BATMAN	2004
Üniversite	: Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü	2009
Yüksek Lisans	: Kocaeli Üniversitesi, Bilişim Sistemleri Mühendisliği A.B.D.	2015
Doktora	: Siirt Üniversitesi, Elektrik-Elektronik Mühendisliği A.B.D.	2019

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2011-2013	Siirt Üniversitesi, Bilgisayar Müh. Bölümü	Arş. Gör.
2013-2014	GYTE, Bilgisayar Müh. Bölümü	Arş. Gör.
2014-2016	Kocaeli Üniversitesi, Bilişim Sistemleri Mühendisliği Bölümü	Arş. Gör.
2016-Devam	Siirt Üniversitesi, Bilgisayar Müh. Bölümü	Arş. Gör.

UZMANLIK ALANI: Bilgisayar Yazılımı, Veri Madenciliği, İşaret İşleme

YABANCI DİLLER: İngilizce

YAYINLAR

Uluslararası Hakemli Dergilerde (SCI) Yayınlanan-Baskıda Makaleler

1. **Kuncan F.**, Kaya Y., Kuncan M., A Novel Approach for Activity Recognition with Down-Sampling 1D Local Binary Pattern Features, Advances in Electrical and Computer Engineering, Vol. 19 (1), pp. 35-44, 2019.
2. **Kuncan F.**, Kaya Y., Kuncan M., Sensör işaretlerinden cinsiyet tanıma için yerel ikili örüntüler tabanlı yeni yaklaşımlar, Journal of the Faculty of Engineering and Architecture of Gazi University, Vol. 34 (4), pp. 2173-2186, 2019.

Uluslararası Hakemli Dergilerde (Alan İndeksli) Yayınlanan Makaleler

1. **Kuncan F.**, Yıldırım M., A method for determination of object-camera distance by using single camera, *IJNES - International Journal of Natural and Engineering Sciences*, 10 (3), pp. 4-8, 2016.

Uluslararası Bilimsel Toplantılarda Sunulan Ve Bildiri Kitabında (*Proceedings*)
Basılan Bildiriler

1. G. Saraç, İ. Kandilli, M. Kuncan, **F. Kuncan**, Elektronik Kart İmalatında Dizgi Makinelerinde Görüntü İşleme Sisteminin Tasarlanması, 1st International Engineering And Technology Symposium (2018 IETS)
2. M. Sönmez, C. Şen, İ. Kandilli, **F. Kuncan**, M. Kuncan, İçmesuyu İsale Hattı Basınç Yönetimi Sistemi ile Kontrolü ve Analizi, 1st International Engineering And Technology Symposium (2018 IETS)
3. M. Sönmez, C. Şen, İ. Kandilli, **F. Kuncan**, E. Cengiz, M. Kuncan, Scada Sisteminde Enerji Takibi ve Ekonomik Yaklaşımlar, 1st International Engineering And Technology Symposium (2018 IETS)
4. İ. Kandilli, **F. Kuncan**, E. Cengiz, M. Kuncan, Mekatronik Sistemin Uzaktan Scada İle Kontrolü, 1st International Engineering And Technology Symposium (2018 IETS)
5. S. Aksünger, S. Öztürk, **F. Kuncan**, M. Kuncan, Machining of the Image from the Camera on CNC, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
6. İ. Kandilli, M. R. Minaz, M. Kuncan, **F. Kuncan**, Robot Design for Locating People in Earthquakes, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
7. İ. Kandilli, M. R. Minaz, M. Kuncan, **F. Kuncan**, Design of Cooling and Heating System in Cars with Solar Energy, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
8. Ş. Kılıç, Y. Doğan, **F. Kuncan**, Sketch Recognition Algorithms For Spiders Diagrams, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
9. M. R. Minaz, M. Çelebi, **F. Kuncan**, F. Çıra, Comparison of Efficiency at Different Speeds of The Axial-Flux Synchronous Generator, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
10. M. R. Minaz, M. Çelebi, F. Çıra, **F. Kuncan**, Comparison of Power at Different Speeds of The Axial-Flux Synchronous Generator, International Conference on Multidisciplinary, Engineering, Science, Education and Technology (2017 IMESET)
11. A. Çubukçu, S. Öztürk, M. Kuncan, K. Kaplan, **F. Kuncan**, The Implementation of DC Motor Speed Control Using Image Processing and OPC Interface in the S7-1200, ISITES 2015, 3-5 June 2015, Valencia, Spain, p.814-821.
12. M. Sönmez, İ. Kandilli, M. Kuncan, **F. Kuncan**, SCADA Sisteminin Veri Güvenirliliği, International Engineering, Science and Education Conference, INESEC 2016, 1-3 December 2016, Diyarbakır, Turkey, p.855-864.
13. **F. Kuncan**, M. Yıldırım, A method for determination of object-camera distance by using single camera, International Congress on Natural and Engineering Sciences, ICNES, 1-5 September 2016, Üsküp, Makedonya.

Ulusal Bilimsel Toplantılarda Sunulan Ve Bildiri Kitabında Basılan
Bildiriler

1. **F. Kuncan**, M. Yıldırım, Tek Kamera Kullanarak Nesne-Kamera Arasındaki Uzaklığın Belirlenmesi İçin Bir Yöntem, Otomatik Kontrol Ulusal Toplantısı, TOK-2015, 10-12 Eylül 2015, Denizli, Türkiye.

Ulusal & Uluslararası Akademik Projeler

1. Kocaeli Üniversitesi **BAP** (2015-03) "Nokta Bulutu Yöntemi Kullanılarak 3 Boyutlu CNC' de Parça Üretimi" isimli proje, Yardımcı Araştırmacı, (2015-2017).
2. Siirt Üniversitesi **BAP** (2018-DR 009) "Hareket Tanıma Sistemleri" isimli proje, Araştırmacı ve Doktora Tez Öğrencisi, (2018-Devam).

