

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

HEMİPLEJİK YAŞLILARDA YÜRÜME ANALİZİ VE
DEĞERLENDİRİLMESİ

Hazal TAŞ ATILGAN

YÜKSEK LİSANS TEZİ

2018-ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI

HEMİPLEJİK YAŞLILARDA YÜRÜME ANALİZİ VE
DEĞERLENDİRİLMESİ

Hazal TAŞ ATILGAN

YÜKSEK LİSANS TEZİ

DANIŞMAN

Doç. Dr. Uğur BİLGE

“Kaynakça gösterilerek tezinden yararlanılabilir”

2018-ANTALYA

Sađlık Bilimleri Enstitüsü M¼d¼rl¼g¼ne;

Bu alıřma j¼rimiz tarafından Biyoistatistik ve Tıbbi Biliřim Anabilim Dalı, Tıp Biliřimi Programında Y¼ksek Lisans tezi olarak kabul edilmiřtir. 18/12/2018

İmza

Tez Danıřmanı : Do. Dr. Uđur BİLGE
Akdeniz ¼niversitesi



¼ye : Prof. Dr. Ahmet YARDIMCI
Akdeniz ¼niversitesi



¼ye : Prof. Dr. Tuncay AYDOĐAN
Isparta Uygulamalı Bilimler ¼niversitesi



Bu tez, Enstit¼ Y¼netim Kurulunca belirlenen yukarıdaki j¼ri ¼yeleri tarafından uygun g¼r¼lm¼ř ve Enstit¼ Y¼netim Kurulu'nun/...../..... tarih ve/..... sayılı kararıyla kabul edilmiřtir.

Prof. Dr. Narin DERİN

Enstit¼ M¼d¼r¼

ETİK BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün safhalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı beyan ederim.



Öğrencinin

Hazal TAŞ ATILGAN



Tez Danışmanı

Doç. Dr. Uğur BİLGE

TEŐEKKÜR

Akademik hayatımın bařlangıcından bu zamana kadar deęerli bilgi ve tecrubesini benden hi esirgemeyen, tez dnemim boyunca her zaman moral ve motivasyon vererek alıřmamı tamamlamamı saęlayan danıřmanım Do. Dr. Uęur BİLGE'ye ve tez alıřmam iin gerekli veriyi saęlayan, engin bilgi ve tecrubesıyla beni ynlendiren hocam Prof. Dr. Ahmet YARDIMCI'ya teőekkürü bir bor bilirim.

ok kıymetli hocam Prof. Dr. Hilmi UYSAL'a bizimle paylařtıęı verisi iin ok teőekkür ederim.

Tez alıřmalarım sırasında her zaman desteęini hissettięim mesai arkadařım Arař. Gör. Nevruz İLHANLI'ya ve alıřmam boyunca yanımda olan, yardımlarını benden esirgemeyen arkadařım Dt. Murat DALMIŐ'a kalpten teőekkür ederim.

Ayrıca alıřmam boyunca gsterdięi sabır ve anlayıřından dolayı sevgili eřim Oęuz ATILGAN'a ok byk bir teőekkür borluyum.

Eęitim hayatım boyunca beni her zaman daha ilerisi iin teővik eden, maddi ve manevi desteklerini hibir zaman esirgemeyen, bařarımda da bařarısızlıęımda da arkamda olduklarını bildięim, hayattaki en byk hazinelerim annem Asuman TAŐ, babam İrfan TAŐ, ve biricik ablam Bengü TAŐ'a sonsuz teőekkürlerimi sunarım.

ÖZET

Amaç: Dünya Sağlık Örgütü'nün tanımına göre inme; 24 saatten uzun süren ya da ölümle sonlanan, vasküler neden dışında gösterilebilir başka bir nedeni olmayan, hızlı gelişen, serebral işlevin fokal ve bazen de global olan bozukluğudur (Mazzoni ve ark., 2009). Özellikle tıbbi metinlerde, hemipleji ise “tek taraflı, kasım aşırı aktivasyonu ve motor aktivitesinde azalma, kas gerginliğinin artması, güçsüzlük ve seçici motor kontrolü kaybı” şeklinde tanımlanmaktadır (Barnes ve Fairhurst, 2012). Bu çalışma ile hemiplejik hastaların yürüme verileri analiz edilerek hastalıklarının hangi evrede (Brunnstrom Evrelemesi) olduğunun tespit edilebilmesi amaçlanmaktadır.

Yöntem: Çalışmada kullanılan üç eksenli ivmeölçer sinyalleri Matlab programında Daubechies5 (DB5) dalgacığı kullanılarak altıncı seviyeye kadar ayrıştırıldı. Yeni oluşan sinyallerden altıncı seviyedeki yaklaşım sinyalinin öznitelikleri seçildi. Daha sonra seçilen öznitelikler WEKA programında Iterative Classifier Optimizier, AdaBoost, Bagging, Classification via Regression (CVR), LogitBoost, OneR, J48, Random Forest, Random SubSpace, Multi Class Classifier ve RepTree algoritmaları; MATLAB programında ise Lineer Discriminant, Complex Tree, Subspace Discriminant ve RUSBoosted Trees algoritmaları ile sınıflandırma yapılarak evreleri tahmin etmek için kullanıldı.

Bulgular:Bu çalışmada hemiplejik hastaların hangi evrede oldukları, yürüme sinyalleri kullanılarak ayrık dalgacık dönüşümü yöntemi ve yapay öğrenme yöntemleri ile tahmin edilmeye çalışılmıştır. Hemiplejik hastaların Brunnstrom Evrelerini en iyi tahmin eden sınıflandırıcı WEKA'da LogitBoost algoritması ve MATLAB programında RUSBoosted Trees algoritması olmuştur.

Sonuç: Hemiplejik hastaların tedavisine yön verme bakımından önemli olan evre belirlemede dalgacık dönüşümü yöntemi ve yapay öğrenme yöntemlerinin kullanılabileceğı görülmüştür. LogitBoost ve RUSBoosted Trees algoritmaları en iyi sonucu vermiştir.

Anahtar Kelimeler: Yürüme analizi, hemipleji, ayrık dalgacık dönüşümü, yapay öğrenme, sınıflandırma

ABSTRACT

Objective: Stroke is defined by the World Health Organization as a clinical syndrome consisting of rapidly developing clinical signs of focal (or global in case of coma) disturbance of cerebral function lasting more than 24 hours or leading to death with no apparent cause other than a vascular origin (Mazzoni et al., 2009). Specifically in medical texts, hemiplegia is defined as a one-sided pattern of muscle overactivation and reduction in motor activity, leading to increased muscle tightness, and reflexes, weakness and loss of selective motor control (Barnes Fairhurst, 2012). In this study, we aimed to predict stages (Brunnstrom Classification) of hemiplegic patients by analyzing their walking data.

Method: The triaxial accelerometer signals used in the study were separated to the sixth level using the Daubechies5 (DB5) wavelet transform in the MATLAB program. The features of the sixth level separated approach signal was selected to form new signals. Then, various classification algorithms were used in WEKA and MATLAB programs to analyze these data. In WEKA, Iterative Classifier Optimizier, AdaBoost, Bagging, Classification via Regression (CVR), Logit Boost, OneR, J48, Random Forest, Random SubSpace, Multi Class Classifier and RepTree algorithms were used. In MATLAB, Lineer Discriminant, Complex Tree, Subspace Discriminant and RUSBoosted Trees algorithms were used.

Results: In this study, the stages of hemiplegic patients were estimated by using discrete wavelet transform method and machine learning algorithms on gait signals. LogitBoost and RUSBoosted Trees algorithms are found to be the best classifiers to predict Brunnstrom stages of hemiplegic patients.

Result: It has been observed that wavelet transform method and machine learning methods can be used in stage determination which is important in the treatment of hemiplegic patients. LogitBoost and RUSBoosted Trees algorithms produced the best results.

Key words: Gait analysis, hemiplegia, discrete wavelet transform, machine learning, classification

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
TABLOLAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vii
SİMGELER ve KISALTMALAR	x
1. GİRİŞ	1
2. GENEL BİLGİLER	3
2.1. Hemipleji	3
2.1.1. Konjenital Hemipleji	3
2.1.2. Kazanılmış Hemipleji	4
2.1.3. Hemiplejik Yürüme	5
2.2. Nörofizyolojik Değerlendirme Yöntemleri	6
2.2.1. Rood	7
2.2.2. Proprioseptif Nöromusküler Fasilitasyon	7
2.2.3. Bobath	7
2.2.4. Brunnstrom	8
2.3. Dalgacık Dönüşümü	9
2.3.1. Sürekli Dalgacık Dönüşümü	15
2.3.2. Ayrık Dalgacık Dönüşümü	16
2.3.3. Dalgacık Operatörleri	21
2.4. Makine Öğrenmesi	28
2.5. Literatür Özeti	30
3. GEREÇ ve YÖNTEM	35
3.1. Araştırmanın Amacı	35
3.2. Araştırmanın Soruları	35
3.3. Araştırmanın Evren ve Örneklemi	35
3.4. Araştırmanın Etik Yönü	35
3.5. Veri Toplama Araçları	35
3.6. Veri Seti Genel Bilgileri	36
3.7. Verilerin Analizi	39

3.7.1. Yürüme Sinyallerinden Ayrık Dalgacık Dönüşümü ile Öznitelik Çıkartma	42
3.7.2. Sınıflandırma Algoritmaları ile Brunnstrom Evresinin Tahmin Edilmesi	47
4. BULGULAR	52
4.1. WEKA’da 35 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları	52
4.2. WEKA’da 50 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları	63
4.3. MATLAB Programında 35 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları	73
4.4. MATLAB Programında 50 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları	81
5. TARTIŞMA	89
6. SONUÇ VE ÖNERİLER	91
KAYNAKLAR	93
ÖZGEÇMİŞ	101

TABLolar DİZİNİ

Tablo 2.1. Yürüme evreleri	6
Tablo 2.2. Brunnstrom motor iyileşme evreleri	9
Tablo 3.1. Hastaların Brunnstrom Evrelemesine göre dağılımları	36
Tablo 3.2. Deneklerin demografik özellikleri	36
Tablo 4.1. WEKA Sınıflandırma algoritmaları ve doğruluk oranları	52
Tablo 4.2. Kappa değerinin yorumlanması	53
Tablo 4.3. LogitBoost algoritması	55
Tablo 4.4. Iterative Classifier Optimizer algoritması	55
Tablo 4.5. AdaBoost algoritması	56
Tablo 4.6. Random SubSpace algoritması	57
Tablo 4.7. REPTree algoritması	57
Tablo 4.8. Random Forest algoritması	58
Tablo 4.9. MultiClass Classifier algoritması	59
Tablo 4.10. J48 algoritması	60
Tablo 4.11. OneR algoritması	60
Tablo 4.12. Bagging algoritması	61
Tablo 4.13. CVR algoritması	62
Tablo 4.14. WEKA’da tekrarlanan sınıflandırma algoritmaları ve doğruluk oranları	64
Tablo 4.15. LogitBoost algoritması (50 kişi)	65

Tablo 4.16. Iterative Classifier Optimizer algoritması (50 kişi)	66
Tablo 4.17. AdaBoost algoritması (50 kişi)	67
Tablo 4.18. Random SubSpace algoritması (50 kişi)	67
Tablo 4.19. RepTree algoritması (50 kişi)	68
Tablo 4.20. Random Forest algoritması (50 kişi)	69
Tablo 4.21. MultiClass Classifier algoritması (50 kişi)	70
Tablo 4.22. CVR algoritması (50 kişi)	70
Tablo 4.23. Bagging algoritması (50 kişi)	71
Tablo 4.24. OneR algoritması (50 kişi)	72
Tablo 4.25. J48 algoritması (50 kişi)	73
Tablo 4.26. Matlab programında 35 kişilik veri seti ile yapılan sınıflandırma sonuçları	74
Tablo 4.27. Matlab programında tekrarlanan sınıflandırma algoritmaları ve doğruluk oranları	81

ŞEKİLLER DİZİNİ

Şekil 2.1. Yürüme döngüsü	5
Şekil 2.2. Dalgacık dönüşümünde zaman-ölçek alanı	11
Şekil 2.3. Dönüşümlerin zaman-frekans çözünürlüğü bakımından karşılaştırılması	12
Şekil 2.4. Haar dalgacığının ölçek fonksiyonu	13
Şekil 2.5. Örnek dalgacık operatörleri	13
Şekil 2.6. Anasinyali oluşturan ötelenmiş ve ölçeklenmiş dalgacıkların gösterimi	15
Şekil 2.7. $c_0(n)$ ana sinyalinin iki ölçeğe ayrıştırılması	18
Şekil 2.8. Dalgacıklar için frekans spektrumları	20
Şekil 2.9. Sinyalin iki seviyeli ayrıştırılması ve birleştirilmesi	20
Şekil 2.10. Aşağı örnekleme	21
Şekil 2.11. Dalgacıkların ayrık ve sürekli olarak sınıflandırılması	22
Şekil 2.12. Haar Dalgacığının ölçek fonksiyon gösterimi	23
Şekil 2.13. Daubechies dalgacık ailesi	24
Şekil 2.14. Morlet dalgacık fonksiyonu	25
Şekil 2.15. Meksika şapkası dalgacığının görünümü	26
Şekil 2.16. Meyer ölçeklendirme ve dalgacık fonksiyonu	26
Şekil 2.17. Symlet dalgacık ailesi	27
Şekil 2.18. Coiflet dalgacıkları	27
Şekil 3.1. Sağlıklı bir hastaya ait anteroposterior eksenden alınan	

yürüme sinyali	37
Şekil 3.2. Brunnstrom III. evrede olan bir hastaya ait anteroposterior eksenenden alınan yürüme sinyali	37
Şekil 3.3. Brunnstrom IV. evrede olan bir hastaya ait anteroposterior eksenenden alınan yürüme sinyali	38
Şekil 3.4. Brunnstrom V. evrede olan bir hastaya ait anteroposterior eksenenden alınan yürüme sinyali	38
Şekil 3.5. Brunnstrom VI. evrede olan bir hastaya ait anteroposterior eksenenden alınan yürüme sinyali	39
Şekil 3.6. Sağlıklı bir kişiye ait yürüme sinyalinin 6 kademeli ayrıştırılması	42
Şekil 3.7. Şekil 3.8'deki kişiye ait yürüme sinyalinin detay katsayılarının gösterimi	43
Şekil 3.8. Brunnstrom evre III olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması	43
Şekil 3.9. Şekil 3.10'daki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi	44
Şekil 3.10. Brunnstrom evre IV olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması	44
Şekil 3.11. Şekil 3.12'deki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi	45
Şekil 3.12. Brunnstrom evre V olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması	45
Şekil 3.13. Şekil 3.14'teki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi	46
Şekil 3.14. Brunnstrom evre VI olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması	46
Şekil 3.15. Şekil 3.16'daki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi	47

Şekil 3.16. Weka programında bulunan test seçenekleri	48
Şekil 3.17. Yinelemeli sınıflandırma algoritması	49
Şekil 4.1. Linear Discriminant algoritması hata matrisi	74
Şekil 4.2. Complex Tree algoritması hata matrisi	76
Şekil 4.3. Subspace Discriminant algoritması hata matrisi	78
Şekil 4.4. RUSBoosted Trees algoritması hata matrisi	80
Şekil 4.5. Linear Discriminant algoritması hata matrisi (50 kişi)	82
Şekil 4.6. Complex Tree algoritması hata matrisi (50 kişi)	84
Şekil 4.7. Subspace Discriminant algoritması hata matrisi (50 kişi)	85
Şekil 4.8. RUSBoosted Trees algoritması hata matrisi (50 kişi)	87

SİMGELER VE KISALTMALAR

ADD	: Ayrık Dalgacık Dönüşümü
AP	: Anterior-posterior
CVR	: Classification via Regression
ÇÇDA	: Çoklu Çözünürlük Dalgacık Analizi
Db	: Daubechies
DD	: Dalgacık Dönüşümü
DN	: Doğru Negatif
DP	: Doğru Pozitif
KZFD	: Kısa Zamanlı Fourier Dönüşümü
MAE	: Mean Absolute Error
MATLAB	: MATrixLABoratory
ML	: Medio-lateral
RMS	: Root Mean Square
SDD	: Sürekli Dalgacık Dönüşümü
SP	: Serebral Palsi
SVO	: Serebrovasküler Olay
VT	: Vertikal
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
WEKA	: Waikato Environment for Knowledge Analysis

1. GİRİŞ

Hemoraji ya da iskemi nedeniyle beyin dokusunda tıkanıklığa neden olan hemipleji, genel olarak aniden başlayan, nörolojik bozukluklarla ilerleyen serebrovasküler olayların (SVO) en sık görülen bulgusudur (Karaduman ve ark., 2018). Konjenital hemipleji diye bilinen hemipleji, doğumdan önce, doğum sırasında ya da doğumdan sonra (yaklaşık iki yaşına kadar) gerçekleşir. Kazanılmış hemipleji ise inme, kaza, enfeksiyon veya tümör gibi hastalıkları takiben gerçekleşir. Vakaların yaklaşık % 80'i konjenitaldir ve %20'si sonradan kazanılmıştır (Barnesve Fairhurst, 2012).

Yapılan araştırmalar inme geçirenlerin yaklaşık olarak üçte ikisinin yardımsız ambule olamadığını, rehabilitasyon alanların ise tedaviden sonra ancak yarısının bağımsız yürüebildiğini göstermiştir (Jorgensen, ve ark., 1995).

Hemiplejik yürüyüş kavramı uzmanlar tarafından hemiplejik hastanın yürüyüşü sırasında ağır, zorlu, zayıf koordinasyonlu hareket paterni ve vücut postürü olarak ifade edilir (Kuan ve ark., 1999).

Hemiplejik hastaları değerlendirmek için bir çok yöntem bulunsa da bunlardan en sık tercih edileni ve bu çalışmada yer alan hemiplejik hastaların değerlendirilmesinde kullanılan yöntem Brunnstrom Evrelemesidir. Brunnstrom altı iyileşme evresinden oluşmaktadır. Ancak ilk iki evrede yürüme söz konusu olmadığı için çalışmaya yalnızca III., IV., V. ve VI. evredeki hemiplejik hastalar dahil edilmiştir. Hastaların Brunnstrom evresine hekim veya fizyoterapist karar vermektedir. Literatür incelendiğinde Brunnstrom evresini otomatik olarak belirlemek amacıyla yapılan çeşitli çalışmaların olduğu görülmüştür. Örneğin, Lei Yu ve arkadaşları 2012 yılında yaptıkları çalışmada inme geçiren hastaların Brunnstrom evrelerini otomatik olarak belirleyebilmek için üst ekstremitate hareket özelliklerini analiz ederek makine öğrenmesi yöntemleri ile bir model kurmuşlardır. Modelin evreleri tahmin edebilme başarısını %92 olarak belirtmişlerdir (Lei ve ark., 2012).

Bu tez çalışmasının amacı hemiplejik hastaların yürüme sinyallerinden hangi evrede olduklarını objektif bir şekilde belirleyebilmektir. Bu bağlamda yürüme ile ilgili biyomekanik özelliklerin ölçümü, analizi ve değerlendirilmesi olarak

tanımlayabileceğimiz yürüme analizi işlemi gerçekleştirilmesine ihtiyaç duyulmuştur.

İnsan yürüyüşünü incelemek için kullanılan bu teknolojik araçlar iki farklı yaklaşıma göre sınıflandırılabilir: giyilemez sensör tabanlı olanlar ve giyilebilir sensörler. Giyilemez sensör sistemleri, sensörlerin bulunduğu yerde kontrollü araştırma şartları kullanmayı gerektirir ve hasta net olarak işaretlenmiş alan üzerinde yürürken yürüyüş üzerine veri yakalar. Bunun aksine, giyilebilir sistemler laboratuvarın dışındaki verileri analiz etmeyi ve kişinin günlük aktiviteleri sırasında insan yürüyüşü hakkında bilgi toplamayı mümkün kılmaktadır. Giyilebilir sensör sistemleri ayak, diz, uyluk veya bel gibi vücudun çeşitli yerlerinde bulunan sensörleri kullanır. İnsan yürüyüşünü etkileyen çeşitli sinyalleri yakalamak için farklı türde sensörler mevcuttur. Bunlar, ivmeölçerler, jiroskopik sensörler, manyetometreler, kuvvet sensörleri, ekstensometreler, goniometreler, aktif işaretler, elektromiyografi vb. olarak sayılabilir. İvmeölçer ve jiroskop gibi giyilebilir sensörler, boyutları, maliyetleri ve biyomekanik yürüyüş verilerininin kolayca toplanabilme yeteneği göz önüne alındığında, geleneksel optik yürüyüş analiz sistemlerine göre giderek popüler hale gelmektedir.

Bu çalışmada da giyilebilir bir teknoloji olan üç eksenli ivmeölçerden alınan yürüme sinyalleri kullanılmıştır.

Günümüzde çok çeşitli sinyal işleme yöntemi bulunmaktadır ve bunlardan biri de Dalgacık Dönüşümü tekniğidir. Dalgacık Dönüşümü (DD) bir sinyalin zaman-frekans gösterimini veren matematiksel bir yöntemdir. Dalgacık dönüşümü, zaman-frekans lokalizasyonu (belirli bir zamanda ve frekansta bir sinyalin elde edilmesi veya farklı ölçeklerdeki alanlarda çeşitli konumlarda öznelik çıkarılması) ve farklı-oranlı filtreleme (çeşitli frekanslara sahip sinyalleri ayırt etme) gibi özellikleri nedeniyle sinyal işlemede etkili bir araçtır (Meyer, 1993; Samant ve Adeli, 2000).

Bu tez çalışmasının amacı doğrultusunda sinyaller Matlab programı kullanılarak Dalgacık Dönüşümü tekniği ile işlenmiş ve ardından Weka programında sınıflandırma algoritmaları ile sınıflandırılmıştır. Son olarak sınıflandırma sonuçları değerlendirilmiştir.

2. GENEL BİLGİLER

2.1. Hemipleji

Yunanca “hemi” = yarı ve “plegia” = işlev kaybı kelimelerinin birleşmesinden oluşan hemipleji, beynin zarar görmesinden kaynaklanan ve yaşam boyu sürebilen bir hastalıktır (Barnes ve Fairhurst, 2012). Bir başka tanımla hemoraji ya da iskemi nedeniyle beyin dokusunda tıkanıklığa neden olan hemipleji, genel olarak aniden başlayan, nörolojik bozukluklarla ilerleyen serebrovasküler olayların (SVO) en sık görülen bulgusudur (Karaduman ve ark., 2018). Hemipleji ve hemiparezi, her ikisi de vücudun bir tarafının zayıflığını gösterir. Hemiparezi vücudun bir tarafındaki bir kas zayıflığı (veya kısmi felç) iken hemipleji vücudun bir tarafında kol, bacak ve gövdede toplam felç anlamına gelir (Chinnabhandar ve ark., 2018).

Hemipleji, vücudun bir tarafındaki hareketi farklı seviyelerde etkiler. Ayrıca epilepsi, öğrenme zorlukları ve anksiyete gibi diğer daha az görülen etkilere neden olabilir. Her 1000 kişiden birini etkileyen hemipleji, beynin etkilenen bölümüne bağlı olarak sağ veya sol hemipleji şeklinde kendini gösterebilir. Bu durum bacakların, gövdenin ve yüzün hareketlerini kontrol eden beyin bölümünün hasarıyla ilgilidir. Genel olarak, beynin sol tarafındaki hasar sağ hemiplejiye ve sağ tarafta meydana gelen hasar sol hemiplejiye neden olur (<http://www.hemihelp.org.uk>, Erişim tarihi 12 Ekim 2018).

Hemipleji iki türlü gerçekleşebilir. Konjenital hemipleji diye bilinen hemipleji, doğumdan önce, doğum sırasında ya da doğumdan sonra (yaklaşık iki yaşına kadar) gerçekleşir. Kazanılmış hemipleji ise inme, kaza, enfeksiyon veya tümör gibi hastalıkları takiben gerçekleşir. Vakaların yaklaşık % 80'i konjenitaldir ve % 20'si sonradan kazanılmıştır (Barnes ve Fairhurst, 2012).

2.1.1. Konjenital Hemipleji

Konjenital hemipleji, yenidoğan serebral palsinin sebep olduğu bir durumdur. Genellikle zamanında doğan bebeklerde görülen konjenital hemiplejinin görülme sıklığı son yıllarda düşük kilolu prematüre bebeklerde de artmıştır. Konjenital hemiplejinin insidansının 0.41-0.79/1000 olduğu tahmin edilmektedir (Panteliadis ve ark. 2007). Vakaların 2/3'ten fazlasının sebebi beyin kanaması veya orta serebral arterin beslenme bölgesindeki serebral enfarktüstür. Bir çok vakada prenatal faktörler

perinatal faktörlerden baskın gelmektedir. Klinik bulgular genellikle bebekler 6-9 aylıkken aileler tarafından farkedilir (Neville ve Goodman, 2001).

Konjenital hemipleji ile ilişkili olarak sıklıkla epilepsi (% 27-47), mental retardasyon (% 20-45), skolyoz (% 15-30), görme bozuklukları (% 10-25), konuşma bozuklukları (% 20) veya işitme kaybı (% 3-5) gözlemlenir (Guzzetta ve ark., 2001).

2.1.2. Kazanılmış Hemipleji

İnme, serebral palsi, epilepsi, beyin dokusunun iltihaplanması, multipl skleroz, menenjit gibi hastalıklar veya kaza sonucu beynin hasar görmesi nedeniyle sonradan vücudun bir yarısında meydana gelen işlev bozuklukları kazanılmış hemipleji olarak tanımlanır.

İnme, ani başlangıçlı, vasküler nedene bağlı fokal nörolojik defisit olarak tanımlanmaktadır (Gündüz, 2006). Gelişmiş ülkelerde üçüncü en sık ölüm nedeni ve dünyada ikinci sıklıkta görülen ölüm nedeni olan inme, sık yatırılarak tedavi edilen nörolojik hastalık olması, uzun süreli özürüllüğe yol açması sebebi ile önemini korumaktadır (World Health Organization, 2018; Stinear, 2010).

İnmeli hastaların %60'dan fazlası günlük hayat faaliyetlerini zorlaştıran kalıcı nörolojik defisitlerden yakınmaktadır (Jongbloed, 1986). İnmeden sonra bağımsız olarak yaşayabilme yeteneği, büyük ölçüde motor bozukluğunun ve motor fonksiyonunun geri kazanılmasına bağlıdır. Motor geri kazanımının doğru tahmin edilmesi rehabilitasyon planlamasına yardımcı olur ve klinisyenler ile hastalar tarafından gerçekçi hedef belirlemeye yardımcı olur (Stinear, 2010).

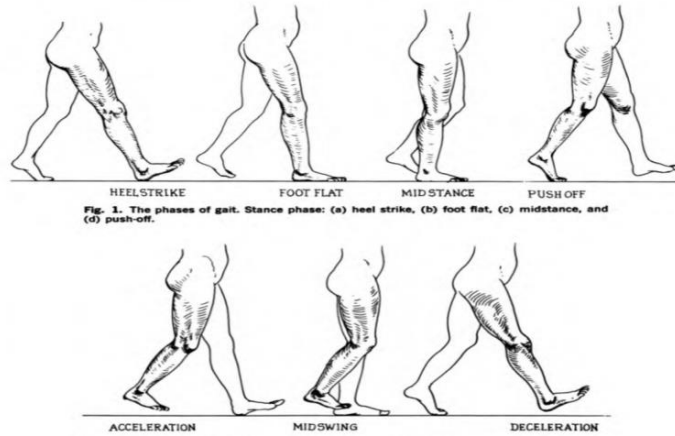
Yapılan araştırmalar inme geçirenlerin yaklaşık olarak üçte ikisinin yardımsız ambule olamadığını, rehabilitasyon alanların ise tedaviden sonra ancak yarısının bağımsız yürüebildiğini göstermiştir. Bozuk yürüme fonksiyonunun inme sonrası fonksiyonel bozuklukta katkısı büyük olup, inme geçiren hastalar tarafından en sık dile getirilen hedef daha iyi bir yürüme fonksiyonudur. Yürüme işlevinin iyileşmesi genellikle inmeden sonraki ilk 6 ay içinde ortaya çıkar. Bununla birlikte, bu 6 ayda fonksiyonel iyileşmenin tamamlandığı zaman hakkında çok az bilgi vardır ve bu

bilgiler inme rehabilitasyonu kliniğine başvuran az sayıdaki hastaya dayanmaktadır (Jorgensen, ve ark., 1995).

Serebral palsi (SP), doğumdan önce, doğum esnasında ya da doğumdan sonra meydana gelen, beyin hasarından kaynaklanan motor bozuklukların bir bütünüdür. Beyindeki hasar motor sistemi etkiler ve sonuç olarak zayıf koordinasyon, bozuk denge veya anormal hareket paternleri ya da bu özelliklerin bir kombinasyonu görülebilir (Miller ve Bachrach, 2008). Gelişmiş ülkelerde, SP prevalansı 1000 canlı doğumda yaklaşık 1.4–2.9'dur (Oskoui ve ark., 2013). Önceki çalışmalarda, araştırmacılar SP için yüksek risk faktörleri arasında doğum sırasında oksijensiz kalma, düşük doğum ağırlığı ve anne enfeksiyonu konularına dikkat çekmişlerdir (Yuan ve ark., 2018; Bearden ve ark., 2016).

2.1.3. Hemiplejik Yürüme

Yürüme, bir konumdan diğerine hareket ederken bacakların ikisinin birden, en az birinin mutlaka zemin ile temas halinde olması koşuluyla, vücudu desteklemek ve ilerletmek amacıyla kullanılmasıdır. Gövdeyi öne doğru ilerletmek amacıyla Şekil 1'deki gibi bacaklarda sürekli ve belirli bir düzende tekrarlanan hareket zincirine yürüme döngüsü adı verilir (Eser ve ark., 2004).



Şekil 2.1. Yürüme döngüsü (Hoppenfeld, 1976)

Yürüme döngüsü duruş ve salınım fazları olarak iki temel bölüme ayrılır. Normal yürüme siklusunun % 60'ı duruş evresinde geçer ve % 40'ı salınım evresindedir. Her bir evre kendi aralarında daha küçük bileşenlere ayrılmıştır (Hoppenfeld, 1976):

Tablo 2.1. Yürüme evreleri

Duruş Evresi	Salınım Evresi
Topuk temas evresi	Hızlanma evresi
Taban temas evresi	Salınım orta evresi
Duruş orta evresi	Yavaşlama evresi
Parmak temas evresi	

Hemiplejik hastaların fizyolojik aktivitelerindeki en önemli sorun yürüme bozukluğudur. Hemiplejik hastalar ayak fonksiyonları ve ayakta durmak için postüral kontrol planları gerektirir ve postüral kontrol yetersiz olduğunda fonksiyonel yürüme bozukluğu gösterirler (You ve Chung, 2015). Hemiplejik yürüyüş kavramı uzmanlar tarafından hemiplejik hastanın yürüyüşü sırasında ağır, zorlu, zayıf koordinasyonlu hareket paterni ve vücut postürü olarak ifade edilir. Perry, hemiplejik yürüyüşü gözlemiş ve hemiplejik hastaların topuk vuruşunun yetersiz, duruş sırasında dengenin kötü kontrollü, hızlanma evresini başlatmak için itme gücü oluşturmanın ve salınım sırasında etkilenmiş ekstremitenin yetersiz kaldığını belirtmiştir. Zayıf tek bacaklı dengenin yanı sıra ilerlemeyi kontrol etmenin zorluğunu hemiplejik yürüyüşte gözlenen anormalliğe yol açtığını öne sürmüştür (Kuan ve ark., 1999).

Hemiplejik yürüyüş yavaş ve asimetric adımlı, etkilenmemiş uzuvda basma fazının uzadığı, etkilenmiş kısımda basma süresinin kısaldığı ve adım aralığının azaldığı, çift ayak üzerine basma süresinin uzadığı ve gövdeyi ileri itmenin zorlaştığı bir yürüme şeklidir. Hemiplejik hastalarda yürüme bozukluğu nedenleri; selektif motor kontrol bozukluğu, kasların güçsüz olması, tonus değişikliği, bilişsel bozukluklar, koordine hareketlerin bozulması, eklem hareket açıklığının kaybı, denge kurmada yaşanan zorluk ve duyuşal geribildirim kaybıdır (Roth ve ark., 1997).

2.2. Nörofizyolojik Değerlendirme Yöntemleri

Tedavi yöntemleri ilk olarak 1940'lı yılların sonlarında geliştirilmeye başlamış ve 1950'li yılların başlarında kabul görerek tedavi ve eğitim yaklaşımlarında temel değişiklikler gözlenmeye başlanmıştır. Bu değişiklikler de nöroloji alanındaki fizyoterapi uygulamalarının gelişimine yansımıştır. İlk yaklaşımlar, Rood (1954), Kabat ve Knott (1954), Brunnstrom (1956) ve Bobath (1969)'ın çalışmalarıyla

gerçekleşmiştir. Bu yazarlar, yöntemlerini nörofizyolojik temellerin üzerine inşa etmişlerdir.

2.2.1. Rood

Merkezi sinir sistemi bozukluklarının tedavisinde Rood Yaklaşımı 1950'lerde Margaret Rood tarafından geliştirilmiştir. Rood'un tekniği, hareketin rahatlatılması ve inhibe edilmesi olarak kategorize edilebilir. Rood, nöromusküler disfonksiyonları olan hastalarda deri üstü stimülasyon ile geliştirilmiş bir terapötik egzersiz sistemi geliştirmiştir (Metcalf ve Lawes, 1998).

2.2.2. Proprioseptif Nöromusküler Fasilitasyon

Knott ve Kabat tarafından 1950'lilerde Vallejo Kaliforniya Kaiser Birliğinde geliştirilen bu yöntem eklem hareket açıklığı için yaygın bir yaklaşımdır. Bu yaklaşım öncelikle çocuklar için geliştirilmiş ancak daha sonraları hem yetişkin hem de çocuklar için nörolojik ve ortopedik bozukluklarda yaygın olarak kullanılmıştır. Proprioseptif Nöromusküler Fasilitasyon, kas esnekliğini iyileştirmek için kullanılan bir germe tekniğidir ve aktif ve pasif hareket açıklığı üzerinde olumlu bir etkiye sahip olduğu gösterilmiştir (Hindle ve ark., 2012).

2.2.3. Bobath

Bobath yaklaşımında ilk olarak 1950'lerde geliştirilmiştir. Bobath kavramı günümüzde merkezi sinir sisteminin bir lezyon nedeniyle fonksiyon, hareket ve postüral kontrol bozukluğu olan bireylerin değerlendirilmesi ve tedavisi için bir problem çözme yaklaşımı olarak tanımlanmaktadır. Kavram, görev performansını gözlemlemek, analiz etmek ve yorumlamak için bir yol sağlar. Bobath yaklaşımının klinik uygulaması, bir dizi standart teknikten ziyade bireyselleştirilmiş bir akıl yürütme süreci kullanmaktadır (Vaughan-Graham, 2009).

1970'lerde Bobath bu yöntemi refleks inhibitör postürlerle ve minder egzersizleriyle uygulamış, sonraki yıllarda (1990) tedavi yöntemlerinde değişiklikler tanımlamıştır. Statik çalışmalardan uzaklaşarak, hastanın tedavisine aktif ağırlık vermiştir. Hastanın motor problemlerine olduğu kadar duyuşal, algısal ve uyumsal davranış düzeyine de ağırlık verilerek, bir bütün halinde eğitimin sürdürülmesine dikkat çekmiştir. Bununla birlikte, yıllar boyunca esas içeriğini hiç değiştirmemiş ve esas problem olan zayıf koordinasyon ve kaybolan kas fonksiyon kontrolü üzerinde

durmak gerektiğini ısrarla belirtmiştir. Teknikleri de bu hedef doğrultusunda gelişim göstermiştir (Otman ve ark., 2001).

2.2.4. Brunnstrom

Hemiplejik hastalarda sık görülen hemiplejik tarafın ihmali Brunnstrom'un dikkatini çekerek, başlangıç noktasını oluşturmuştur. Diğer yaklaşımlarda olduğu gibi, geri dönüş aşamalarının değerlendirilmesi ilk basamağı oluşturmaktadır. Bu aşamalar, normal gelişimle paralellik gösterir ve hemiplejik hastaların bu aşamalardan herhangi birinde platoya ulaşabileceği düşünülmektedir.

Tedavinin amacı hastanın var olan hareket derecesini tayin ederek o noktadan tedaviye başlamak, reflekslerin eğitilmesiyle birlikte, kas işlevinin subkortikalden kortikale doğru ilerletmektir.

Brunnstrom hareket terapisi, klinik pratikte terapistler tarafından yaygın olarak kullanılmaktadır. Bununla birlikte, yaklaşımı uygulamak için özel bir eğitim gerekli değildir. Müdahalede kullanılan teknikler ve yöntemler "Brunnstrom'un Hemipleji Hareket Terapisi: Nörofizyolojik bir Yaklaşım" adlı kitabında verilmiştir (Pandian ve ark., 2012).

Brunnstrom hemiplejik hastaların belirli iyileşme evreleri geçirdiğini gözlemlemiş, bu evrelerin ilerleyişinin bazen hızlı bazen de yavaş olabileceğini ifade etmiştir. İyileşme süreci genellikle proksimalden distale doğru olmaktadır. Üst ekstremitede fleksör sinerji genellikle ekstansör sinerjiden önce ortaya çıkmaktadır. istemli hareketten önce refleks hareket, izole ve ince motor hareketten önce de kaba hareket ortaya çıkmaktadır.

Pek çok hastada gözlenen ve Brunnstrom tarafından tanımlanan Brunnstrom iyileşme evreleri Tablo 2.2'de gösterilmiştir.

Tablo 2.2. Brunnstrom motor iyileşme evreleri

Evre 1	Tutulmuş bacakta hiçbir hareket yoktur. Bacak tümüyle flastiktir.
Evre 2	Minimal istemli hareket mevcuttur.
Evre 3	Otururken ve ayakta kalça, diz, ayak bileği fleksiyonu istemli olarak yapılabilir. Spastisite en yüksek noktadadır.
Evre 4	Otururken ayağını arkaya koyarak 90 dereceden aşan diz fleksiyonu yapabilir. Topuğu yerden kaldırmadan ayak bileği dorsifleksiyonu yapabilir.
Evre 5	Ayakta o bacağa ağırlık vermeden izole diz fleksiyonu ile birlikte kalça ekstansiyonu, kalça ve diz ekstansiyonu ile izole ayak bileği dorsifleksiyonu yapabilir.
Evre 6	Otururken veya ayakta dururken kalça abduksiyonu, otururken ayak bileği inversiyonu ve eversiyonu ile beraber dizin resiprokal içe ve dışa rotasyonunu başarabilir.

2.3. Dalgacık Dönüşümü

Sinyal, fiziki bir büyüklüğü ya da değişkeni ifade eden bir fonksiyondur. Sinyaller, tipik olarak olgunun kendisi ya da davranışı ile ilgili bilgi verir. Sinyalleri; sürekli-ayrık, analog-dijital, gerçek-karmaşık, belirli-rastgele, tek-çift, periyodik-periyodik olmayan, enerji ve güç sinyalleri olarak gruplandırabiliriz (Öner ve ark.,2017).

Bir fiziki büyüklüğün bir ya da birden çok bağımsız değişkene göre durumunu açıklayan gözlemlere zaman serisi denir. Zaman serilerinde bağımsız değişken genellikle zamandır. Matematiksel olarak tanımlandığında (t) ye bağlı bir g(t)fonksiyonu şeklinde tanımlanır. Veriler sürekli bir şekilde kaydediliyorsa elde edilen seriler sürekli seriler, belirli aralıklarda kaydediliyorsa ayrık serilerdir. Sürekli serilerdeki veri boyutunun fazla olması sebebiyle, içinden örnekleme yapılarak ayrık diziler oluşturulur. Günümüzde, birçok fiziksel büyüklük sürekli ve ayrık sinyal olarak gösterilmekte ve bu sinyallerin analizinde yaygın olarak Dalgacık (Wavelet) analizi kullanılmaktadır (Öner ve ark., 2017).

Fourier dönüşümü, sinyalin frekans bileşenlerini analiz etmek için kullanışlı bir araçtır. En çok tercih edilen spektral analiz yöntemi olan Fourier analizi bir sinyali zaman düzleminde frekans düzlemine dönüştürür fakat frekans alanına geçildiğinde zaman alanı kaybolur. Bu problemin çözülmesi amacıyla Gabor (1946), Gabor

dönüşümüya da Kısa Zamanlı Fourier Dönüşümü (KZDF) diye isimlendirilen matematiksel dönüşümü geliştirmiştir. Kısa Zamanlı Fourier Dönüşümü, hem frekans hem de zamanla ilgili bilgi veren spektrogramı bulmak amacıyla kayan bir pencere kullanır. KZDF ile kusursuz frekans çözünürlüğü elde edilemese de düşük frekans çözünürlüğü ile kabul edilebilir ölçüde zaman çözünürlüğü sağlanır. Kısa Zamanlı Fourier Dönüşümünde yüksek ve düşük frekanslı bileşmeler için pencere fonksiyonu genişliği değiştirilemez. Sinyalin birkaç zaman-frekans gösterimi, yalnızca farklı pencere fonksiyonu genişlikleri ile Kısa Zamanlı Fourier Dönüşümünün birkaç kez tekrarlanması ile elde edilmesi mümkün olur. Ancak böyle bir analiz, zaman kaybına yol açması ve gereksiz işlemlere neden olması sebebiyle kullanışsızdır (Toprak, 2007; Chun-Lin, 2010).


Dalgacık Dönüşümü (DD) bir sinyalin zaman-frekans gösterimini veren matematiksel bir yöntemdir. DD, değişken zaman-frekans çözünürlüğü sağladığından KZFD'den üstün olarak kabul edilir. Zaman-frekans çözünürlüğü sinyal işleme uygulamalarının çoğu için büyük bir avantaj teşkil eder. Çünkü alçak frekanslar frekansta, yüksek frekanslar zamanda daha iyi çözülür (Toprak, 2007).

Dalgacıklar, sınırlı bir süreye ve 0 ortalama değere sahip 'küçük' dalgalar olarak da tanımlanabilir. Hem zaman hem de frekansta bir fonksiyonu veya bir veri kümesini lokalize edebilen dalgacıkların kökeni 1909'da Haar'ın tezine kadar uzanabilir (Daubechies, 1992). 1930'larda, matematik, fizik ve elektronik mühendisliğinde ve sismolojide bağımsız olarak ölçek değişkenli temel fonksiyonlar gelişmiştir. Dalgacık kavramı, 80'li yılların ortalarında Grossman ve Morlet (1984) tarafından tanıtılmıştır. Dalgacık dönüşümü, zaman-frekans lokalizasyonu (belirli bir zamanda ve frekansta bir sinyalin elde edilmesi veya farklı ölçeklerdeki alanlarda çeşitli konumlarda öznitelik çıkarılması) ve farklı- oranlı filtreleme (çeşitli frekanslara sahip sinyalleri ayırt etme) gibi özellikleri nedeniyle sinyal işlemede etkili bir araçtır (Meyer, 1993; Samant ve Adeli, 2000). Bu özellikleri kullanarak, zaman ve mekandaki belirli yerel özellikler ile karakterize edilen bir giriş sinyalinden istenen öznitelikleri çıkarmak mümkündür (Adeli ve ark., 2003).

DD, sinyalin zaman-frekans analizinde kullanılan matematiksel dönüşüm tekniğidir. Grossman ve Morlet' in çalışmalarındaki amaç; sismik sinyallerin salınan sonlu süreli basit bir fonksiyonun ötelenmiş ve genişletilmiş (veya daraltılmış) hallerinin


birleşimi olarak ifade edilebileceğini yani modellenebileceğini kanıtlayabilmektir. Bu çalışmaların sonucunda Sürekli Dalgacık Dönüşümü ortaya çıkarılmıştır (Toprak, 2007). İlerleyen zamanlarda dalgacık analizinin değişik sinyal türlerine de uygulanabilir bir teknik olduğu anlaşılmıştır. Gerçekleştirilen uygulamalarda sinyallerde süreksizlik tanısında ve sinyalden gürültü arındırmada DD'den önemli derecede faydalanılmıştır (Taswell, 1999). Dalgacık dönüşümü, isminden de anlaşılacağı üzere dalgacıklar yardımı ile yapılmaktadır. KZDF'de olduğu gibi DD'de de pencere işlevini ana dalgacık adı verilen fonksiyon üstlenir. Ancak bu ana dalgacık dönüşüm boyunca ölçeklenir ve ötelenir. Dalganın genişletilip daraltılmasına ölçekleme; zaman ekseninde kaydırılmasına öteleme denir (Öner ve ark., 2017).

Pencere fonksiyonunun genişliği dönüştürme süresince Kısa Zamanlı Fourier Dönüşümünde sabit kalır. Buna karşın, dalgacık dönüşümünde sürekli değiştiği için, zaman ve frekans alanının çözünürlüğü artar. Dalgacık dönüşümünün Fourier dönüşümünden üstünlüğü buradan gelmektedir. KZFD, zaman-frekans alanını kullanırken, Dalgacık dönüşümü zaman-ölçek domenini kullanmaktadır. Şekil 2.2'de DD ile sinyaldeki ölçek ve zaman değişimi görülmektedir (Öner ve ark., 2017).



Şekil 2.2. Dalgacık dönüşümünde zaman-ölçek alanı

Öte yandan Şekil 2.3'te dalgacık dönüşümü, Fourier ve KZF'nin zaman-frekans alanında çözünürlükleri görülmektedir. Özetleyecek olursak, Fourier dönüşümü frekans bilgisini verirken frekansların zaman bilgisini vermez. Kısa Zamanlı Fourier Dönüşümünde zaman-frekans çözünürlüğü sabit olup zaman penceresi her frekansta değişmez büyüklüktedir. DD'de ise bu çözünürlük ayarlanabilir özelliktedir (Öner ve ark., 2017).



Şekil 2.3. Dönüşümlerin zaman-frekans çözünürlüğü bakımından karşılaştırılması

Dalgacık dönüşümünde farklı pencere genişlikleri, skala faktörünün değiştirilmesi ile, “ana dalgacık fonksiyonu” denilen tek bir fonksiyon ile gerçekleştirilir. Dalgacık dönüşümündeki temel fonksiyonlar ‘dalgacıklar’ olarak isimlendirilir (Toprak, 2007). Fonksiyonun dalgacık olarak adlandırılabilmesi için ortalama değerinin sıfır ve süresinin sınırlı olması gerekmektedir. Dalgacık fonksiyonu genlik ekseninin negatif ve pozitif yönleri boyunca salınım yapmalıdır. Bu salınım, zaman eksenini boyunca ilerlerken genlik ekseninde sifıra oturarak sonlanmalıdır. Dalga ve dalgacık kavramlarının farkı kosinüs ve sinüs gibi dalga fonksiyonlarının genlik ekseninde $\pm\infty$ arasında sürekli salınım yapıp sonsuz süreye sahip olması ile açıklanabilir. Farklı amaçlar için kullanılacak ve farklı özelliklere sahip olan birçok ana dalgacık vardır. Dalgacık, küçük dalga anlamındadır ki buradaki “küçüklük” belirli uzunlukta pencere fonksiyonu şeklinde ifade edilebilir. Dalgacığı nitelik açısından ifade edecek olursak aşağıda yer alan iki eşitliği sağlayan bir gerçek değerli $\psi(x)$ fonksiyonu olmalıdır (Öner ve ark., 2017).

$$\int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (1)$$


$$\int_{-\infty}^{+\infty} \psi^2(x) dx = 1 \quad (2)$$

Bu koşulları sağlayan her $\psi(x)$ fonksiyonuna dalgacık diyebiliriz. Haar dalgacığı en yaygın olarak bilinen dalgacıktır ve bu dalgacığın dalgacık fonksiyonu Denklem 3’te ve ölçek fonksiyonu Şekil 2.4’te verilmiştir (Altay, 2010).

$$\psi(x) = 1 \quad 0 \leq x < 1/2$$


$$\psi(x) = -1 \quad 1/2 \leq x < 1 \quad (3)$$

$$\psi(x)=0 \quad x \notin [0,1]$$



Şekil 2.4. Haar dalgacığının ölçek fonksiyonu

Şekil 2.5'te verilen ana dalgacık fonksiyonları DD'de kullanılır. Ana dalgacıkların genlik ekseninde salınım yaparak sıfıra oturduğu görülmektedir.



Şekil 2.5. Örnek dalgacık operatörleri (Fugal2009)

DD'de ölçek parametresi 'a' ile ifade edilir. Bu parametre frekans ile ilişkilidir. Küçük ölçekler yüksek frekanslara; büyük ölçekler de düşük frekanslara karşılık gelirler. DD ile sinyal analizi yaparken ölçek küçük değerli kullanılır ise üzerinde

çalışılan sinyalde bulunan yüksek frekanslı bileşenler daha kolay bir şekilde ayırt edilebilirler. Bu durumun aksine ölçek büyük değerde ise düşük frekanslı sinyaller daha rahat ayırt edilebilirler (Öner ve ark., 2017).

Farklı genişlikteki temel fonksiyonları, sonlu enerjiye sahip olan ve ortalaması sıfıra denk olan Ana Dalgacık fonksiyonu $\psi(t)$ ' in ötelenip ölçeklendirilmesi ile uygun genişlik ve zaman aralığında meydana getirilirler. Temel fonksiyonların matematiksel gösterimi Denklem 4'teki gibidir (Toprak, 2007).


$$\psi_{s,u} = \frac{1}{|\sqrt{s}|} \psi\left(\frac{t-u}{s}\right), s, u \in \mathbb{R} \quad (4)$$

s ölçeklendirme değişkeni, haritalardaki ölçek gibidir. Düşük ölçekler detaylı; yüksek ölçekler ise genel görünüm için elverişlidir. Ölçeklendirme, bir sinyalin zaman-genlik gösterimini genişleten ya da daraltan bir dönüşüm tekniğidir ve matematiksel olarak belirtmek gerekirse; $f(t)$ sinyal ise $f(st)$ sinyalin ölçeklendirilmiş halidir. Büyük ölçek, sinyali genişletmek; küçük ölçek değeri ise sinyali daraltmak için uygundur. s ölçeklendirme değişkenine, $0 < s < 1$ arasında değerler verirsek sinyali genişletmiş, $s > 1$ değeri verirsek sinyali daraltmış oluruz (Toprak, 2007).

u öteleme parametresi, pencere fonksiyonunun sinyal üzerindeki yerini değiştirir. Yani pencerenin sinyal boyunca zaman ekseninde hareket etmesini sağlar. u öteleme parametresi aynı zamanda, dönüşüm alanında zaman ile ilgili bilgi verir (Toprak, 2007).

Normalizasyon çarpanı olan $\frac{1}{\sqrt{s}}$ ile Ana Dalgacık fonksiyonundan elde edilen pencere fonksiyonlarının enerjisi ile Ana Dalgacık fonksiyonunun enerjisinin aynı olması sağlanır (Toprak, 2007).

Kısaca özetlemek gerekirse, ölçekleme parametresi ana dalgacığı daraltıp genişleterek şekil olarak değiştirir; öteleme parametresi ise zaman ekseninde kaydırarak yerinin değişmesini sağlar. Ölçekleme ve öteleme esnasında ana dalgacığın enerjisi korunur. Yani bir ana dalgacığın başlangıçtaki enerjisi, ölçekleme ve öteleme uygulamasının değişmez (Altay, 2010).



Şekil 2.6. Ana sinyali oluşturan ötelenmiş ve ölçeklenmiş dalgacıkların gösterimi

Dalgacık analiz yöntemleri, fizikten tıba, hızla artan sayıda uygulama alanları bulmaktadır. Özellikle, spektral karakteristikleri zamanla değişmekte olan durağan olmayan sinyallerin analizi için güçlü bir alternatif haline gelmiştir. Bu, istatistiksel özelliklerinin çoğunun durağan olmaması nedeniyle biyolojik sinyal analizinde çok önemlidir. Bu nedenle, pratikte, dalgacık dönüşümü yöntemi, zaman içinde yakın olarak bulunan kısa süreli, yüksek frekanslı bileşenlerin yanı sıra frekansta yakın aralıklı uzun süreli bileşenlerden oluşan biyolojik sinyallerin analizi için uygundur (Sekine ve ark., 2002).

Dalgacık dönüşümünün iki türü vardır: Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD). SDD’de de ölçeklendirme ve dönüşüm parametreleri devamlı değiştiğinden tüm ölçekler için dalgacık katsayılarının elde edilmesi zaman alıcı ve zordur. Bundan dolayı, daha çok ADD tercih edilmektedir (Toprak, 2007).

2.3.1. Sürekli Dalgacık Dönüşümü

SDD, dalgacık fonksiyonunun kaydırılıp bir ölçek ile çarpılmasından sonra, zaman domeni boyunca toplanmasıyla elde edilir (Öner ve ark., 2017).

SDD’de dönüştürülecek $x(t)$ sinyali için ilk olarak uygun bir ana dalgacığa karar verilir ve bu ana dalgacık dönüşümde kullanılacak pencerelerin temelini oluşturur. Yani, farklı konum ve şekilde pencereler elde edebilmek için ana dalgacık dönüştürme boyunca ölçeklenip ötelenir. İkinci işlem olarak, dönüşüm katsayılarının hesaplanmasına (çoğunlukla $a = 1$ ölçeği ile) başlanır. SDD aslında 1’den büyük bütün ölçek değerleri için hesaplanabilir, ama sinyale bağlı olarak bu işleme çoğunlukla ihtiyaç duyulmaz. Pratikte karşılaşılan sinyallerin genellikle sınırlı bant genişliği olduğundan, dönüşüm işlemi de belirli bir ölçek aralığında gerçekleştirilmektedir (Altay, 2010).

Ana dalgacık fonksiyonu analiz sırasında, başta $a = 1$ ölçeği için sinyalin başlangıcına yerleştirilir ve ana dalgacık fonksiyonunu bu sinyal ile

çarparak $\pm\infty$ arasında olması koşulu ile integral hesabı yapılır. Sinyal enerjisinin her ölçekte sabit kalması istenir. Bu amaçla bulunan integral çıktısı $|a|^{-1/2}$ terimi ile çarpılır. Böylelikle $t = 0$ anında ve $a = 1$ ölçeğindeki ilk dalgacık katsayısı hesaplanmış olur. Daha sonra bu dalgacığın $t = b$ anına kadar zaman ekseninde kaydırılması için b öteleme parametresi kullanılır. İşlem tekrar edilerek $t = b$ anına denk gelen $a = 1$ ölçeğindeki bir sonraki dalgacık katsayısı bulunur. Sinyal sonlanana kadar bu işlem sürdürülür. Tüm bu hesaplar ile elde edilen çıktılar $a = 1$ ölçeğinin dalgacık katsayılarıdır. Hesaplamalar a ölçek değeri arttırılarak tekrar edilir. Belirlenen seviyeye kadar ölçeği arttırmaya devam edilebilir. Bu işlemde önemli nokta, büyük ölçek değerlerinde küçük frekanslı bileşenler incelenirken küçük ölçek değerlerinde yüksek frekanslı bileşenlerin incelenmesidir (Altay, 2010).

2.3.2. Ayrık Dalgacık Dönüşümü

Ayrık dalgacık dönüşümü, SDD ile aynı mantık ile çalışır, fakat dalgacık dönüşümünü farklı bir yöntemle yapmaktadır. SDD'deki dalgacık fonksiyonunun ölçeklendirilip ötelenmesi işi ADD'de, yüksek geçişli ve alçak geçişli filtreler aracılığı ile yapılır. Bu durum sinyalin ayrık veri noktaları olarak, diğer bir deyişle dijital olarak depolanıp işlenmesinin sonucudur. Bu nedenle, sinyal işleme, görüntü işleme ve sayısal analiz gibi alanlarda ayrık dalgacık dönüşümü tercih edilmektedir. Ayrık dalgacık dönüşümü, dijital olarak toplanan verilerin, dönüşüm sonrası katsayıları matrislerle ifade edilebilen, gürültüden temizleme, sıkıştırma gibi işlemlerin yapılabilmesine olanak sağlayan dalgacık dönüşümü tipidir (Demren, 2015).

SDD bir sinyale uygulandığında sinyalden elde edilen dalgacık katsayıları, sinyali inceleme ve tekrar ters DD ile geri dönüştürme işlemi için fazla uzun ve gereksizdir. Bu nedenle ADD'ye gereksinim duyulmuştur (Altay, 2010; Toprak 2007).

Ayrık dalgacık dönüşümü, a_1 ölçeğinde N_1 örnekleme frekansı ile örneklenmiş olan bir sinyalin, a_2 ölçeğinde N_2 örnekleme frekansı ile örneklenebilir olduğu temeline dayanır. a_1 ölçeğinin f_1 frekansına, a_2 ölçeğinin de f_2 frekansına denk geldiğini ve $a_1 < a_2$ ($f_1 > f_2$) olarak düşünersek N_1 ve N_2 'nin ilişkisi

$$N_2 = \frac{a_1}{a_2} N_1 \text{ ya da } N_2 = \frac{f_2}{f_1} N_1 \quad (5)$$

olarak tanımlanabilir. Bu eşitlikten de anlaşılacağı üzere küçük frekanslarda örnekleme frekansının daha düşük belirlenebileceğini söyleyebiliriz. Ancak Nyquist¹ örnekleme teoremine sadık kalınması gerekir.

ADD'de ölçekleme parametresi çoğunlukla $a = 2m$ olacak şekilde (2, 4, 6, 8, 16, 32, ...) yani diydik logaritmik artırılır. Bununla birlikte öteleme parametresi $b = n.2m$ olarak seçilir. Böylelikle ADD tekniği uygulanan sinyalden alınan dalgacık katsayıları indirgenmiş olduğu için hem zaman tasarrufu hem de az hesaplama yapılmış olur (Altay, 2010).

Sürekli öteleme ve genişleme parametrelerinin yerine,

$$a = a_0^m, b = nb_0 a_0^m \quad (6)$$

şeklindeki ayrık parametreler tanımlanabilir. Bu ifadede a_0, b_0 sabit sayılar olup, $a_0 > 1, b_0 > 0$ koşullarını sağlar. Bununla birlikte m, n değerleri de, Z tam sayılar kümesinin elemanlarıdır. Denklem 7'de ayrıklaştırılmış ana dalgacık eşitliği verilmiştir.

$$\Psi_{m,n}(t) = a_0^{-m/2} \Psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (7)$$

Buradan hareketle ayrık parametrelili DD, Denklem 8'de tanımlanmıştır.

$$ADD_{\Psi} x(m, n) = \int_{-\infty}^{\infty} x(t) \Psi_{m,n}^*(t) dt \quad (8)$$

$L^2(R)$ sonlu enerjili sinyaller için bir vektör uzayını ifade ederken, a_0 ve b_0 'ın uygun seçimi ile ana dalgacık ailesi $L^2(R)$ 'nin ortonormal bazını oluşturur. a_0 'ın ve b_0 'ın uygun seçimleri $a_0 = 2$ ve $b_0 = 1$ için DD, diadik-ortonormal DD olarak adlandırılır. Böyle bir ortonormal bazın dikkat çeken niteliklerinden birisi ise a_0 ve b_0 'ın o şekilde seçilmesi ile sinyali farklı zaman ve frekans çözünürlüğü olan ölçeklere ayrıştırmamızı sağlayan ve Çoklu Çözünürlük Dalgacık Analizi (ÇÇDA) adı verilen algoritmanın kullanılabilir olmasıdır. $c_0(n)$, fiziki bir ölçme cihazı ile elde edilen bir ayrık zaman sinyali olur ise; Bu sinyali, detay ve yaklaşım diye adlandırılan iki ayrı frekans aralığına ayrıştırmak mümkündür. Bu anlamda çoklu çözünürlük sinyal ayrıştırma tekniğini kullanarak bir seviyeli olarak ayrıştırılan sinyaller $c_1(n)$ ve $d_1(n)$

¹Örnekleme frekansının örnekleme yapılacak maksimum frekansın en az iki katı olması gerektiğini belirten teorem (Fidan & Bodur, 2013)

olur ve $c_1(n)$, orijinal sinyalin yaklaşım gösterimini ve $d_1(n)$, sinyalin DD halindeki detay gösterimini verir.

Bunlar sırasıyla denklem 9 ve 10'da gösterilmiştir.

$$c_1(n) = \sum_k h(k - 2n)c_0(k) \quad (9)$$


$$d_1(n) = \sum_k g(k - 2n)c_0(k) \quad (10)$$

Denklemlerde $h(n)$ ve $g(n)$ katsayıları, $c_0(n)$ 'i, $c_1(n)$ yaklaşım ve $d_1(n)$ detay sinyale ayırıştırıran birleşik süzgeç katsayılarıdır. Devamındaki ölçek ayırıştırmasında ise, yine $c_1(n)$ sinyali baz alınır ve 2. seviye ayırıştırılmış sinyale ait detay ve yaklaşım katsayıları aşağıdaki gibi tanımlanır:

$$c_2(n) = \sum_k h(k - 2n)c_1(k) \quad (11)$$

$$d_2(n) = \sum_k g(k - 2n)c_1(k) \quad (12)$$

Böylelikle daha ileriki seviyelerdeki ölçeklerin ayırıştırılmalarına da benzer şekilde devam edilebilir. İki seviyeli ÇÇDA tekniğinin uygulanması Şekil 2.7'de sunulmuştur (Altay, 2010).



Şekil 2.7. $c_0(n)$ ana sinyalinin iki ölçeğe ayırıştırılması

Ayrık dalgacık dönüşümü, şekli piramite benzeyen bir algoritma ile pratik uygulamalarda iki adımı olan bir işlem olarak gerçekleştirilebilen ayrık konvolüsyon² denklemidir. Ayrık sinyalin, sayısal alçak geçiren ve yüksek geçiren filtrelerle uygulanması işlemin ilk adımıdır. Yani ayrık sinyal dizisinin, alçak ve yüksek


²Konvolüsyon, birim dürtü yanıtı $h(t)$ olarak bilinen bir sistemin, $x(t)$ giriş işaretine karşılık üreteceği $y(t)$ çıkış işaretini zaman domeninde bulmaya yarayan bir işlemdir.

geçiren filtrelerin impuls cevapları ile ayrı ayrı konvolüsyonu alınır. Konvolüsyonun sonunda, bir başka deyişle filtrelerin çıkışında bulunan diziler, seyrek örnekleme ile baştan başlayarak her iki dizi elemanın yalnızca baştaki elemanı alınarak, eleman sayıları yarıya indirilir. Bu işlem aşağıya doğru örnekleme olarak da adlandırılır. Böylelikle konvolüsyon sonucunda alınan sinyal dizilerinin eleman sayılarının toplamı ile ayırık sinyalin eleman sayısı toplamı eşit olur. Bu işlem dönüşümün en önemli adımıdır. İlk bakışta seyrek örnekleme işleminin bilgi kaybına yol açtığı düşünülebilir ama bu işlem ile dönüşüm sonunda elde edilen lüzumsuz bilgiler arındırılır böylelikle DD kullanışlı bir hale getirilmiş olur (Toprak, 2007).

ADD ile bir sinyal spektrumu, alçak frekanstan yüksek frekanslara doğru peş peşe frekans bandlarına ayrıştırılır. Ayrıştırmanın ilk basamağında işleme tabi tutulan alçak frekans bandı sinyalin spektrumudur. Sinyalin sonlu enerjiye sahip olması gerektiği unutulmamalıdır (Toprak, 2007).

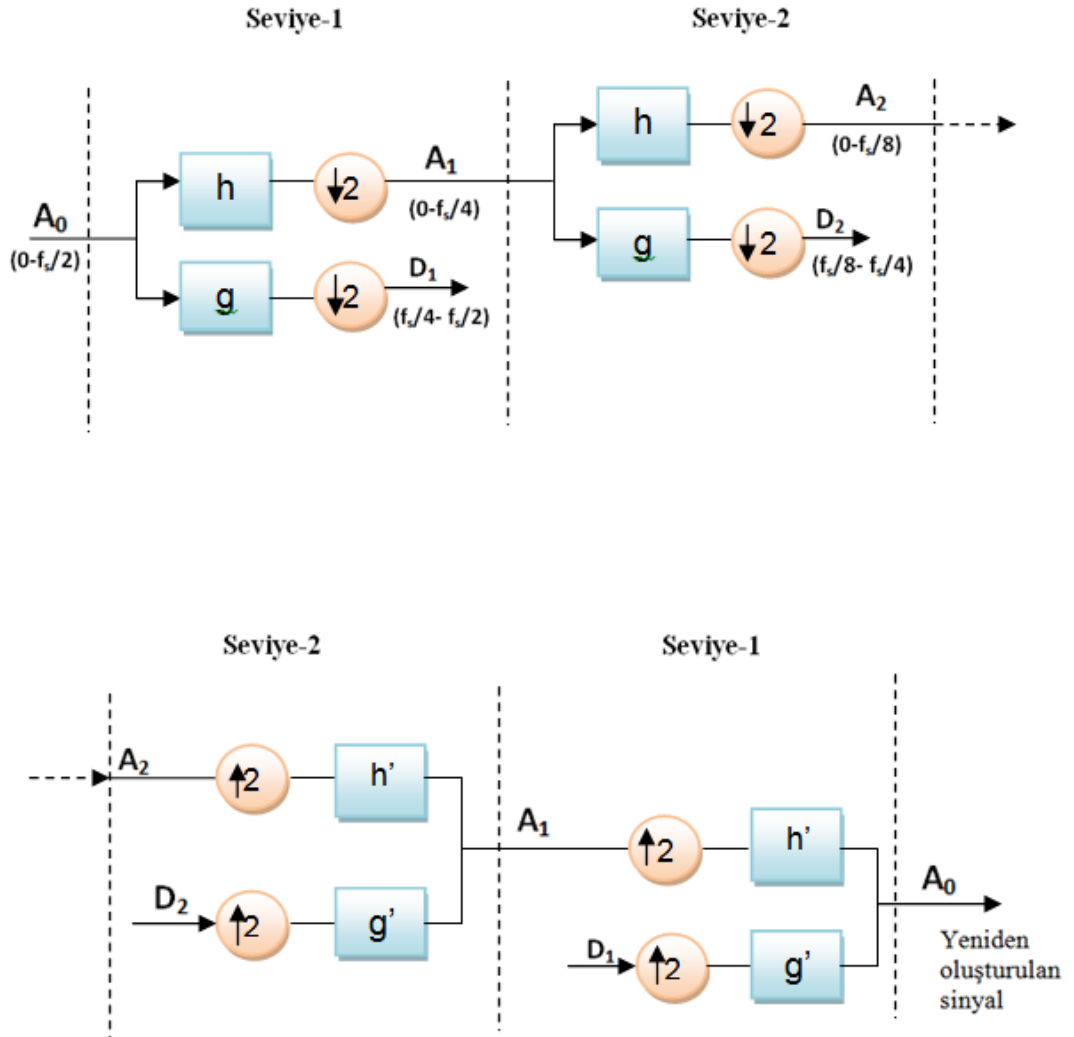
Belirtildiği üzere ADD tekniği kullanılarak sinyali, kendisini meydana getiren frekans bandlarına ayırmak mümkündür. Bu frekans bandları olan yaklaşım ve detay katsayılarını birleştirilerek gerçek sinyali tekrar elde etmek de mümkündür. Sinyalden gürültü temizleme maksadı ile ADD tekniği ile ana sinyal alt frekans bandlarına ayrıştırılır. Gürültüyü meydana getiren yüksek frekans bileşenleri eşikleme yöntemi ile ayrıştırılarak tekrar birleştirmeye sokulmaz. Bu yolla yeni sinyalin içindeki fazlalık olan yüksek frekans bileşenleri eşiklenerek ayrılmış olur (Altay, 2010).

Fourier teorisinde olduğu gibi, zaman ekseninde daraltma, frekans boyutunda genişlemeye ve yukarı doğru kaymaya karşılık gelir ve bunun tersini söylemek de mümkündür. Yani $\psi(t/a)$ fonksiyonunun Fourier dönüşümü $\psi(a\omega)$ ve $\psi(at)$ fonksiyonunun Fourier dönüşümü $\psi(\omega/a)$ 'dir. Şekil 2.8'de bir dalgacığa ait değişen ölçekler için frekans bantları gösterilmektedir.



Şekil 2.8. Dalgacıklar için frekans spektrumları (ψ_1 en küçük ölçek)

A_0 ana sinyalinin iki seviyeli olarak ayrıştırılması ve tekrar birleştirilmesi Şekil 2.9'da göstermektedir. Burada A_1 ve A_2 sırasıyla 1. seviye ve 2. seviye için yaklaşım katsayılarını, D_1 ve D_2 detay katsayılarını, f_s örnekleme frekansını gösterir (Altay, 2010).




Şekil 2.9. Sinyalin iki seviyeli ayrıştırılması ve birleştirilmesi

Buradaki “h” ifadesi yüksek geçiren ayrıştırma süzgecini; “h” ise yüksek geçiren birleşimsüzgecini ifade ederken “g” alçak geçiren ayrıştırma süzgecini ve “g” alçak geçiren birleşim süzgecini ifade etmektedir.

ÇÇDA’da yüksek ve alçak geçiren olmak üzere sinyal öncelikle ayrıştırma süzgeçlerinden geçirilir. Süzgeçleme işleminin ardından aşağı örnekleme (down sampling) ile sinyali meydana getiren ayrık veri sayıları ikiye bölünür (Şekil


2.10).Bu bölüm ayrıştırma bölümü olup yaklaşım katsayıları (cA_1) ve detay katsayıları (cD_1) bulunmuş olur. Diğer bir işlem olan birleştirmede ise sinyaller öncelikle yukarı örnekleme (upsampling) ile veri sayısı ikiye katlanır. Ardından detay ile yaklaşımlar yüksek ve alçak geçiren birleştirme süzgeçlerinden geçirilerek sinyalin D_1 detay, A_1 yaklaşım olmak üzere bileşenleri elde edilmiş olur. A_1 ve D_1 toplanarak yeniden oluşturulan ana sinyal elde edilir(Altay, 2010).



Şekil 2.10. Aşağı örnekleme

2.3.3. Dalgacık Operatörleri

Dalgacıklar ölçekleme fonksiyonunun varlığı, ortogonal olup olmama, simetrik olup olmama, daraltma işleminde fayda sağlayan momentlerin sayısı gibi özellikleri ile sınıflandırılabilirler (Duran, 2013). Dalgacıklardaki en temel ayırım dönüşümlerde olduğu gibi “Ayrık Dalgacıklar” ve “Sürekli Dalgacıklar” şeklindedir. Sürekli dalgacıklar içinde Haar, Daubechies, Symlets, Coiflets, Biorthogonal, Gauss, Mexican Hat, Morlet, Meyer, Shannon dalgacıkları sayılabilir. Bunlardan Haar, Daubechies, Symlets, Coiflets, Biorthogonal ayrık dalgacık dönüşümüne de uygun olan dalgacıklardır. Ayrık ve Sürekli dalgacıkların sınıflandırılması şekil 2.11’de verilmiştir (Demren, 2015).



Şekil 2.11. Dalgacıkların Ayrık ve Sürekli olarak sınıflandırılması

En sık kullanılan dalgacıklardan bazıları aşağıda tanıtılmıştır.

Haar Dalgacı


1909'da Alfred Haar tarafından bulunmuş olan bu dalgacık bilindiği kadarıyla en eski ve en basit dalgacık tipidir. Haar dalgacı, Daubechies dalgacıklarının özel bir halidir. En az birleşme noktasına sahip, yani birinci derecedeki Daubechies dalgacıdır. Ölçekleme fonksiyonu $\phi=1$ olan Haar dalgacığının dalgacık fonksiyonu aşağıda eşitlik 13'te gösterilmiştir (Demren, 2015; Duran, 2013).

$$\psi(t) = \begin{cases} -1, & \text{eğer } 0 \leq t < \frac{1}{2} \\ 1, & \text{eğer } \frac{1}{2} \leq t < 1 \\ 0, & \text{diğer durumlarda} \end{cases} \quad (13)$$

Bu ifadeyi, belli bir aralıkta sürekli fonksiyonlar için yapılan bir çoklu çözünürlük yaklaşımı ile elde etmek mümkündür. Ölçeklendirme fonksiyonu $\phi=1_{[0,1]}$ iken ve $h[n]$ filtresi $2^{-1/2}$ ye eşit $n=0$ ve $n=1$ 'de olmak üzere 2 adet sıfırdan farklı katsayıya sahip iken aşağıdaki işlemler yapılarak Haar dalgacığına ulaşılabilir.

$$\frac{1}{\sqrt{2}}\psi\left(\frac{t}{2}\right) = \sum_{n=-\infty}^{\infty} (-1)^{1-n} h[1-n]\phi(t-n) = \frac{1}{\sqrt{2}}(\phi(t-1) - \phi(t)) \quad (14)$$

Haar Dalgacığının ölçek fonksiyonunun gösterimi şekil 2.12'de verilmiştir.



Şekil 2.12. Haar Dalgacığının ölçek fonksiyon gösterimi

Haar dalgacığının avantajları şu şekildedir:

- Kavramsal olarak basit
- Hızlı
- Etkili bir hafızaya sahip
- Diğer dalgacık dönüşümleri ile ilgili bir sorun olan kenar efektleri olmadan tam tersine çevrilebilir (Elfouly ve ark., 2008).

Haar dalgacığının dezavantajı ise sadece bir adet birleşme noktası olduğu için, düzgün ve yumuşak geçişli fonksiyonlar için pek uygun bir sinyal temsili oluşturamamasıdır (Demren, 2015).

Daubechies Dalgacık Ailesi

1990'da Ingrid Daubechies tarafından üretilen Daubechies (Db) dalgacıkları, en sık kullanılan ve dalgacık dönüşümünün popüler bir yöntem olmasını sağlayan dalgacıklardır. Daubechies dalgacıklarının isimleri dereceleri ile ifade edilir. Örneğin 5. derece Daubechies dalgacığı Daubechies 5 dalgacığıdır ve db5 olarak ifade edilir. Bu dalgacıkların derecesi, birleşme noktalarının sayısıdır. Daubechies dalgacık ailesi, verilen bir derece için, en küçük desteğe sahip dalgacıkların ailesidir (Demren, 2015).

Db dalgacığı, Haar dalgacığı ile kıyaslandığında daha karmaşık ve çok daha uzun hesaplamalar gerektirdiği görülmektedir (Elfouly ve ark., 2008).


Db dalgacığının ölçekleme ve dalgacık fonksiyonlarının matematiksel ifadesi 15 ve 16'da verilmiştir (Duran, 2013).

$$\phi(t) = \sqrt{2} \sum_k h_k \phi(2t - k) \quad (15)$$

$$\psi(t) = \sqrt{2} \sum_k g_k \phi(2t - k) \quad (16)$$

Db dalgacığı, yoğun desteğe sahip dalgacık fonksiyonunun sıfıra yaklaşan momentlerinin sayısı ile ilgilidir. Sıfıra yaklaşan momentlerin miktarı filtre uzunluğunun $\frac{1}{2}$ 'sine eşittir. Örnek olarak Haar dalgacığının sıfıra yaklaşan moment sayısı bir iken Db4 dalgacığının sıfıra yaklaşan momentlerinin sayısı 8'dir. (Duran, 2013).

Daubechies1 (db1) dalgacığı, Haar dalgacığı ile aynıdır. Daubechies ailesinin sonraki dokuz üyesinin dalgacık işlevleri Şekil 2.13'te gösterilmiştir (Misiti ve ark., 2009).



Şekil 2.13. Daubechies dalgacık ailesi

Daubechies dalgacık ailesi ortogonal ve biortogonal olabilmektedir. Ölçeklendirme fonksiyonuna sahip olan Db dalgacık ailesi hem sürekli dönüşüme hem de ADD'ye uygundur. Verilen bir birleşme noktası sayısı N için, olabilecek en küçük desteğe $2N-1$ sahip dalgacıklar ailesidir. Db dalgacıkları simetrik olmayıp filtre genişliği $2N'$ dir.


Morlet Dalgacığı

Jeofizikçi Jean Morlet'in Gabor dönüşümünü Grossman ile birlikte değiştirerek kullanması sonucu ortaya çıkan Morlet dalgacığına ait bir ölçeklendirme fonksiyonu

bulunmamaktadır ve bu dalgacık ortogonal değildir. Morlet dalgacığının fonksiyonu Denklem (17) de verilmiştir (Demren, 2015).

$$\psi(x) = \frac{1}{\sqrt[4]{\pi}} \cos\left(x\pi \sqrt{\frac{2}{\log(2)}}\right) e^{\left(-\frac{x^2}{2}\right)} \quad (17)$$

Morlet dalgacık fonksiyonunun görünümü ise Şekil 2.14’te gösterilmiştir.



Şekil 2.14. Morlet Dalgacık fonksiyonu

Morlet Dalgacık fonksiyonun genel özelliklerini özetlemek gerekirse:


- Ölçeklendirme fonksiyonu yoktur.
- Ortogonal ya da biortogonal değildir.
- Yalnızca sürekli dönüşüme uygundur.
- Simetriktir.
- Desteği küçük değildir ve -4 ile 4 arasında etkilidir (Demren, 2015).

Meksika Şapkası (Mexican Hat) Dalgacı

İsmini şeklinin Meksika şapkası “sombbrero”ya benzemesinden alan bu dalgacık Gauss ailesinin ikinci dereceden dalgacıdır. Simetrik olup ortogonal ya da biortogonal değildir. Morlet dalgacığında olduğu gibi ölçek fonksiyonları olmadığından sadece sürekli dalgacık dönüşümü yapabilirler. Mexican-Hat dalgacı teorik olarak Denklem (18) deki gibidir (Duran, 2013; Demren, 2015).

$$\psi(x) = \frac{2}{\sqrt{3}} \pi^{-\frac{1}{4}} (1 - t^2) e^{\left(-\frac{x^2}{2}\right)} \quad (18)$$

Meksika şapkası dalgacığının görünümü Şekil 2.15'teki gibidir.




Şekil 2.15. Meksika Şapkası dalgacığının görünümü

Meyer Dalgacı

Yves Meyer tarafından üretilen ve frekans uzayında tanımlı olan Meyer dalgacıkları ortonormal dalgacıklar olup simetriktir. Sonsuz türevlenebilirler ve süreklidirler. Desteği sonsuzdur ancak etkili olduğu aralık $[-8,8]$ arasındadır.

Meyer dalgacı Şekil 2.16'daki gibi gözükmetedir (Duran, 2013; Demren, 2015).

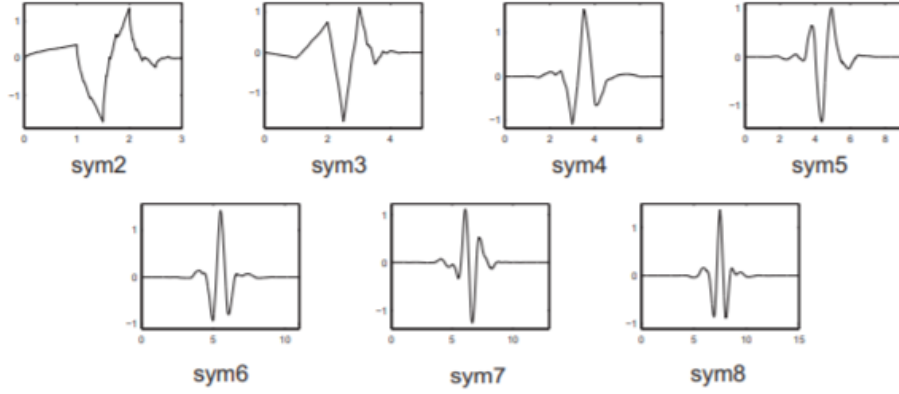


Şekil 2.16. Meyer ölçeklendirme ve dalgacık fonksiyonu

Symlet Dalgacıkları

Daubechies tarafından üretilmiş olup, Daubechies dalgacıklarının neredeyse simetrik halidir. Simetrik dalgacıklarla işlem görüntü işleme, veri sıkıştırma gibi bazı uygulamalarda ise önem arz etmektedir. Ürettiği dalgacıklarda bu sorunu gören Daubechies, daha simetrik ama yine küçük destekli bir dalgacık üretme ihtiyacı duymuştur. Simetrik olmanın dezavantajı ise, sinyalin ayrıştırılması sonrasında mutlak şekilde yeniden oluşturulmasının her zaman mümkün olmayışıdır. Symlet Dalgacıkları ortogondur ve N derece olduğunda uzunlukları $2N-1$ 'dir. Sürekli ve ayrık dalgacık dönüşümünde kullanılabilir. Kısa yazılışı 'sym' şeklindedir (Duran, 2013; Demren, 2015).


Symlet dalgacıkları şekil 2.17'de gösterilmiştir.



Şekil 2.17. Symlet dalgacık ailesi

Coiflet Dalgacıkları

I. Daubechies tarafından R. Coifman'ın talebi üzerine türetilmişlerdir. N , Coiflet dalgacığının derecesi olmak üzere dalgacığın uzunluğu $6N-1$ 'dir. Bu dalgacık ayrık ve sürekli dalgacık dönüşümü için uygun olup Şekil 2.18'deki gibi gözükmetedir (Misiti ve ark., 2009; Duran, 2013).



Şekil 2.18. Coiflet dalgacıkları

2.4. Makine Öğrenmesi

Son yıllarda Makine Öğrenimi, bilişim teknolojisinin temellerini oluşturan yöntemlerden biri olmuştur ve bununla birlikte, hayatımızın genellikle gizli olan bir parçası olmakla birlikte, oldukça merkezi bir yapı haline gelmiştir (Smola ve Vishwanathan, 2008).

Makine öğrenimi terimi, verilerdeki anlamlı kalıpların otomatik olarak algılanması anlamına gelir (Shwartz ve David, 2014). Başka bir deyişle makine öğrenmesi genel olarak, bir probleme ait veriyi kullanarak o problemi modelleyen bilgisayar algoritmalarını ifade etmektedir (Atalay ve Çelik, 2017). Makine öğrenmesi ile bilgisayara eski örneklerden edinilmiş tecrübelerin öğretilmesi sağlanmaktadır. Bu sayede ileride olması muhtemel benzeri olaylarla ilgili kararlar verilebilmesine ve problemlere çözüm üretilebilmesine olanak tanınır (Çentik, 2013).

Tümevarım ve çıkarımların yapıldığı makine öğrenmesinde, bu çıkarımlarla, gelecek ile ilgili tahminler yapmak hedeflenir. Makine öğrenmesinde data, gelecek ile ilgili bilgi tahmini yapmak amacıyla kullanılacaksa uygulama aşaması için iki aşama gereklidir (Çentik, 2013). Bunlar eğitim ve test aşamalarıdır. Veri tabanındaki örnek bir veri ile herhangi bir bilgisayar modeli geliştirme süreci eğitim olarak adlandırılır. Geliştirilen bilgisayar modelinin, veri tabanında bilinmeyen örneklerden elde edilen veri tabanından test edilme sürecine test denir (Kaya Ayana, 2016).

Yaygın olarak kullanılan makine öğrenmesi türleri:

Denetimli öğrenme: Algoritmanın, girişleri istenen çıkışlara eşleyen bir işlev oluşturduğu öğrenme türüdür. Denetimli öğrenme görevinin bir standart formülasyonu, sınıflandırma problemidir: öğrenenin, bir fonksiyonu birkaç girdi-çıkı örneğine bakarak (davranışını tahmin etmek için) bir vektörü birkaç sınıftan birine eşleyen bir işlevi öğrenmesi gerekir.

Denetimsiz öğrenme: Girdi setlerinden oluşan öğrenme türü olup etiketli örnekler mevcut değildir.

Yarı denetimli öğrenme: Sınıflandırıcıya da uygun bir işlev meydana getirmek adına etiketli ve etiketlenmemiş örnekleri birleştiren öğrenme türüdür.

Takviyeli öğrenme: Hedefine ulaşabilmek için bulunduğu ortamı algılayan ve kendi başına karar alabilme yetisi olan bir sistemin, doğru kararlar almayı nasıl öğrenebileceğini gösteren öğrenme türüdür. Her eylemin çevrede bazı etkileri vardır ve çevre öğrenme algoritmasına rehberlik eden geri bildirim sağlar.

Transdüksiyon öğrenme: Denetimli öğrenmeye benzer, ancak açıkça bir işlev oluşturmaz: bunun yerine, yeni çıktıları eğitim girdileri, eğitim çıktıları ve yeni girdiler temelinde tahmin etmeye çalışır.

Endüktif öğrenme (learning to learn): Algoritmanın, önceki deneyime dayanarak kendi endüktif eğilimini öğrendiği öğrenme türüdür (Ayodele, 2010).

Yukarıda makine öğrenmesinde girdilerin ve çıktıların beraber kullanıldığı örneklerin makine öğrenmesi için sunulduğu öğrenme şekli denetimli öğrenme olarak tanımlanmıştır. Her bir girdi değişkenini, bilinen sayıdaki bir ayrı gruba atamayı hedefleyen durumlara ise sınıflandırma denir (Kartal, 2015).

Sınıflandırmada çıktı kümesindeki her bir eleman birer sınıfı (class), sınıflandırma problemini çözümlen algoritma sınıflandırıcıyı (classifier) ifade etmektedir. Literatürde makine öğrenmesinde sınıflandırma yapmak üzere kullanılacak çok sayıda algoritma vardır. Bunlardan başlıcaları Destek Vektör Makineleri, k-En Yakın Komşu Algoritması, Naive Bayes Sınıflandırıcı, Karar Ağaçları, Yapay Sinir Ağları, olarak sayılabilir (Kartal, 2015).

Makine öğrenmesinin en çok kullanılan ve en temel görevlerinden biri olan sınıflandırma, bilinmeyen bir verinin bilinen bir kategoriye dahil edilmesinde kullanılır (Harrington, 2012). Çıkarımı örneklerden yaptığı bilinen sınıflandırma tekniğinin amacı kavramları tanımladıktan sonra, algoritmanın tanımadığı örnekleri en yüksek doğruluk oranıyla etiketleyecek sınıflandırıcıyı eğitmektir (Kartal, 2015).

Literatür tarandığında belirlenen bir problemi makine öğrenmesi teknikleri ile çözüme kavuşturmak için bazı adımların tanımlandığı görülmektedir. Örnek olarak, 2007 yılında Rossi, sınıflandırma problemlerini çözümlen için ilk olarak girdiye karar verilmesi gerektiğini vurgulamıştır. Ardından eğitim için kullanılacak veri setinin meydana getirilmesi gerektiğini belirten Rossi, sınıflandırıcıyı eğitmeyi ve

performansını tahmin etmeyi, son olarak sınıflandırıcı tahminlerinin değerlendirilmesi gerektiğini belirterek dört ana başlık önermiştir (Rossi, 2007).

2013 yılında Hu, bu adımları beş ana başlık ve bazı alt başlıklar altında incelemiştir:

1. Verinin toplanması
2. Veriye ön-işleme teknikleri uygulama
 - a. Veriyi gürültüden temizleme
 - b. Veriyi dönüştürme
 - c. Verinin eğitim ve test kümesi olarak ayrılması
3. Eğitim verisinin üzerinde model kurma
4. Test verisinin üzerinde modeli değerlendirme
5. Performansın başarılı bulunması halinde pratiğe dökülmesi(Kartal, 2015).

Brownlee ise 2014 yılında, makine öğrenmesi problemlerinin aşağıda verilen altı adımda çözülebileceğinden bahsetmiştir:

1. Problemi tanımlama
2. Veriyi analiz etme
3. Veriyi hazırlama
4. Algoritmanın değerlendirilmesi
5. Sonuçları geliştirme
6. Sonuçları sunma (Kartal, 2015).

2.5. Literatür Özeti

İnsan yürüyüşünün analizi günümüzde birçok araştırma projesinin konusudur. Web of Knowledge'de yapılan bir araştırma başlıkta 'yürüyüş' içeren bilimsel makaleler için 2012-2013 yılları arasında 3.400'den fazla yayın göstermektedir (Muro-De-La-Herran ve ark., 2014). Aynı tarama 2016-2017 yılları için yapıldığında ise 10.958 yayın karşımıza çıkmaktadır. Yürüme analizi 19. yy.'den beri spor amaçlı veya güvenlik için insanların tanımlanması amacıyla da kullanılmaktadır (Muro-De-La-Herran ve ark., 2014;Tao ve ark., 2012).

Yürüyüş analizi ile yürüyüş fazı tanımlanabilir, insan yürüme olaylarının kinematik ve kinetik parametreleri belirlenebilir ve kas iskelet fonksiyonları kantitatif olarak değerlendirilebilir. Spor, rehabilitasyon ve sağlık teşhislerinde yürüyüş analizi kullanılmaktadır (Guo ve ark., 2014). Örneğin bazı spor dallarında, sporcu performanslarındaki hataları tanımlayabilmek ve sporcuların kendilerini geliştirmelerini sağlamak için bu metot uygulanır (Boulgouris ve ark., 2005; Watanabe ve Hokari, 2006; Kwon ve Gross, 2005; Wang ve ark., 2003). Ortopedi ve rehabilitasyonda, hastanın iyileşme sürecini izlemek için yürüme analizi kullanılır (Steultjens ve ark., 2000; Kimmeskamp ve Hennig, 2001; Pope ve ark., 1985). Sağlık tanılarında, asemptomatik olgular ile akselerometre ve jiroskoplara dayalı medial diz osteoartriti olan hastalar arasında ayırım yapılmasına yönelik bir yöntem araştırılmış ve parkinson hastalığına yönelik uygulamalara yönelik ambulatuvar izleme yöntemi de geliştirilmiştir (Turcot ve ark., 2008; Moore ve ark., 2008; Salarian ve ark., 2007). Biyomedikal mühendisliği alanında, yürüyüş analizi, insan hareketini karakterize etmek için temel bir yöntem ve yardımcı araç olmuştur (Tao ve ark., 2012).

Özetle yürüyüş analizi, insan yürüme bozukluklarının saptanmasında yaygın olarak kullanılmaktadır. İnsan yürüyüşünü analiz etmek için geliştirilmiş iki ana yürüyüş analizi yaklaşımı vardır. Bir yaklaşım, insan yürüme hareketini elde etmek için video tabanlı sistemler, aktif manyetik izleyici ve optik işaretleyici sistemleri içeren işaretleme sistemlerini kullanır; bununla birlikte, yapay olarak üretilmiş bir kaynağa bağımlıdırlar ve laboratuvar ortamının dışında kullanılamazlar (Guo ve ark., 2014). Muro-de-la-herran A. ve diğerleri bunları giyilemez sensör sistemleri olarak adlandırmışlardır. Diğer yaklaşım ise giyilebilir sensör sistemleridir. Giyilebilir sistemler laboratuvarın dışındaki verileri analiz etmeyi ve kişinin günlük aktiviteleri sırasında insan yürüyüşü hakkında bilgi toplamayı mümkün kılmaktadır. Giyilebilir sensör sistemleri ayak, diz, uyluk veya bel gibi vücudun çeşitli yerlerinde bulunan sensörleri kullanır (Muro-De-La-Herran ve ark., 2014).

İvmeölçerler, jiroskoplar, kuvvet sensörleri, gerinim ölçerler, eğimölçerler, gonyometreler vb. giyilebilir sensörler, insan yürüyüşünün çeşitli özelliklerini ölçebilir (Bonato, 2003; Engin ve ark., 2005). Bu sensörler tarafından kaydedilen hareket sinyali yürüyüş analizini gerçekleştirmek için kullanılabilir. İvmeölçer ve jiroskop gibi giyilebilir atalet sensörleri, boyutları, maliyetleri ve biyomekanik

yürüyüş verilerinin kolayca toplanabilme yeteneği göz önüne alındığında, geleneksel optik yürüyüş analiz sistemlerine göre giderek popüler hale gelmektedir (Kobsar ve ark., 2014).

Ning Wang ve arkadaşları zaman-frekans analizi kullanarak yürüme paternlerinin ivmeölçer tabanlı bir sınıflamasını yapmışlardır. Çalışmada, iliyak omuriliğın üstünde bele takılmış üç eksenli bir ivmeölçer kullanılarak elde edilen verilerden beş farklı insan yürüme paternini saptamak için 33 boyutlu zaman-frekans alan özellikleri geliştirilmiş ve değerlendirilmiştir. 52 denekten bir koridor boyunca düz bir zeminde yürümeleri, bir merdivenden yukarı ve aşağı doğru inmeleri istenmiştir. Anterior-posterior (AP), medio-lateral (ML) ve vertikal (VT) doğrultudaki ivme verilerinin zaman-frekans alan özellikleri geliştirilmiştir. Her yöndeki ivme sinyali dalgacık paket dönüşümü kullanılarak farklı dalgacık ölçeklerinde altı detaylı sinyale ayrıştırılmıştır. 0.78–18.75 Hz frekans bandına karşılık gelen 5 ile 2 arasındaki ölçeklerde ayrıştırılmış sinyallerin RMS (Root Mean Square) değerleri ve standart sapmaları hesaplanmıştır. AP, ML ve VT yönlerinde 0,36-18,75 Hz frekans bandındaki hızlanma sinyalindeki enerjiler de hesaplanmıştır. Çalışmada, beşinci seviye bir Daubechies dalgacıđı, altı seviyedeki ayrışma ile ivme sinyaline uygulanan dalgacık ayrışmasında kullanılmıştır. ML ivme, yürüyüş paternleri arasında önemli bir farklılık göstermezken, ivme sinyalinin RMS'nin geçmiş çalışmalarda ayırt edici bir özellik olduđu gösterilmiştir. RMS değerleri 0.78 - 18.75 Hz'ye karşılık gelen seviye 2 ila 5 dalgacık katsayılarında sadece AP ve VT yönlerinde hesaplanmıştır (Wang ve ark., 2007).

Bir başka çalışmada kıyafetin içine veya dışına takılan bir cihazdan elde edilen ivmeölçer ve barometre verilerinin dalgacık dönüşümleri, 51 yaşlı insanın 25 dakikalık serbest yaşam aktiviteleri boyunca yürümelerini tanımlamak için kullanılmıştır. Yazarlar dalgacıkların yürüyüş karmaşıklığı veya tökezlemeler gibi anormallikleri araştırmak için yeni yollar sağladığını vurgulamış ve karar ağacı algoritmalarıyla birlikte ayırık dalgacık ayrışmasını birleştiren yürüyüş bozukluklarını uzaktan izlemek için yeni bir yöntem sunmuşlardır. Bu çalışmada Daubechies 'db5' dalgacıđı kullanılmıştır. 'Db5' dalgacıđının, basitliđi ve sürekli birinci mertebeden türevi nedeniyle sinyal işleme uygulamalarında yaygın olarak kullanıldıđı belirtilmiştir (Brodie, 2016).

Kobsar ve arkadaşları tarafından yapılan bir başka çalışmada ise üç boyutlu ivmeölçer veri modellerine göre farklı antrenman geçmişlerinin ve deneyim düzeylerinin koşucuları sınıflandırmak için üç eksenli bir ivmeölçerin yeterliliğinin incelenmesi amaçlanmıştır. Ayrık değişkenler, kısa bir koşu sırasında RMS, dalgacık dönüşümü ve otokorelasyon prosedürleri kullanılarak 3 boyutlu ivmelerden çıkarılmıştır.

Spesifik olarak, bir Daubechies 5-ana dalgacık kullanılarak 5-seviyeli bir dalgalanma ayrıştırması kullanılmıştır. Beş seviyenin her birinin genliği, her ekseninde RMS olarak ölçülmüştür (Kobsar ve ark., 2014).

Konuyla ilgili yapılan bir diğer çalışmada bir bel ivme sinyali kullanılarak düz zeminde yürüme ile merdiven yürüyüşü ayırt edilmeye çalışılmıştır. Bir üç eksenli ivmeölçer bele sabitlenmiş ve üç ivme sinyali bir taşınabilir veri kaydedici tarafından 256 Hz'lik bir örnekleme hızında kaydedilmiştir. Yirmi sağlıklı erkek denekten, herhangi bir talimat olmaksızın bir koridor boyunca yürümesi veya sürekli olarak bir merdivenden geçmesi istenmiştir. Veriler ayrık dalgacık dönüşümü kullanılarak analiz edilmiştir. Yürüme paternleri iki aşamaya göre sınıflandırılmıştır. İlk adımda, yürüyüş paterninin değiştiği zamanlar, anterio-posterior ivmenin (LF_A) ve dikey ivmelenmenin (LF_V) düşük frekanslı bileşeni kullanılarak saptanmıştır. İkinci adımda, dalgacık katsayıları düşey doğrultuda (P_{wcv}) ve anterio-posterior yönde (P_{wca}) karşılaştırılarak üç tip yürüyüş paterni ayırt edilmiştir. Yürüme paternlerindeki değişikliklerin hem LF_A hem de LF_V kullanılarak tespit edilebileceği belirtilmiştir. Yürüme paternleri arasında yanal ivme anlamı olarak farklılık göstermemiştir. Bu nedenle, analiz için dikey ve anterio-posterior ivme sinyalleri seçilmiştir. Karşılaştırma yoluyla FFT kullanılarak frekans analizi yapılmıştır. İvme sinyali her bir yürüme modeline ayrılmış ve FFT uygulanmıştır. Bununla birlikte, yürüyüş paternlerini sınıflandırmanın zor olduğu, çünkü üç yürüyüş paterninin frekans dağılımının, bireyler için geniş ve farklı olduğu vurgulanmıştır. Çalışmada ayrıca dalgacık katsayılarının kullanılmasının frekans tepkisini taklit eden dijital filtreler tasarlamaya çalışılmıştır. Önerilen yöntemde, filtreler yürüyüş paternindeki değişiklikleri saptayabilmekte ve yürüyüş paternini sınıflandırmaktadır. Bununla birlikte, dalgacık dönüşümü kullanılarak sonuç alınmadan filtreleri doğrudan tasarlamının zorluğu belirtilmiştir. Sonuç olarak, ivme sinyalinin düşük frekanslı

bileşenini kullanarak sürekli yürüme kaydında yürüyüş paternindeki değişikliklerin saptanabileceği ve dalgacık katsayılarının gücünü kullanarak düz zeminlerde ve merdivenlerde yürümenin sınıflandırılabilmesi belirtilmektedir (Sekine ve ark., 1998).

3. GEREÇ VE YÖNTEM

3.1. Araştırmanın Amacı

Yapılan tez çalışması ile: Hemipleji tanılı ve Brunnstrom evreleri bilinen olgulardan elde edilmiş olan yürüme sinyali verisinin dalgacık dönüşümü yöntemi ve makine öğrenmesi sınıflama algoritmaları kullanılarak sınıflandırılması; böylelikle ileride karşılaşılabilecek hemiplejik olguların hangi evrede olduklarının tahmin edilmesi amaçlanmıştır.

3.2. Araştırma Soruları

Hemiplejik yürüyüş sinyali verisi ile Brunnstrom Evrelemesine göre sınıf tahmini yapmak mümkün müdür?

Dalgacık dönüşümü ile ayrıştırılan sinyallerden çıkartılan öznelikler ile makine öğrenmesi algoritmalarının başarısı nedir?

3.3. Araştırmanın Evren ve Örneklemi

Araştırmanın evrenini inme sonrası hemiplejik olan olgular oluşturmaktadır.

Araştırmanın örneklemini Japonya Chiba Üniversitesinde 2005-2006 yıllarında inme sonrası hemiplejik olan olgulardan alınan yürüme sinyali verisinden oluşmaktadır (Yardımcı, 2007).

3.4. Araştırmanın Etik Yönü

Çalışmada kullanılan veriler için Japonya Chiba Üniversitesinde yerel etik kuruldan onay alınmış ve tüm denekler yazılı bilgilendirilmiş onam vermiştir.

3.5. Veri Toplama Araçları

Çalışmada kullanılan sinyaller üç eksenli bir ivmeölçer (3031-010, IC-Sensors, USA, boyut: 4x4x3 mm; ağırlık: 0.3 g; range:±10 g; frekans tepkisi: 0-500 HZ) aracılığıyla elde edilmiştir. İvmeölçer anteroposterior (x), lateral (y) ve vertikal (z) sinyalleri kaydetmek için ortogonal olarak monte edilmiştir. İvmeölçerler, kontrollü eğim altında çıktılarını ölçülerek kalibre edilmiştir. Daha sonra bel kemeri için bir akrilik plaka üzerine sabitlenmiştir. Elastik bir bel kemeri ile hastanın sırtında vertebral kolonun lumbosakral bölgesine, hasta dikilirken ağırlık merkezine yakın olarak takılmıştır. İvmeölçer ünitesi, bir portatif veri kaydediciye (Micro 8, Shimadzu,

Japan) bir arayüz devresi aracılığıyla bağlanmıştır. Bu veri kaydedici bir CPU, bir 10-bit A / D dönüştürücü, bir IC kart arayüzü ve bir çıkarılabilir 2-MB IC hafıza kartından oluşmaktadır. Arayüz devresi, her bir yön için bir anti-aliasing filtresi olarak üç amplifikatör ve üç adet ikinci dereceden analog Butterworth alçak geçiren filtreler içermektedir. *Cutoff* frekansı 500 Hz'dir. İvmeölçer çıktıları, veri kaydedici tarafından 1024 Hz'lik bir örnekleme hızında dijitalleştirilmiş ve IC hafıza kartına kaydedilmiştir. Ölçümler tamamlandıktan sonra, veriler analiz için bir kart okuyucu aracılığıyla kişisel bir bilgisayara aktarılmıştır (Yardımcı, 2007).

3.6. Veri Seti Genel Bilgileri

Çalışmada ilk aşama olarak inme sonrası hemiplejik olan 28 hasta ve 7 sağlıklı bireyden alınan yürüme sinyali verisi kullanılmıştır. Hastaların 9'u kadın; 19'u erkek ve sağlıklıların tamamı kadındır.

Brunnstrom Evrelemesi altı evreden oluşsa da ilk iki evrede yürüme söz konusu olmadığı için çalışmaya yalnızca III, IV, V ve VI. evredeki hastalar dahil edilmiştir. Tablo 3.1'de hastaların Brunnstrom Evrelemesine göre dağılımları yer almaktadır.

Tablo 3.1. Hastaların Brunnstrom Evrelemesine göre dağılımları


Brunnstrom Evresi	Hasta Sayısı	Cinsiyet(K/E)
III	12	3/9
IV	9	3/6
V	4	3/1
VI	3	0/3

Çalışmada yer alan hemiplejik hastaların ve sağlıklı bireylerin ortalama yaş, kilo ve boy özellikleri Tablo 3.2'de verilmiştir.


Tablo3.2. Deneklerin demografik özellikleri

Grup	Yaş	Boy	Kilo
Genel	66±11	154±8.56	54.6±9.4
Hasta	67±11	155±8.89	55.27±9.81
Sağlıklı	61±5.1	149±1.41	49.66±1.69


Yürüme sinyali verisi yukarıda özellikleri verilen deneklerin bir koridor boyunca serbest hızla yürüme sırasında kaydedilmiştir. Sırasıyla Şekil 3.2., Şekil 3.3., Şekil 3.4., Şekil 3.5. ve Şekil 3.6’da sağlıklı, Evre 3, Evre 4, Evre 5 ve Evre 6’da olan deneklerin işlenmemiş yürüme sinyallerine ait görüntüler şu şekildedir:




Şekil 3.1. Sağlıklı bir hastaya ait anteroposterior eksenden alınan yürüme sinyali




Şekil 3.2. Brunnstrom III. evrede olan bir hastaya ait anteroposterior eksenden alınan yürüme sinyali



Şekil 3.3. Brunstrom IV. evrede olan bir hastaya ait anteroposterior ekseninden alınan yürüme sinyali



Şekil 3.4. Brunstrom V. evrede olan bir hastaya ait anteroposterior ekseninden alınan yürüme sinyali



Şekil 3.5. Brunnstrom VI. evrede olan bir hastaya aitanteroposterior eksenden alınan yürüme sinyali

İkinci aşamada 15 sağlıklı bireyden anteroposterior ekseni olan bir ivmeölçerle yürüme sinyalleri alındı. Dalgacık dönüşümü yöntemiyle ayrıştırılan sinyallerden elde edilen öznitelikler ile birinci aşamada kullanılan veri setinin anteroposterior eksene ait öznitelikleri birleştirilerek örneklem sayısı 50'ye yükseltildi.

3.7. Verilerin Analizi

Çalışma kapsamında inme sonrası hemiplejik olan 28 hastadan ve 7 sağlıklı bireyden alınan yürüme sinyali verisi ve sonradan eklenen 15 sağlıklı yürüme sinyali verisi kullanılmıştır. Sinyal verisinin analizi için Matlab ve WEKA programlarından faydalanılmıştır.

MATLAB

MATLAB, teknik hesaplama yapmak üzere geliştirilen oldukça performanslı bir dildir. Programlama yapmayı, hesaplama yapmayı ve görsel içerik üretmeyi son derece basit bir ortamda sunan MATLAB problemi ve çözümünü bilindik matematiksel ifadelerle anlaşılır kılar. En güncel ve en etkili algoritmaları, büyük verileri işleyebilme yeteneği, programlama için sağladığı çok kuvvetli araçları MATLAB'ı öne çıkaran özellikleridir. Bu programlama dili aşağıdaki işlemler için kullanılabilir:

- Teknik hesaplamalar yapmak
- Sinyal işleme tekniklerini kullanmak
- Test ve ölçüm yapmak

- Kontrol sistemlerinin model tabanlı tasarımı,
- Görüntü işleme tekniklerini kullanmak
- Finansal model kurma ve analiz yapma (Deveci Kocakoç, 2010).

MATLAB ismi İngilizce matris laboratuvarı (MATrixLABoratory) anlamına karşılık gelen kelimedenden türetilmiştir. MATLAB ilk defa LINPACK ve EISPACK tasarımları yoluyla geliştirilen matris yazılımına kolay erişim sağlamak amacı ile yazılmıştır.

MATLAB temel veri elemanı boyutlandırmasına ihtiyaç duymayan bir dizim (array) olan etkileşimli bir sistemdir. Bu da özellikle matris ve vektör formüllü pek çok teknik hesaplamaların çözümünü C veya Fortran gibi etkileşimli olmayan dillerde yazılan bir programın çözümünden çok daha kısa olmasını sağlar.

MATLAB ile yapılabilen matematiksel işlemler; doğrusal cebir, veri çözümlenme, sinyal işleme, polinom ve ara değer işlemleri ve diferansiyel denklem çözümleri şeklinde sıralanabilir. Gerek matematiksel işlemlerin sonuçları ve gerekse dışarıdan aktarılan verilerin 2-boyutlu ve 3-boyutlu grafikleri kolaylıkla sağlanabilir. Bu grafikler ve diğer şekiller üzerinde ise renklendirme ve ışıklandırma işlemleri yapılabildiği gibi şekil canlandırma (animasyon) işlemleri de yapılabilir. Harici arayüz yardımıyla C ve Fortran programlama dilleri ile iletişim kurulabilmektedir.

MATLAB başlangıçta sayısal hesaplamaları yerine getirmek amacı ile geliştirilmiş olmakla beraber 5.0 sürümünden itibaren geliştirdiği Symbolic Math Toolbox program paketi ilavesi ile sembolik matematiksel işlemleri de yapabilir hale gelmiştir. Bu paket sembolik hesaplamaları MATLAB'ın sayısal hesaplama ortamına dahil etmiştir.

MATLAB'ın belirleyici niteliklerinden birisi, MATLAB ana paketine ilaveten araç kutuları anlamına gelen toolbox adı verilen uygulamaya özel çözümler sağlayan fonksiyon paketlerinden oluşmasıdır. Araç kutuları veya fonksiyon paketleri MATLAB ortamını özel türden problemlerin çözümünü sağlamak amacı ile genişleten kapsamlı bir MATLAB fonksiyonları derlemesidir. Araç kutuları; matematik ve analiz, matematiksel modelleme ve benzetim, gerçek zamanda veri toplama ve denetim, sinyal ve görüntü işleme, denetim sistemi tasarımı, maliyet

modellemesi ve analiz gibi pek çok uygulama alanını kapsamaktadır. Bu ilave fonksiyon paketlerinin bir kısmı ana program yapısında olup bunlar Simulink, Real Time Workshop ve Stateflow'dur. Simulink dinamik sistemlerin modellenmesi, benzetimi ve çözümlenmesinde kullanılan bir paket yazılım programıdır. Her ne kadar MATLAB ana paketi içinde yer alan diferansiyel denklem çözüm fonksiyonları olan ODE fonksiyonları yardımı ile dinamik sistemlerinin çözümünü elde etmek mümkünse de bunlar Simulink paketinin sağladığı esnekliği sağlayamaz. Simulink'te modeller ise bir grafik kullanıcı arayüzü yardımıyla oluşturulur. Simulink'te sinyal giriş elemanı, sinyal çıkış elemanı, doğrusal ve doğrusal olmayan elemanlar ve bağlantı elemanlarından oluşan çok geniş kapsamlı bir blok kütüphanesi mevcuttur. Model oluşturulduktan sonra ise genellikle Simulink menüsünden seçilen integral alma veya diferansiyel denklem çözüm yöntemleri ile modelin çözümü yapılır (Yüksel, 2004).

WEKA

Weka (Waikato Environment for Knowledge Analysis) veri madenciliği uygulamalarında kullanılan makine öğrenmesi algoritma topluluğudur. Veri hazırlama, regresyon, kümeleme, sınıflandırma, görselleştirme ve birliktelik kuralları gibi araçlar içeren Weka, GNU General Public License kapsamında verilen açık kaynaklı bir yazılımdır (WEKA, 2016).


Weka, yapısında pek çok yöntem, hazır fonksiyon, algoritma ve kütüphane barındırmaktadır. Modüler olma niteliği ile yeni geliştirilmiş olan ya da programda olmayan özellikler kullanıcı istediği takdirde Weka platformundan ücret ödmeden indirilebilir.

Weka programı Java tabanlı bir yazılımdır ve kütüphaneleri .jar uzantılıdır. Uzantısının .jar olması sayesinde Java programında yazılmış pek çok program veyaprojeye uyumda çok büyük rahatlık sağlar. Weka'da çalışılabilmesi için, kullanılacak verinin uzantısının .arff olması gerekmektedir. WEKA programı CSV ve C4.5 uzantılı veri dosyalarını açmaya da imkân tanımaktadır (Altun, 2018; Takaoğlu, 2016).


3.7.1. Yürüme Sinyallerinden Ayrık Dalgacık Dönüşümü ile Öznitelik Çıkartma

Sinyallerin ayrık dalgacık dönüşümü ile analizinde uygun dalgacığın seçimi ve ayrışım seviyelerinin sayısı çok önemlidir. Ayrışım seviyelerinin sayısı seçilirken baskın frekans bileşenleri dikkate alınır (Toprak, 2007).


Çalışmada yer alan deneklerden üç eksenli ivmeölçerle alınan yürüme sinyalleri bir önceki bölümde tanıtilan Matlab programı kullanılarak ayrıştırıldı. Öncelikle her bir denekten alınan sinyalin her bir eksenini .mat olarak kaydedildi ve böylelikle 105 adet sinyal verisi elde edildi. Daha sonra her bir eksen için sınıflandırma işleminde kullanılacak katsayıları elde etmek üzere 105 ayrıştırma işlemi gerçekleştirildi. Bu işlem literatürde yürüme sinyali analizinde en çok tercih edilen Daubechies 5 (Db5) ayrık ana dalgacığı kullanılarak gerçekleştirildi. Db5 ana dalgacığı 6. seviyeye kadar ayrıştırıldı, böylelikle her bir yürüme sinyali d1- d6 ayrıştırma bandlarına ve a6 yaklaşık alt bandına ayrılmış oldu. Aşağıdaki gösterimlerde s sinyalin orijinal halini, d_i'ler ayrıştırma fonksiyonunu ve a₆ yaklaşıklık fonksiyonunu belirtmektedir.




Şekil 3.6. Sağlıklı bir kişiye ait yürüme sinyalinin 6 kademeli ayrıştırılması




Şekil 3.7. Şekil 3.8'deki sağlıklıkişiye ait yürüme sinyalinin detay katsayılarının gösterimi




Şekil 3.8. Brunnstrom evre III olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması




Şekil 3.9. Şekil 3.10'daki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi




Şekil 3.10. Brunnstrom evre IV olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması




Şekil 3.11. Şekil 3.12'deki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi




Şekil 3.12. Brunnstrom evre V olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması



Şekil 3.13. Şekil 3.14'teki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi



Şekil 3.14. Brunnstrom evre VI olan bir hastaya ait yürüme sinyalinin 6 kademeli ayrıştırılması



Şekil 3.15. Şekil 3.16'daki hastaya ait yürüme sinyalinin detay katsayılarının gösterimi

Sinyallerin Db 5 ana dalgacık kullanılarak 6 seviyeli olarak ayrıştırılmasından sonra sınıflandırma verisini oluşturmak üzere 6. seviyedeki yaklaşıklık sinyalinin öznitelikleri seçildi. Bu öznitelikler minimum, maksimum, ortalama, ortanca, ortalamadan mutlak sapma, ortancadan mutlak sapma, vektörün birinci normu (L1 norm), vektörün ikinci normu (L2 norm) ve maksimum normdur.

3.7.2. Sınıflandırma Algoritmaları ile Brunnstrom Evresinin Tahmin Edilmesi


Bu bölümde, yukarıda bahsi geçen dalgacık dönüşümü ile elde edilen özniteliklerden oluşan veri setlerine uygulanan sınıflandırma algoritmalarından bahsedilecektir.

İlk veri seti 35 kişiden anteroposterior, lateral ve vertikal eksenden alınan yürüme sinyallerinin dalgacık dönüşümü sonucunda 6. seviye yaklaşıklık sinyali katsayılarından elde edilen öznitelikler ile kişilerin Brunnstrom evrelerinden oluşmaktadır. İkinci veri seti ise var olan veri setine eklenen, 15 sağlıklı yürüyüşten alınan sinyallerin dalgacık dönüşümü sonucunda 6. seviye yaklaşıklık sinyali katsayılarından çıkartılan özniteliklerden oluşmaktadır. Ancak bu veri setinde yalnızca anteroposterior eksenden alınan sinyallerden elde edilen öznitelikler yer almaktadır.

En başta da belirtildiği gibi çalışmanın amacı kişilerin yürüme sinyali verisinden Brunstrom evrelerini tahmin edebilmektir. Bu bağlamda, bu çalışmadaki sınıflandırma problemi için önce Weka ve daha sonra MATLAB programında yer alan sınıflandırma algoritmaları kullanılmıştır.

Çalışmada Weka programının kullanılmasının nedeni; açık kaynak kodlu olarak Java dili üzerinde geliştirilmiş olup, verileri basit bir dosyadan okuyabilmesidir. Ayrıca WEKA ile birlikte birçok kütüphane hazır olarak gelmektedir. Veri ön işleme, regresyon, sınıflandırma, kümeleme, öznitelik seçimi veya öznitelik çıkarımı bunlara örnek olarak gösterilebilir.

Çalışmada Weka programı içerisinde yer alan Iterative Classifier Optimizier, AdaBoost, Bagging, Classification via Regression (CVR), LogitBoost, OneR, J48, Random Forest, Random SubSpace, MultiClass Classifier ve RepTree sınıflandırma algoritmaları kullanılmış ve farklı sonuçlar elde edilmiştir. WEKA’da eğitim ve test için çeşitli stratejiler mevcuttur. Şekil 3.18’de görüldüğü gibi WEKA 4 farklı test seçeneği sunmaktadır. Bunlar sırasıyla aşağıda anlatılmıştır:



Şekil 3.16. Weka programında bulunan test seçenekleri

Eğitim seti (Training set) seçeneği verinin sadece eğitim amacıyla kullanılmasını sağlar. Bu strateji ile veriye önce eğitim yaptırılıp sonra ikinci bir küme, test amacıyla kullanılabilir. Eğitim seti seçeneği, Şekil 3.18’de yer alan “sağlanan test seti” (Supplied test set) kümesi üzerinde çalışır. Çapraz doğrulama (Cross-validation) stratejisi ise veri kümesini belirtilen sayıda kümeye bölerek alt kümelere birisini eğitim kümesi olarak kabul eder ve sistemi eğitir. Eğittiği sistemi bir başka alt küme üzerinde dener ve bu küme sınama kümesi (validating set) ya da test kümesi (test set) olarak adlandırılır. Bu işlemi seçilen küme sayısı kadar tekrarlar, böylelikle sistem iyileştirilmeye çalışılır. Diğer bir strateji olan yüzdelik bölme (percentage split), kümeyi verilen oranda ikiye böler. Bu kümelere ilki eğitim, ikincisi ise test amaçlı


kullanır. Örneğin %60 olarak girildiğinde, kümenin ilk %60'lık kısmı eğitim, sonraki %40'lık kısmı ise test için kullanılacağı anlamına gelmektedir (Şeker, 2011).

Çalışmada problemin çözümü için kullanılan tüm algoritmalarda test seçeneği olarak 10 kat çaprazlama (10 fold cross-validation) tekniği kullanılmıştır.

Bir sonraki bölümde ayrıntılı sonuçlarına yer verilecek olan algoritmalar aşağıda tanıtılmıştır.

Yinelemeli Sınıflandırma (Iterative Classifier Optimizer)

Yinelemeli sınıflandırma, çeşitli temel makine öğrenme yöntemlerinin ağlardan bilgi almasını sağlayan bir yapıdır. Temel makine öğrenme yöntemi, her bir örneği girdi olarak tanımlayan bilgiyi alan ve daha sonra bir etiket çıkartan herhangi bir standart sınıflandırıcı olabilir. Yinelemeli sınıflandırma algoritması, Şekil 3.17'de gösterildiği gibi, mevcut öngörücüye girdi olarak komşu düğümlerle ilgili önceki tahminleri kullanarak çalışır (Fan ve Huang, 2011).



Şekil 3.17. Yinelemeli sınıflandırma algoritması. Düğümlü etiketlerin mevcut tahminlerine dayanarak ilişkisel özellikleri tekrar tekrar hesaplar, ardından her düğüm, yerel özelliklerinin ve ilişkisel özelliklerinin birleştirilmiş giriş vektörünü kullanarak sınıflandırır.

AdaBoost

Güçlendirme (Boosting), birçok zayıf ve yanlış kuralı birleştirerek doğru bir tahmin kuralı oluşturma fikrine dayanan, makine öğrenmesine yönelik bir yaklaşımdır. Adaptif Yükseltme Algoritması olarak da bilinen AdaBoost algoritması, pratikte kullanılan ilk boosting algoritmasıdır ve birçok alanda en yaygın kullanılan ve çalışılan algoritmalarından biri olmaya devam etmektedir (Schapire, 2013).

Classification via Regression (CVR)

Regresyon yöntemlerini kullanarak sınıflandırma yapmak için kullanılan CVR algoritması sınıfları ikilileştirilir ve her sınıf değeri için bir regresyon modeli

oluşturulur. Başka bir deyişle belirli bir örneğin kendisine ait olup olmadığını pozitif sınıf için öngören regresyon modelleri oluşturur.

Random SubSpace

Makine öğreniminde, aynı zamanda *attribute bagging* veya *feature bagging* olarak da adlandırılan Random Subspace, bir topluluktaki tahmin ediciler arasındaki korelasyonu, tüm özellik seti yerine rastgele özellik örnekleri üzerinde eğiterek azaltmaya çalışan bir topluluk öğrenme yöntemidir.

RepTree

Reduced Error Pruning Tree (Azaltılmış Hata Budama Ağacı) hızlı bir karar ağacı öğrenmesidir ve bilgi kazanımına veya varyansı azaltan bilgilere dayanarak bir karar ağacı oluşturur.

Random Forest

Random Forest sınıflandırma, regresyon ve çok sayıda karar ağacı oluşturarak ve sınıfların modunu (sınıflandırma) veya tek tek ağaçların ortalama tahmini (regresyon) çıkaran görevler için basit bir topluluk öğrenme yöntemidir.

MultiClass Classifier

MultiClass Classifier makine öğreniminde, örnekleri üç veya daha fazla sınıftan birine sınıflandırma söz konusu olduğunda kullanılan bir algoritmadır. MultiClass Classifier, her örnek için birden fazla etiketin öngörüleceği Multi Label Classifier ile karıştırılmamalıdır.

Bagging

Bagging, sınıflandırma veya regresyon için kullanılabilecek bir topluluk algoritmasıdır. Sınırlı miktarda veriye sahip olduğunda yararlı bir teknik olan Bagging istatistiksel bir tahmin tekniğidir. Düşük bir sapmaya ve yüksek bir varyansa sahip modeller ile en iyi şekilde kullanılan bir tekniktir ve bu, yaptığı tahminlerin eğitildikleri spesifik verilere büyük ölçüde bağımlı olduğu anlamına gelir. Bu yüksek varyans ihtiyacına uyan en çok kullanılan Bagging algoritması karar ağaçlarıdır (Brownlee, 2016).

LogitBoost

Sınıflandırma metodolojisindeki en önemli gelişmelerden biri olan Boosting (güçlendirme), eğitim verilerinin yeniden yorumlanmış sürümlerine sıralı bir sınıflandırma algoritması uygular ve böylelikle bu şekilde üretilen sınıfların ağırlıklı çoğunluğunu alarak çalışır. Birçok sınıflandırma algoritması için, bu basit strateji performansta önemli gelişmeler sağlar. Makine öğrenimi literatüründe (Freund ve Schapire 1995) önerilen ve o zamandan bu yana çok fazla ilgi gören Boosting birçok zayıf öğrenenden güçlü bir öğrenme çıkarmayı hedefleyen bir sınıflandırma algoritmasıdır (Friedman ve ark.,2000).

One Rule (Tek Kural)

Amacı veri kümeleriyle ilgili basit kuralları bulmak olan OneRule (OneR) sınıflandırma algoritması, tek bir özelliğe dayanan bir nesneyi sınıflandırmaya çalışan kurallar bütünüdür. Bu bakımdan tek seviyeden oluşan karar ağacı yapısındadır. Ayrıca çok karışık hipotezler sunabilen sınıflandırıcılarla karşı karşıya gelebilecek tahminler de yapabilme yetisine de sahiptir (Aydın ve Aslan, 2017).

J48

J48, ID3³ algoritmasının bir uzantısı olup, karar ağacı budaması, eksik değer, sürekli özellik değer aralığı, kural üretilmesi vb. gibi ek özellikleri bulunmaktadır. WEKA'da, J48, C4.5 algoritmasının Java tabanlı, açık kaynak kodlu bir uygulamasıdır (Kaur ve Chhabra, 2014). Normalleştirmeye yer veriyor olmak C4.5 ağacının ID3 ağacından en büyük farkıdır. ID3 ağacı üzerinde entropi hesaplanması yapıldığı gibi bu değer baz alınarak karar noktaları saptanır. Entropi değerlerinin oran olarak tutulduğu C4.5 ağacı üstünde alt ağaçların erişim yoğunluklarına göre farklı derecelere taşınması da mümkün kılınmaktadır. Bu konuda C4.5 ağacının diğer bir farklılığı daha ortaya çıkar. Bu da ID3 ağacından farklı bir yaklaşım ile bu ağaçta budama işleminin yapılabilmesidir (Şeker, 2012).

³J.R. Quinlan, tarafından 1986 yılında bir veri setinden "karar ağacı" geliştirmiştir. Bu algoritma aşağıdan yukarı (top-down: kökten alt dallara doğru) ve greedysearch (sonuca en yakın durum) teknikleri kullanılır.

4. BULGULAR

4.1. WEKA Programında 35 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları

Brunnstrom Evrelemesine göre hangi evrede oldukları bilinen hemiplejik hastalardan ve sağlıklı bireylerden üç eksenli bir ivmeölçer ile alınan yürüme sinyalleri Matlab programında Db5 ana dalgacığı kullanılarak 6. seviyeye kadar ayrıştırılmıştır. Ayrıştırma sonunda 6. seviyedeki yaklaşıklık sinyalinden öznitelikler çıkartılmıştır. Elde edilen özniteliklerden oluşan veri seti Weka programındaki sınıflandırma algoritmaları kullanılarak sınıflandırılmıştır. Tablo 4.1'de kullanılan sınıflandırma algoritmaları ve doğruluk oranları gösterilmektedir.

Tablo 4.1. WEKA Sınıflandırma algoritmaları ve doğruluk oranları

Algoritma	Doğruluk %	Kappa	Ortalama Mutlak Hata
Iterative Classifier Optimize	91,43	0,89	0,06
AdaBoost	57,14	0,38	0,23
CVR	85,71	0,81	0,16
Bagging	85,71	0,81	0,1
LogitBoost	91,43	0,89	0,04
OneR	85,71	0,81	0,06
Random SubSpace	74,29	0,65	0,19
J48	88,57	0,85	0,05
REPTree	80	0,73	0,08
Random Forest	74,29	0,65	0,22
Multi Class Classifier	65,71	0,55	0,13

Algoritma başarısının ölçülmesinde kullanılan en popüler yöntem Doğruluk (Accuracy) oranıdır. Bu oran Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) oranları ile hesaplanır ve aşağıdaki gibidir:

$$\text{Doğruluk} = \frac{DP+DN}{DP+YN+YP+DN} \quad (18)$$

ve hata oranı:

$$\text{Hata} = \frac{YP+YN}{DP+YN+YP+DN} \quad (19)$$

Bunun yanı sıra Cohen's Kappa istatistiği gözlemler arasındaki uyumayı ölçmek için kullanılmaktadır. Tam uyum sağlandığında kappa istatistiği 1 değerini alır. 1'e ne kadar yaklaşırsa uyum derecesinin o kadar iyi olduğundan bahsedilebilir. Kappa istatistiği -1 değerini alması durumunda hiç uyum yoktur yorumu yapılır.

Kappa istatistiği değerini hesaplarırken iki farklı olasılıktan faydalanılır. Bunlar Pr(a) ve Pr(e)'dir. İki değerlendiricinin gözlemlediği uyumların toplam orantısı Pr(a) iken, bu uyumun şansa bağlı ortaya çıkma olasılığı Pr(e)'dir. Söz konusu olasılıklar üzerinden Kappa katsayısı için kullanılan formül Denklem 20'deki gibidir (Kılıç, 2015).

$$\text{Kappa} = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)} \quad (20)$$

Elde edilen Kappa değerini yorumlamak için Landis ve Koch aşağıdaki çizelgeyi önermişlerdir (Kılıç, 2015; Landis ve Koch, 1977).

Tablo 4.2. Kappa değerinin yorumlanması

Kappa değeri	Yorum
<0	Şansa bağlı olabilecek uyumdan daha kötü uyum olması
0.01 — 0.20	Önemsiz düzeyde uyum olması
0.21 — 0.40	Zayıf düzeyde uyum olması
0.41 — 0.60	Orta düzeyde uyum olması
0.61 — 0.80	İyi düzeyde uyum olması
0.81 — 1.00	Çok iyi düzeyde uyum olması

Bütün test süreçlerinde kestirimi yapılan ve gerçek değer arasındaki farkın ortalaması olan Ortalama Mutlak Hata (Mean Absolute Error-MAE) ise aşağıdaki gibi hesaplanır.

$$MAE = \frac{1}{n} \sum_{t=1}^n |x_t - \hat{x}_t| \quad (21)$$

Tablo 4.1'e bakıldığında Iterative Classifier Optimizer algoritmasının doğruluk oranının %91,43; Kappa istatistiğinin 0,89; MAE oranının ise 0,06 olduğu görülmektedir. AdaBoost algoritması %57,14 doğruluk oranına sahipken Kappa istatistiği 0,38 ve MAE oranı 0,23'tür. CVR algoritmasının doğruluk oranı %85,71; Kappa istatistiği 0,81; MAE oranı 0,16'dır. Bagging algoritmasının Doğruluk oranı yine %85,71 ve Kappa istatistiği 0,81 iken MAE oranı 0,09'dur. Başarılı sonuç veren algoritmalarından biri olan LogitBoost algoritmasının Doğruluk oranı %91,43; Kappa istatistiği 0,89 ve MAE oranı 0,04 olarak bulunmuştur. Doğruluk oranı %85,71 olan OneR algoritmasının Kappa istatistiği 0,81 ve MAE oranı 0,06'dır. Random SubSpace algoritmasının Doğruluk oranı %74,29 iken Kappa istatistiği 0,65 ve MAE oranı 0,19 olarak bulunmuştur. Bir başka başarılı sonuç veren algoritma olan J48 algoritmasının Doğruluk oranı %88,57; Kappa istatistiği 0,85 ve MAE oranı 0,05'tir. RepTree algoritmasının Doğruluk oranı %80; Kappa istatistiği 0,73 ve MAE oranı 0,08'dir. Random Forest algoritmasının Doğruluk oranı %74,29 iken Kappa istatistiği 0,65 ve MAE oranı 0,22 olarak bulunmuştur. Son olarak Multi Class Classifier algoritmasının Doğruluk oranı %65,71; Kappa istatistiği 0,55 ve MAE oranı 0,13'tür.

Doğruluk oranlarına ve Kappa istatistiklerine bakıldığında LogitBoost, Iterative Classifier Optimize, J48, OneR, Bagging ve CVR algoritmalarının oldukça önemli derecede başarılı oldukları görülmektedir. Algoritmaların detaylı sınıflandırma sonuçları aşağıdaki tablolarda sunulmuştur:

Tablo 4.3. LogitBoost algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	1	0,04	0,92	1	0,96	0,99
4S	0,89	0,04	0,89	0,89	0,89	0,81
5S	0,75	0,03	0,75	0,75	0,75	0,64
6S	0,67	0	1	0,67	0,8	0,74
Ağr. Ort.	0,91	0,03	0,92	0,91	0,91	0,88

LogitBoost algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	12	0	0	0
4S	0	1	8	0	0
5S	0	0	1	3	0
6S	0	0	0	1	2

LogitBoost algoritmasının DP oranı 0,914 olup sağlıklı ve 3. evredeki hastaların tamamını doğru olarak sınıflandırmıştır. 4. evredeki 9 hastanın 8'ini doğru sınıflandıran algoritma 1 tanesini 3. evre olarak sınıflandırmıştır. Yine 5. ve 6. evrelerdeki hastalardan 1'er tanesini bir önceki evre olarak sınıflandırmıştır.

Tablo 4.4. Iterative Classifier Optimizer algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	1	0,04	0,92	1	0,96	0,96
4S	0,89	0,04	0,89	0,89	0,89	0,89
5S	0,75	0,03	0,75	0,75	0,75	0,77
6S	0,67	0	1	0,67	0,8	0,84
Ağr. Ort.	0,91	0,03	0,92	0,91	0,91	0,92

Iterative Classifier Optimizer algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	12	0	0	0
4S	0	1	8	0	0
5S	0	0	1	3	0
6S	0	0	0	1	2

Iterative Classifier Optimizer algoritması LogitBoost algoritması ile aynı sonuçları vermiş olup nedeni yineleyici sınıflandırıcı olarak LogitBoost algoritmasını kullanmasıdır.

Tablo 4.5. AdaBoost algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0	0	?	0	?	0,78
3S	1	0,35	0,6	1	0,75	0,75
4S	0,89	0,27	0,53	0,89	0,67	0,82
5S	0	0	?	0	?	0,74
6S	0	0	?	0	?	0,6
Ağr. Ort.	0,57	0,19	?	0,57	?	0,76

AdaBoost algoritması hata matrisi:

	S	3S	4S	5S	6S
S	0	7	0	0	0
3S	0	12	0	0	0
4S	0	1	8	0	0
5S	0	0	4	0	0
6S	0	0	3	0	0

AdaBoost algoritmasının DP oranı 0,57 olup yalnızca 3. ve 4. evredeki hastaları sınıflandırmada başarı gösterebilmiştir.

Tablo 4.6. Random SubSpace algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0,07	0,78	1	0,88	1
3S	0,92	0,09	0,85	0,92	0,88	0,97
4S	0,78	0,08	0,78	0,78	0,78	0,98
5S	0,25	0,07	0,33	0,25	0,29	0,92
6S	0	0,03	0	0	0	0,97
Ağr. Ort.	0,74	0,07	0,68	0,74	0,71	0,97

Random SubSpace algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	11	1	0	0
4S	1	0	7	0	1
5S	0	2	1	1	0
6S	1	0	0	2	0

DP oranı 0,74 olan Random SubSpace algoritması sağlıklı hastaların tamamını doğru sınıflandırırken 6. evrelerdeki hastaların tamamını yanlış sınıflandırmıştır.

Tablo 4.7. REPTree algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	0,92	0,04	0,92	0,92	0,92	0,97
4S	0,78	0,08	0,78	0,78	0,78	0,87
5S	0,75	0,1	0,5	0,75	0,6	0,83
6S	0	0,03	0	0	0	0,94
Ağr. Ort.	0,8	0,05	0,77	0,8	0,78	0,93

REPTree algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	11	1	0	0
4S	0	1	7	1	0
5S	0	0	0	3	1
6S	0	0	1	2	0

REPTree algoritmasının DP oranı 0,8 olarak bulunmuştur. Random SubSpace algoritması gibi sağlıklı hastaların tamamını doğru sınıflandırırken 6. evrelerdeki hastaların tamamını yanlış sınıflandırmıştır. 3., 4. ve 5. evrelerdeki hastaların birer tanesini bir önceki evre olarak sınıflandırmıştır.

Tablo 4.8. Random Forest algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0,07	0,78	1	0,88	1
3S	0,92	0,04	0,92	0,92	0,92	0,98
4S	0,78	0,23	0,54	0,78	0,64	0,78
5S	0	0	?	0	?	0,63
6S	0,33	0	1	0,33	0,56	0,85
Ağr. Ort.	0,74	0,09	?	0,74	?	0,88

Random Forest algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	11	1	0	0
4S	1	1	7	0	0
5S	0	0	4	0	0
6S	1	0	1	0	1

Random Forest algoritmasının DP oranı 0,74'tür. Sağlıklıların tamamını doğru tahmin eden algoritma 5. evredeki hastaların tamamını 4. evre olarak sınıflandırmıştır.

Tablo 4.9. MultiClass Classifier algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,86	0	1	0,86	0,92	1
3S	0,75	0,17	0,69	0,75	0,72	0,91
4S	0,56	0,12	0,63	0,56	0,59	0,85
5S	0,25	0,07	0,33	0,25	0,29	0,72
6S	0,67	0,1	0,4	0,67	0,5	0,91
Ağr. Ort.	0,66	0,11	0,67	0,66	0,66	0,89

MultiClass Classifier algoritması hata matrisi:

	S	3S	4S	5S	6S
S	6	1	0	0	0
3S	0	9	2	1	0
4S	0	3	5	0	1
5S	0	0	1	1	2
6S	0	0	0	1	2

MultiClass Classifier algoritmasının DP oranı 0,66 olup en yüksek doğru sınıflandırma başarısını sağlıklılarda göstermiştir.

Tablo 4.10. J48 algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,86	0	1	0,86	0,92	0,93
3S	0,92	0,04	0,92	0,92	0,92	0,94
4S	0,89	0,04	0,89	0,89	0,89	0,93
5S	0,75	0,03	0,75	0,75	0,75	0,86
6S	1	0,03	0,75	1	0,86	0,98
Ağr. Ort.	0,89	0,03	0,89	0,89	0,89	0,93

J48 algoritması hata matrisi:

	S	3S	4S	5S	6S
S	6	1	0	0	0
3S	0	11	1	0	0
4S	0	0	8	1	0
5S	0	0	0	3	1
6S	0	0	0	0	3

J48 algoritması 0,89 DP oranı ile başarılı algoritmalar arasındadır. Bu algoritma Logit Boost ve Iterative Classifier Optimizer algoritmasından farklı olarak 6. Evredeki hastaların tamamını doğru olarak sınıflandırmıştır.

Tablo 4.11. OneR algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	0,92	0	1	0,92	0,96	0,96
4S	0,89	0,04	0,89	0,89	0,89	0,93
5S	1	0,13	0,5	1	0,67	0,94
6S	0	0	?	0	?	0,5
Ağr. Ort.	0,86	0,03	?	0,86	?	0,92

OneR algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	11	1	0	0
4S	0	0	8	1	0
5S	0	0	0	4	0
6S	0	0	0	3	0

OneR algoritmasının DP oranı 0,86 olup sağlıklı ve 5. evre için tam başarı gösterirken 6. evredeki hastaların hiç birini doğru olarak sınıflandıramamıştır.

Tablo 4.12. Bagging algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	0,92	0	1	0,92	0,96	1
4S	0,89	0,38	0,89	0,89	0,89	1
5S	0,75	0,1	0,5	0,75	0,6	0,95
6S	0,33	0,03	0,5	0,33	0,4	0,96
Ağr. Ort.	0,86	0,02	0,87	0,86	0,86	0,99

Bagging algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	11	1	0	0
4S	0	0	8	1	0
5S	0	0	0	3	1
6S	0	0	0	2	1

Bagging algoritmasının DP oranı da 0,86 olarak bulunmuştur. Sağlıklıların tamamını doğru olarak sınıflandırmıştır.

Tablo 4.13. CVR algoritması

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	1	0,04	0,92	1	0,96	0,98
4S	0,89	0,04	0,89	0,89	0,89	0,97
5S	0,5	0,07	0,5	0,5	0,5	0,93
6S	0,33	0,03	0,5	0,33	0,4	0,98
Ağr. Ort.	0,86	0,04	0,85	0,86	0,85	0,98

CVR algoritması hata matrisi:

	S	3S	4S	5S	6S
S	7	0	0	0	0
3S	0	12	0	0	0
4S	0	1	8	0	0
5S	0	0	1	2	1
6S	0	0	0	2	1

Doğruluk oranı 0,86 olan bir başka sınıflandırıcı CVR algoritması sağlıklı ve 3. evre olan hastaları sınıflandırmada tam başarı göstermiştir.

Yukarıdaki tablolarda bahsi geçen kesinlik, hassasiyet, F Skoru ve ROC alanı kavramları aşağıda açıklanmıştır:

Kesinlik (Precision): Doğru pozitif oranın tahmin edilen bütün pozitiflere oranıdır.

$$Kesinlik = \frac{DP}{DP + YP}$$

Hassasiyet (Recall): Doğru pozitif oranının olması gereken bütün pozitiflere oranıdır.

$$Hassasiyet = \frac{DP}{DP + YN}$$

F Skoru: Hassasiyet ve kesinlik ölçütleri tek başlarına anlam ifade eden bir karşılaştırma sonucu elde etmemiz için yeterli değildir. Daha doğru sonuçlar elde edebilmek için her iki ölçütü de beraber değerlendirmek gerekir. f-skoru olarak da bilinen f-ölçütü bunun için tanımlanmış olup, duyarlılık ve kesinliğin harmonik ortalamasıdır.

$$f \text{ skoru} = 2 \frac{Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet}$$

Roc Alanı: Amaç, her sınıflandırma eşiği için Doğru Pozitif ve Yanlış Pozitif oranların bir grafiğini oluşturarak, bir ikili sınıflandırıcının performansını incelemektir. ROC analizi, çalışma karakteristikleri eğitim zamanında bilinmediğinde, sınıflandırıcıların değerlendirilmesi ve karşılaştırılması için önemli bir araç olarak bilinmektedir.

4.2. WEKA Programında 50 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları

Yukarıdaki bölümlerde bahsedilen Brunnstrom Evreleri bilinen 28 hemiplejik hasta ile 7 sağlıklı bireyin üç eksenli ivmeölçer ile alınan yürüme sinyallerine Matlab programı kullanılarak Dalgacık Dönüşümü tekniği uygulanmış ve sinyaller ayrıştırılmıştır. Ayrıştırılan sinyallerden 6. seviyedeki yaklaşıklık sinyali seçilmiş ve bu sinyalin öznelikleri ile bir veri seti oluşturulmuştur. Bu veri setine uygulanan sınıflandırma algoritmaları ve sonuçları yukarıda verilmiştir.

Bu bölümde ise mevcut veri setine yeni veriler eklenmiş ve aynı algoritmalarla sınıflandırma tekrarlanmıştır. Elde edilen yeni yürüme sinyali 15 sağlıklı bireyden, anteroposterior ekseni olan bir ivmeölçerden alınan yürüme sinyalini kapsadığı için mevcut verinin de yalnızca ilgili ekseni kullanılmıştır.

Yeni eklenen 15 yürüme sinyali mevcut sinyalde olduğu gibi Daubechies 5 ana dalgacık dönüşümü ile 6 seviyeli olarak ayrıştırılmıştır. Yine 6. seviye yaklaşıklık sinyalinin öznelikleri seçilmiş ve mevcut veri setine eklenmiştir.

Oluşturulan yeni veri seti ile tekrarlanan sınıflandırma sonuçları Tablo 4.9'da sunulmuştur.

Tablo 4.14. WEKA'da tekrarlanan sınıflandırma algoritmaları ve doğruluk oranları

Algoritma	Doğruluk %	Kappa	Ortalama Mutlak Hata	35 örneklem ile alınan doğruluk oranları
Iterative Classifier Optimize	90	0,856	0,05	91
AdaBoost	52	0,277	0,243	57
CVR	82	0,737	0,151	86
Bagging	78	0,683	0,137	86
LogitBoost	90	0,856	0,043	91
OneR	78	0,666	0,088	86
Random SubSpace	68	0,526	0,192	74
J48	86	0,801	0,056	89
REPTree	76	0,651	0,121	80
Random Forest	72	0,596	0,150	74
Multi Class Classifier	76	0,660	0,159	66

Yeni veri seti ile tekrarlanan sınıflandırma işleminin sonucunda doğruluk oranlarında Tablo 4.14'te görüldüğü gibi bir düşüş gözlenmiştir.

Iterative Classifier Optimizer algoritmasının doğruluk oranının %90; Kappa istatistiğinin 0,86; MAE oranının ise 0,05 olduğu görülmektedir. AdaBoost algoritması %52 doğruluk oranına sahipken Kappa istatistiği 0,28 ve MAE oranı 0,24'tür. CVR algoritmasının doğruluk oranı %82; Kappa istatistiği 0,74; MAE oranı 0,15'dir. Bagging algoritmasının Doğruluk oranı %78 ve Kappa istatistiği 0,68 iken

MAE oranı 0,13'tür. Yine başarılı sonuç veren algoritmalarından biri olan LogitBoost algoritmasının Doğruluk oranı %90; Kappa istatistiği 0,86 ve MAE oranı 0,04 olarak bulunmuştur. Doğruluk oranı %78 olan OneR algoritmasının Kappa istatistiği 0,67 ve MAE oranı 0,09'dur. Random SubSpace algoritmasının Doğruluk oranı %68 iken Kappa istatistiği 0,53 ve MAE oranı 0,19 olarak bulunmuştur. Bir başka başarılı sonuç veren algoritma olan J48 algoritmasının Doğruluk oranı %86; Kappa istatistiği 0,80 ve MAE oranı 0,06'dır. RepTree algoritmasının Doğruluk oranı %76; Kappa istatistiği 0,65 ve MAE oranı 0,12'dir. Random Forest algoritmasının Doğruluk oranı %72 iken Kappa istatistiği 0,60 ve MAE oranı 0,15 olarak bulunmuştur. Son olarak Multi Class Classifier algoritmasının Doğruluk oranı %76; Kappa istatistiği 0,66 ve MAE oranı 0,16'dır.

Aşağıda algoritmalara ait detaylı sınıflandırma sonuçları sunulmuştur.

Tablo 4.15. LogitBoost algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0,07	0,92	1	0,96	1
3S	0,83	0,03	0,91	0,83	0,87	0,99
4S	0,89	0,02	0,89	0,89	0,89	0,89
5S	0,75	0,02	0,75	0,75	0,75	0,76
6S	0,67	0	1	0,67	0,8	0,7
Ağr. Ort.	0,9	0,04	0,90	0,9	0,9	0,94

LogitBoost algoritması hata matrisi:

	S	3S	4S	5S	6S
S	22	0	0	0	0
3S	2	10	0	0	0
4S	0	1	8	0	0
5S	0	0	1	3	0
6S	0	0	0	1	2

LogitBoost algoritmasının doğruluk oranı 0,91'den 0,9'a düşse de sınıflandırmadaki başarısı yine oldukça yüksek olan bir algoritma olarak karşımıza çıkmaktadır. Sağlıklıların tamamını doğru sınıflandıran bu algoritma, ilk sınıflandırmayla kıyaslandığında yalnızca 3. evrede hata yapmıştır.

Tablo 4.16. Iterative Classifier Optimizer algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0,07	0,92	1	0,96	0,99
3S	0,83	0,03	0,91	0,83	0,83	0,98
4S	0,89	0,02	0,89	0,89	0,86	0,89
5S	0,75	0,02	0,75	0,75	0,73	0,79
6S	0,67	0	1	0,67	0,81	0,69
Ağr. Ort.	0,9	0,04	0,90	0,9	0,87	0,94

Iterative Classifier Optimizer algoritması hata matrisi:

	S	3S	4S	5S	6S
S	22	0	0	0	0
3S	2	10	0	0	0
4S	0	1	8	0	0
5S	0	0	1	3	0
6S	0	0	0	1	2

Iterative Classifier Optimizer algoritması 35 denekle yapılan sınıflandırmada olduğu gibi sağlıklıların tamamını doğru sınıflandırmıştır. Ancak ilk sınıflandırmada 3. evrenin de tamamı doğru sınıflanmışken, denek sayısı 50'ye çıktığında bu evredeki 12 hastanın 10 tanesi doğru olarak tahminlenmiştir. DP oranı 0,91'den 0,90'a gerilemiştir. Ancak yinede oldukça önemli derecede bir başarı elde edilmiştir.

Tablo 4.17. AdaBoost algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,77	0,25	0,71	0,77	0,74	0,73
3S	0,75	0,45	0,35	0,75	0,47	0,37
4S	0	0	?	0	?	0,39
5S	0	0	?	0	?	0,12
6S	0	0	?	0	?	0,09
Ağr. Ort.	0,52	0,22	?	0,52	?	0,5

AdaBoost algoritması hata matrisi:

	S	3S	4S	5S	6S
S	17	5	0	0	0
3S	3	9	0	0	0
4S	1	8	0	0	0
5S	2	2	0	0	0
6S	1	2	0	0	0

Doğruluk oranı ilk sınıflandırmaya göre %57'den %52'ye düşen AdaBoost algoritması sağlıklıları %77 ve 3. evre hastaları %75 oranında doğru sınıflarken 4., 5. ve 6. evre hastaların hiç birini doğru sınıflandıramamıştır.

Tablo 4.18. Random SubSpace algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,82	0,25	0,72	0,82	0,77	0,91
3S	0,67	0,16	0,57	0,67	0,62	0,89
4S	0,89	0,05	0,8	0,89	0,84	0,94
5S	0	0,02	0	0	0	0,75
6S	0	0	?	0	?	0,97
Ağr. Ort.	0,68	0,16	?	0,68	?	0,90

Random SubSpace algoritması hata matrisi:

	S	3S	4S	5S	6S
S	18	4	0	0	0
3S	3	8	1	0	0
4S	1	0	8	0	0
5S	2	1	1	0	0
6S	1	1	0	1	0

İlk sınıflandırmada DP oranı %74 olan Random SubSpace algoritmasının DP oranı % 68'e düşmüştür. Sağlıklı ve 4. evre hastaları sınıflandırmada %80'in üzerinde başarı gösterirken 5. ve 6. evre hastaların hiç birini doğru sınıflandıramamıştır.

Tablo 4.19. RepTree algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,82	0,18	0,78	0,82	0,8	0,86
3S	0,83	0,13	0,67	0,83	0,74	0,85
4S	0,89	0,02	0,89	0,89	0,89	0,93
5S	0,5	0,02	0,67	0,5	0,57	0,71
6S	0	0	?	0	?	0,79
Ağr. Ort.	0,76	0,12	?	0,76	?	0,85

RepTree algoritması hata matrisi:

	S	3S	4S	5S	6S
S	18	4	0	0	0
3S	2	10	0	0	0
4S	1	0	8	0	0
5S	2	0	0	2	0
6S	0	1	1	1	0

RepTree algoritmasının DP oranı %80'den %76'ya düşmüştür. Sağlıklıları, 3. Ve 4. Evre hastaları doğru sınıflandırma başarısı %80'in üzerinde olan algoritma 6. Evre hastaların hiç birini doğru olarak sınıflandıramamıştır.

Tablo 4.20. Random Forest algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,86	0,11	0,86	0,86	0,86	0,94
3S	0,75	0,11	0,69	0,75	0,72	0,91
4S	0,89	0,12	0,62	0,89	0,73	0,94
5S	0	0,02	0	0	0	0,84
6S	0	0,02	0	0	0	0,93
Ağr. Ort.	0,72	0,1	0,66	0,72	0,68	0,92

Random Forest algoritması hata matrisi:

	S	3S	4S	5S	6S
S	19	3	0	0	0
3S	2	9	1	0	0
4S	1	0	8	0	0
5S	0	0	3	0	1
6S	0	1	1	1	0

Random Forest algoritmasının DP oranı %74'ten %72'ye düşmüş olup 5. ve 6. evre hastaların hiç birini doğru olarak sınıflandıramamıştır. Ancak sağlıklıları ve 4. evre hastaları doğru sınıflandırma başarısı %80'in üzerindedir.

Tablo 4.21. MultiClass Classifier algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	1	0	1	1	1	1
3S	0,5	0,11	0,6	0,5	0,55	0,83
4S	0,56	0,17	0,42	0,56	0,48	0,75
5S	0,5	0,02	0,67	0,5	0,57	0,85
6S	1	0	1	1	1	1
Ağr. Ort.	0,76	0,06	0,77	0,76	0,76	0,90

MultiClass Classifier algoritması hata matrisi:

	S	3S	4S	5S	6S
S	22	0	0	0	0
3S	0	6	5	1	0
4S	0	4	5	0	0
5S	0	0	2	2	0
6S	0	0	0	0	3

Örnekleme sayısı artırıldıktan sonra tekrarlanan sınıflandırmalarda DP oranı artan tek algoritma MultiClass Classifier algoritması olmuştur. DP oranı %60'tan %76'ya yükselmiş olup sağlıklıların ve 6. evre hastaların tamamını doğru olarak sınıflandırmıştır.

Tablo 4.22. CVR algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,96	0,07	0,91	0,96	0,93	0,98
3S	0,92	0,05	0,85	0,92	0,88	0,98
4S	0,89	0,12	0,62	0,89	0,73	0,90
5S	0,25	0	1	0,25	0,4	0,94
6S	0	0	?	0	?	0,73
Ağr. Ort.	0,82	0,07	?	0,82	?	0,95

CVR algoritması hata matrisi:

	S	3S	4S	5S	6S
S	21	1	0	0	0
3S	1	11	0	0	0
4S	0	1	8	0	0
5S	0	0	3	1	0
6S	1	0	2	0	0

İlk sınıflandırmada 0,86 olan doğruluk oranı burada 0,82'ye düşmüştür. Sağlıklı ve 3. evrede 1'er kişi yanlış tahmin edilmiş; 6. Evredeki hastaların hiç biri doğru olarak sınıflandırılmamıştır.

Tablo 4.23. Bagging algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,91	0,14	0,83	0,91	0,87	0,95
3S	0,83	0,05	0,83	0,83	0,83	0,95
4S	0,78	0,02	0,88	0,78	0,82	0,98
5S	0,25	0,04	0,33	0,25	0,29	0,9
6S	0,33	0,04	0,33	0,33	0,33	0,79
Ağr. Ort.	0,78	0,09	0,77	0,78	0,77	0,94

Bagging algoritması hata matrisi:

	S	3S	4S	5S	6S
S	20	2	0	0	0
3S	1	10	1	0	0
4S	1	0	7	1	0
5S	1	0	0	1	2
6S	1	0	0	1	1

Bagging algoritmasında doğruluk oranında belirgin bir düşüş meydana gelmiştir. 0,86 olan doğruluk oranı denek sayısı 50'ye çıktığında 0,78'e gerilemiştir.

Tablo 4.24.OneR algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,91	0,29	0,71	0,91	0,8	0,81
3S	0,92	0,05	0,85	0,92	0,88	0,93
4S	0,89	0,02	0,89	0,89	0,89	0,93
5S	0	0	?	0	?	0,5
6S	0	0	?	0	?	0,5
Ağr. Ort.	0,78	0,14	?	0,78	?	0,82

OneR algoritması hata matrisi:

	S	3S	4S	5S	6S
S	20	2	3	0	0
3S	0	11	1	0	0
4S	1	0	8	0	0
5S	4	0	0	0	0
6S	3	0	0	0	0

OneR algoritmasının ilk sınıflandırmada doğruluk oranı 0,86 iken denek sayısı 50'ye çıkartıldığında 0,78'e gerilemiştir. İlk sınıflandırmada 5. evrenin tamamını doğru tahmin etmiş olup burada 5. ve 6. evrenin tamamını yanlış tahminlemiştir.

Tablo 4.25. J48 algoritması (50 kişi)

Sınıf	Doğru Pozitif Oran	Yanlış Pozitif Oran	Kesinlik	Hassasiyet	F Skoru	ROC Alanı
Sağlıklı	0,96	0,07	0,91	0,96	0,93	0,94
3S	0,83	0,03	0,91	0,83	0,87	0,90
4S	0,78	0,02	0,88	0,78	0,82	0,88
5S	0,75	0,04	0,6	0,75	0,67	0,85
6S	0,67	0,02	0,67	0,67	0,67	0,82
Ağr. Ort.	0,86	0,05	0,87	0,86	0,86	0,91

J48 algoritması hata matrisi:

	S	3S	4S	5S	6S
S	21	1	0	0	0
3S	1	10	1	0	0
4S	1	0	7	1	0
5S	0	0	0	3	1
6S	0	0	0	1	2

İlk sınıflandırmadaki DP oranı 0,89 olan J48 algoritmasının DP oranı 0,86'ya düşmüştür.

4.3. MATLAB Programında 35 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları

Yürüme sinyallerinden dalgacık dönüşümü sonucu elde edilen özneliklerden oluşan veri seti kişilerin Brunnstrom evrelerini tahmin edebilmek üzere Matlab Programında bulunan sınıflandırma algoritmaları kullanılarak sınıflandırıldı. Tablo 4.26'da Matlab programında kullanılan sınıflandırma algoritmaları ve doğru sınıflandırma oranları yer almaktadır. Matlab programında da WEKA'da olduğu gibi problemin çözümü için kullanılan tüm algoritmalarda test seçeneği olarak 10 kat çaprazlama (10 fold cross-validation) tekniği kullanılmıştır.

Tablo 4.26. Matlab Programında 35 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları

Sınıflayıcı	Doğruluk Oranı %
Linear Discriminant	69,4
Complex Tree	83,3
Subspace Discriminant	75
RUSBoosted Trees	86,1


Linear Discriminant Algoritması:

Diskriminant analizi, farklı sınıfların, farklı Gauss dağılımlarına dayanan veri ürettiklerini varsayan bir sınıflandırma yöntemidir. Bu yöntemde bir sınıflandırıcıyı eğitmek (oluşturmak) için, fitting işlevi her sınıf için bir Gauss dağılımının parametrelerini tahmin eder. Yeni veri sınıflarını tahmin etmek için, eğitilmiş sınıflandırıcı en düşük yanlış sınıflandırma maliyetine sahip sınıfı bulur.


Linear Discriminant algoritmasının hata matrisi ve sınıflara göre AUC (Area Under Curve) eğrileri aşağıda sunulmuştur.

True class	1	2	3	4	5
1	9	3			
2	1	7		1	
3		2	1	1	
4			1	2	
5	1				6


Şekil 4.1. Linear Discriminant algoritması hata matrisi




Seviye III




Seviye IV



Seviye V



Seviye VI




Sağlıklı

Linear Discriminat algoritmasının doğru sınıflandırma oranı % 69,4 olup DP oranları 3. evre için 0,75; 4. evre için 0,78; 5. evre için 0,25; 6. evre için 0,67 ve sağlıklılar için 0,86 olarak bulunmuştur.


Complex Tree Algoritması:

Çok sınıflı öğrenme için ikili karar ağacı modeli sunan Complex Tree algoritması sınıflar arasında çok iyi ayrımlar yapan birçok yaprakları olan bir karar ağacıdır.

Complex Tree algoritmasının hata matrisi ve sınıflara göre AUC (Area Under Curve) eğrileri aşağıda sunulmuştur.




Şekil 4.2. Complex Tree algoritması hata matrisi




Seviye III

Seviye IV



Seviye V

Seviye VI




Sağlıklı

Complex Tree algoritmasının doğru sınıflandırma oranı % 83,3 olup DP oranları 3. evre için 0,92; 4. evre için 0,89; 5. evre için 1; 6. evre için 0 ve sağlıklılar için 1 olarak bulunmuştur. Complex Tree algoritması sağlıklıların ve 5. Evrede olan hastaların tamamını doğru sınıflandırırken 6. evredeki hastaların hiç birini doğru olarak sınıflandıramamıştır.


Subspace Discriminant Algoritması:

Subspace Discriminant algoritması bir topluluk öğrenme algoritmasıdır. Diskriminant analizi ya da k-en yakın komşu (KNN) sınıflandırıcılarının doğruluğunu arttırmak için kullanılır.

Subspace Discriminant algoritmasının hata matrisi ve sınıflara göre AUC (Area Under Curve) eğrileri aşağıda sunulmuştur.




Şekil 4.3. Subspace Discriminant algoritması hata matrisi




Seviye III

Seviye IV



Seviye III

Seviye IV

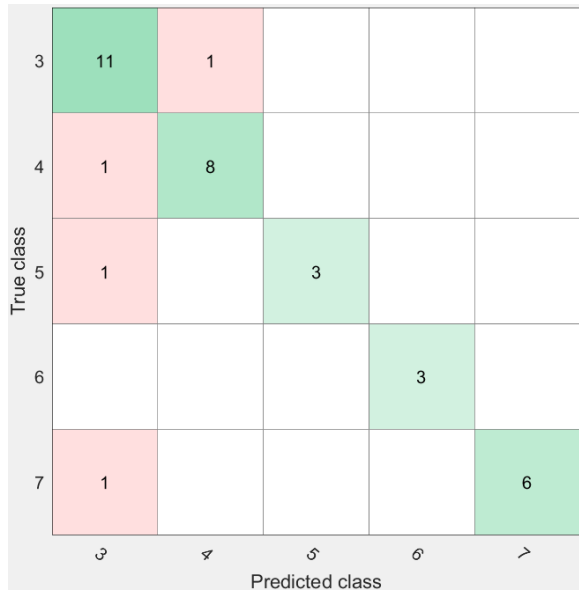


Sağlıklı


Subspace Discriminant algoritmasının doğru sınıflandırma oranı % 76 olup DP oranları 3. evre için 1; 4. evre için 1; 5. evre için 0; 6. evre için 0 ve sağlıklılar için 0,77 olarak bulunmuştur. Subspace Discriminant algoritması 3. ve 4. evrede olan hastaların tamamını doğru sınıflandırırken 6. evredeki hastaların hiç birini doğru olarak sınıflandıramamıştır.

RUSBoosted Trees Algoritması:

RUSBoosted Trees algoritması özellikle dengesiz verilerin sınıflandırılmasında yani eğitim verilerindeki bazı sınıfların diğerlerinden daha az üyesi olduğu durumlarda etkilidir. RUS, Random Under Sampling'in (Rasgele Örneklemeye Altında) kısaltmasıdır. Çoğunluk sınıfı örneklerini kaldırarak azınlık sınıfını daha iyi modellemek için RUS ve standart Boosting prosedürü olan AdaBoost'un bir kombinasyonunu kullanır. Algoritma, N, örnekleme için temel birim olarak, eğitim verilerinde en az üyeye sahip sınıftaki üye sayısını alır. Daha fazla üyeye sahip sınıflar, her sınıfın sadece N gözlemlerini alarak örneklendirilir. Diğer bir deyişle, eğer K sınıf varsa, o zaman, her bir zayıf öğrenci için, topluluk içinde, RUSBoost, K sınıflarının her birinden N gözlemleri ile verilerin bir alt kümesini alır. RUSBoosted Trees algoritmasının hata matrisi ve sınıflara göre AUC (Area Under Curve) eğrileri aşağıda sunulmuştur.




Şekil 4.4. RUSBoosted Trees algoritması hata matrisi




Seviye III

Seviye IV



Seviye V

Seviye VI



Sağlıklı

RUSBoostes Trees algoritması MATLAB programında bu problemin çözümü için en yüksek doğruluk oranını vermiş olup doğru sınıflandırma oranı % 86,1'dir. Algoritmanın DP oranları 3. evre için 0,92; 4. evre için 0,89; 5. evre için 0,75; 6. evre için 1 ve sağlıklılar için 0,86 olarak bulunmuştur. RUSBoostes Trees algoritması 6. evre olan hastaların tamamını doğru sınıflandırırken diğer sınıflarda birer hata yapmıştır.

4.4. MATLAB Programında 50 Kişilik Veri Seti ile Yapılan Sınıflandırma Sonuçları


Bu bölümde mevcut veri setine yeni eklenen veri ile aynı sınıflandırma algoritmaları tekrarlanmış ve sonuçlar Tablo 4.27'de sunulmuştur.

Tablo 4.27. Matlab programında tekrarlanan sınıflandırma algoritmaları ve doğruluk oranları


Sınıflayıcı	Doğruluk Oranı %	35 örneklem ile alınan doğruluk oranları
Lineer Discriminant	64	69,4
Complex Tree	82	83,3
Subspace Discriminant	76	75
RUSBoosted Trees	86,1	86,1


Mevcut veri setine 15 sağlıklı kişiden anteroposterior eksenini olan bir ivmeölçer ile alınan yürüme sinyallerinden elde edilen öznelikler eklenmiş ve Matlab programında aynı algoritmalar kullanılarak sınıflandırma tekrar edilmiştir. Sınıflandırma algoritmalarının hata matrisleri ve her bir sınıfa ait AUC eğrileri aşağıda sunulmuştur.

Linear Discriminant algoritması:




Şekil 4.5. Linear Discriminant algoritması hata matrisi (50 kişi)





Seviye V


Seviye VI



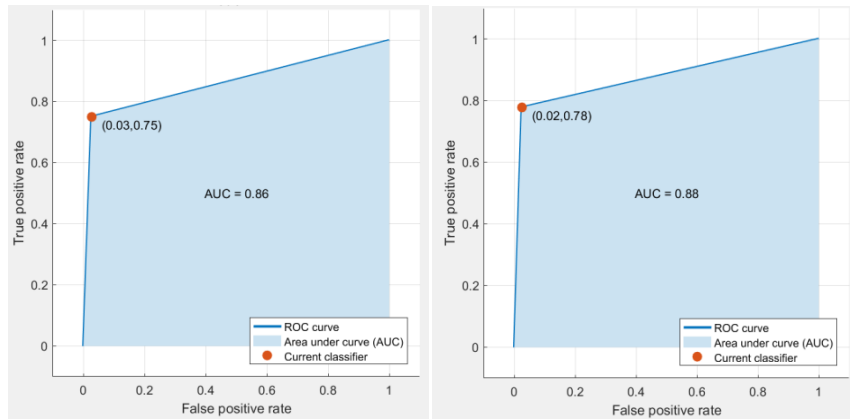
Sađlıklı

Tekrarlanan Linear Discriminant algoritması sonucunda dođruluk oranı %69,4'ten %64'e dūřmūř olup DP oranları 3. evre iēin 1; 4. evre iēin 0,56; 5. evre iēin 0; 6. evre iēin 0 ve sađlıklılar iēin 0,68 olarak bulunmuřtur. Linear Discriminant algoritması 3. evre olan hastaların tamamını dođru sınıflandırırken 5. ve 6. evre hastaların hiē birini dođru olarak sınıflandıramamıřtır.

Complex Tree algoritması:




Şekil 4.6. Complex Tree algoritması hata matrisi (50 kişi)




Seviye III

Seviye IV



Seviye V


Seviye VI




Sağlıklı

Tekrarlanan Complex Tree algoritması sonucunda doğruluk oranı %83,3'ten %82'ye düşmüş olup DP oranları 3. evre için 0,75; 4. evre için 0,78; 5. evre için 1; 6. evre için 0 ve sağlıklılar için 0,95 olarak bulunmuştur. Complex Tree algoritması 5. evre olan hastaların tamamını doğru sınıflandırırken 6. evre hastaların hiç birini doğru olarak sınıflandıramamıştır. Bunun yanında 22 sağlıklıların 21 tanesini doğru olarak sınıflandırmıştır.

Subspace Discriminat algoritması:




Şekil 4.7. Subspace Discriminant algoritması hata matrisi (50 kişi)




Seviye III

Seviye IV



Seviye V


Seviye VI



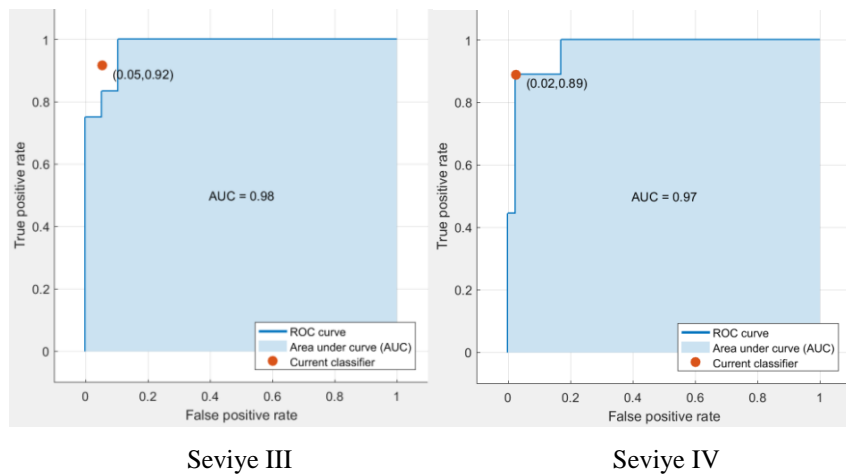
Sağlıklı


Tekrarlanan Subspace Discriminant algoritması sonucunda doğruluk oranı %75'ten %76'ya yükselmiş olup DP oranları 3. evre için 1; 4. evre için 1; 5. evre için 0; 6. evre için 0 ve sağlıklılar için 0,77 olarak bulunmuştur. Subspace Discriminant algoritması 3. ve 4. evre olan hastaların tamamını doğru sınıflandırırken 5. ve 6. evre hastaların hiç birini doğru olarak sınıflandıramamıştır.

RUSBoosted Trees algoritması:




Şekil 4.8. RusBoosted Trees algoritması hata matrisi (50 kişi)





Seviye V

Seviye VI



Sağlıklı

Tekrarlanan RusBoosted Trees algoritması sonucunda doğruluk oranı değişmemiş ve %86,1 olarak bulunmuştur. Ancak sınıflara göre DP oranları değişiklik göstermektedir. 3. evre için 1; 4. evre için 1; 5. evre için 0; 6. evre için 0 ve sağlıklılar için 0,77 olarak bulunmuştur. Subspace Discriminant algoritması 3. ve 4. evre olan hastaların tamamını doğru sınıflandırırken 5. ve 6. evre hastaların hiç birini doğru olarak sınıflandıramamıştır.

Algoritmanın DP oranları 3. evre için 0,92; 4. evre için 0,89; 5. evre için 0,75; 6. evre için 1 ve sağlıklılar için 0,86 olarak bulunmuştur. RUSBoostes Trees algoritması 6. evre olan hastaların tamamını doğru sınıflandırırken diğer sınıflarda birer hata yapmıştır.

5. TARTIŞMA

Hemiplejik Yaşlılarda Yürüyüş Analizi ve Değerlendirilmesi başlıklı çalışmamızın örnekleme Japonya Chiba Üniversitesinde 2005-2006 yıllarında inme sonrası hemiplejik olan olgulardan alınan yürüme sinyali verisinden oluşmaktadır. Evreninin hemiplejik hastalardan oluştuğu bir çalışma için 28 hemiplejik yürüyüş ve 7 sağlıklı yürüyüş sinyali verisinin yetersiz kalabileceği düşünülmektedir. Örneklem sayısının yetersiz olmasından dolayı sınıflandırma sonuçlarının başarısı hakkında genelleme yapmak zor olsa da uygulanan teknikler sonrası yapılan sınıflandırmalarda tatmin edici doğruluk oranlarına ulaşılmıştır.

Çalışmada veri setini oluşturan, Brunnstrom evreleri bilinen hemiplejik yaşlı yürüme sinyali verisine benzer veri bulmakta yaşanan güçlük nedeni ile veri seti yalnızca sağlıklı bireylerin yürüme sinyali verisi eklenerek genişletilebilmiştir.

Olgu sayısı 15 sağlıklı yürüyüş sinyali verisi eklendikten sonra 50'ye çıkartılmıştır. Oluşturulan yeni veri seti ile tekrar sınıflandırma yapıldığında doğruluk oranlarında gözlemlenen azalmanın olası nedenleri aşağıdaki gibidir:

- Mevcut veri setinde üç eksenli ivmeölçer ile alınan yürüme sinyallerinin dalgacık dönüşümü sonrası elde edilen öznitelikleri kullanılmıştır. Yeni veri setinde ise yalnızca anteroposterior eksenden alınan yürüme sinyali verisi kullanılmıştır. Olgu sayısı artmış olsa da öznitelik sayısı azaldığı için doğruluk oranlarında düşüş meydana geldiği düşünülmektedir.
- Makine öğrenme tekniklerinde her analiz birbirinden farklı sonuçlar verebilmektedir. Bunun nedeninin değişen veri seti ve algoritmada kullanılan parametreler olduğu düşünülmektedir.

Bunun yanı sıra tüm algoritmalarda sınıflama doğruluk oranında düşüş gözlenirken Multi Class Classifier algoritmasında %11'lik bir artış gözlenmiştir.

Sınıflandırma sonuçlarında dikkat çeken bir başka unsur ise Boosting algoritmalarının sonuçlarıdır. AdaBoost ve LogitBoost algoritmalarının doğru sınıflandırma oranları arasında ilk sınıflandırma için %34; ikinci sınıflandırma için %38 oranında bir fark gözlenmiştir. Bunun nedeninin LogitBoost algoritmasının, AdaBoost algoritmasında sorun olarak var olan çok gürültülü verilerden kaynaklı

aşırı uygunluk problemini çözmek için geliştirilmiş olması olduğu düşünülmektedir. LogitBoost ise bu sorunun çözümü için eğitim hatasını doğrusal bir biçimde azaltmaktadır (Aydın ve Aslan, 2017).

LogitBoost algoritması ile Iterative Classifier Optimize algoritması aynı sonuçları vermiştir. Bunun nedeni Iterative Classifier Optimize algoritmasının yineleyici sınıflandırıcı olarak LogitBoost algoritmasını kullanmasıdır.

MATLAB programında tekrarlanan RusBoosted Trees algoritması sonucunda doğruluk oranı değişmemiştir. Fakat sınıflara göre Doğru Pozitif oranları değiştiği için algoritmanın aynı şekilde sonuç verdiği söylenemez.

Çalışmada yürüme sinyalleri literatürde en çok tercih edilen dalgacık olan Daubechies dalgacığı kullanılarak ayrıştırılmıştır. Daubechies 5 ana dalgacığı ile ayrıştırılan sinyalden elde edilen özniteliklerin evre tahmininde kullanılabileceğı görülmüştür. Sonraki çalışmalarda farklı dalgacık operatörleri ile de ayrıştırma yapıp elde edilen özniteliklerin sınıflandırılması planlanmaktadır.

Sınıflandırma için WEKA ve MATLAB programlarından yararlanılmıştır. Farklı veri işleme araçlarında farklı sınıflandırma algoritmaları olması nedeniyle karşılaştırma yapmanın çok doğru olmadığı düşünülse de WEKA ve MATLAB ile yapılan sınıflandırmalarda Boosting algoritmalarının bu problemin çözümünde en iyi sonucu verdiği görülmektedir.

6. SONUÇ ve ÖNERİLER

Bu çalışmada hemiplejik hastaların yürüme sinyallerinden, Brunnstrom evrelerinin tahmin edilebilmesi için dalgacık dönüşümü tekniği ve sınıflama algoritmaları kullanılmıştır.

Matlab programında Daubechies 5 ana dalgacığı ile 6 seviyeli olarak ayrıştırılan yürüme sinyallerinden 6. seviyedeki yaklaşım sinyalinin öznitelikleri seçilmiştir.

Bu tez kapsamında iki farklı veri seti ile çalışılmıştır. İlk veri seti 28 hemiplejik hasta, 7 sağlıklı birey yürüyüş verisinden elde edilen özniteliklerden oluşmaktadır. İlk veri setinde yer alan bireylerin yürüme sinyalleri üç eksenli (anteroposterior, lateral, vertikal) ivmeölçer kullanılarak alınmıştır. İkinci veri seti, ilk veri setine 15 sağlıklı bireyin yürüyüş verisi daha eklenerek oluşturulmuştur. Ancak eklenen yürüyüş sinyali verisi yalnızca anteroposterior eksenine bulunan bir ivmeölçerle alındığı için mevcut veri setinden de sadece bu eksene ait öznitelikler kullanılmıştır.

Bu veri seti ile Weka programında Iterative Classifier Optimizier, AdaBoost, Bagging, Classification via Regression (CVR), LogitBoost, OneR, J48, Random Forest, Random SubSpace, Multi Class Classifier ve RepTree algoritmaları; MATLAB programında ise Lineer Discriminant, Complex Tree, Subspace Discriminant ve RUSBoosted Trees algoritmaları kullanılarak sınıf tahmini yapılmaya çalışılmıştır. Sınıflandırma algoritmaları içerisinde en yüksek doğruluk oranını WEKA'da LogitBoost algoritması (35 kişi için % 91; 50 kişi için %90), MATLAB programında ise RUSBoosted Trees algoritması (%86,1) vermiştir.

Gelecek çalışmalarda;

- Hem patolojik yürüme hem de sağlıklı yürüme sinyal verisinin arttırılması,
- Farklı dalgacık operatörleriyle sinyallerin yeniden ayrıştırılması ve yeni öznitelikler ile sınıflandırma tahmini yapılması,
- Rapidminer, Keel, Clementine, KNIME, Orange, R gibi farklı veri işleme araçları kullanılarak yeniden sınıflandırma yapılması ve mevcut sonuçlarla karşılaştırılması,

- Akdeniz Üniversitesi Hastanesi'nde yürüme sorunları ile ilgilenen klinisyenlere destek olmak amacıyla hastaların yürüme bozukluklarını sınıflandıran, rehabilitasyon sürecinde izlemede kullanılacak bir karar destek sistemi yazılması planlanmaktadır.

KAYNAKÇA

Adeli, H., Zhou , Z., & Dadmehr, N. Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*. 2013; (123), 69-87.

Alp, A., Efe, B., Adalı, M., Bilgiç, A., Demir Türe, S., Coşkun, Ş., et al. The Impact of Whole Body Vibration Therapy on Spasticity and Disability of the Patients with Poststroke Hemiplegia. *Rehabilitation Research and Practice*. 2018.

Altay, Ö. Dalgacık Analizi ile Yüksek Gerilim Aygıtlarından Alınan İşaretlerin Değerlendirilmesi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Doktora Tezi, 2010, İstanbul (Danışman: Prof. Dr. Ö Kalenderli)

Altun, S. MR Spektroskopi Temelli Beyin Tümörü Teşhisinde Veri Madenciliği Uygulamaları. Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, 2018, Kahramanmaraş (Danışman: Doç. Dr. A Alkan)

Atalay, M., & Çelik, E. Büyük Veri Analizinde Yapay Zeka ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Dergisi*. 2017; 9(22), 155-172.

Aydın, F., & Aslan, Z. Yapay Öğrenme Yöntemleri ve Dalgacık Dönüşümü Kullanılarak Nörodejeneratif Hastalıkların Teşhisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 2017; 32(3), 749-766.

Ayodele, T. Types of Machine Learning Algorithms. *New Advances in Machine Learnin*. 2010; (s. 3-48).

Barnes, L., & Fairhurst, C. *The Hemiplegia Handbook for Parints and Professionals*. (H. M. Hart, Dü.) Londra, İngiltere: Mac Keith Press.2012.

Bearden, D., Monokwane, B., Khurana, E., Baier, J., & Baranov, E. Pediatric Cerebral Palsy in Botswana: Etiology, Outcomes, and Comorbidities. *Pediatric Neurology*. 2016; (59), 23-29.

Bonato, P. Wearable Sensors/Systems and Their Impact On Biomedical Engineering. *Eng. Med. Biol. Mag*. 2003; (22), 18-21.

Boulgouris, N., Hatzinakos, D., & Plataniotis, K. Gait Recognition: A Challenging Signal Processing Technology For Biometric Identification. IEEE Signal Process. 2005; (22), 78-90.

Brodie, M. V. Wearable Pendant Device Monitoring Using New Wavelet-based Methods Shows Daily Life and Laboratory Gaits are Different. Med Biol Eng Comput. 2016; 54(4), 663-674.

Chinnabhandar, V., Singh, A., & Manda, A. Acute Hemiplegia in Children: A Prospective Study of Etiology, Clinical Presentation, and Outcome from Western India. Journal of Neurosciences in Rural Practice. 2018; 9(4), 504-509.

Çentik, G. Makine Öğrenmesi Yöntemlerinin Polisomnografik Verilere Uygulanması. Trakya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Doktora Tezi, 2013, Edirne (Danışman: Yard. Doç. Dr. İ Umut)

Daubechies, I. Ten Lectures on Wavelets. Philadelphia: PA: Society for Industrial and Applied Mathematics. 1992

De Quervain, I., Simon, S., Leurgans, S., Pease, W., & McAllister, D. Gait Pattern in the Early Recovery Period after Stroke. The Journal of Bone and Joint Surgery.1996; 78(10), 1506-1514.

Demren, E. Dalgacık Dönüşümünün Fourier Dönüşümü ile Karşılaştırılması ve Uygulama.İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Makina Mühendisliği Anabilim Dalı Makina Dinamiği, Titreşim ve Akustiği Yüksek Lisans Tezi, 2015, İstanbul (Danışman: Prof. Dr. K Y Şanlıtürk)

Deveci Kocakoç, İ. MATLAB ve İstatistiksel Veri Analizi. Ankara: Nobel. 2010.

Duran, K. Rüzgar Karakteristiklerinin Dalgacık Dönüşümü ile Ortaya Konması. İstanbul Teknik Üniversitesi Meteoroloji Mühendisliği Anabilim Dalı Atmosfer Bilimleri Programı Yüksek Lisans Tezi, 2013, İstanbul (Danışman: Prof. Dr. K Koçak)

Elektronik Notları (Cilt EMO YAYIN NO: EK/2012/546). (E. Fidan, & A. Bodur, Çev.) Ankara: TMMOB Elektrik Mühendisleri Odası. 2013.

- Elfouly, F., Mahmoud, M., Dessouky, M., & Deyab, S. Comparison between Haar and Daubechies Wavelet Transformations on FPGA Technology. *International Scholarly and Scientific Research & Innovation*. 2008; 2(1), 96-101.
- Engin, M., Demirel, A., Engin, E., & Fedakar, M. Recent Developments And Trends In Biomedical Sensors. *Measurement*. 2005; (37), 173-188.
- Eser, F., Aksel, J., & Karakuş, D. İnme Sonrası Gelişen Hemiplejide Yürümenin Özellikleri ve Yürüme Analizinin Yeri. *Fiziksel Tıp*. 2004; 7(1), 39-42.
- Fan, S., & Huang, B. Training Iterative Collective Classifiers with Back-Propagation. *Journal of Machine Learning Research*. 2011; 2122-2159.
- Friedman, J., Hastie, T., & Tibshirani, R. Additive Logistic Regression: a Statistical View of Boosting. *The Annals of Statistics*. 2000; 28(2), 337-407.
- Guo, Y., Wu, D., Liu, G., Zhao, G., Huang, B., & Wang, L. A Low-Cost Body Inertial-Sensing Network For Practical Gait Discrimination Of Hemiplegia Patients. *Telemedicine And E-Health*. 2014; 748-754.
- Guzzetta , A., Fazzi , B., Mercuri, E., & Bertuccelli, B. Visual Function in Children with Hemiplegia in the First Years of Life. *Developmental Medicine and Child Neurology*. 2001; 43(5), 321-329.
- Gündüz, B. Stroke and Prognostic Factors. . *Turk J Phys Med Rehab*. 2006; 52, 30-33.
- Harrington, P. *Machine Learning in Action*. New York: Manning Publications Co. 2012.
- Hindle, K. B., Whitcomb, T. J., Briggs, W. O., & Hong, J. Proprioceptive Neuromuscular Facilitation (PNF): Its Mechanisms and Effects on Range of Motion and Muscular Function. *Journal of Human Kinetics*. 2012; 31, 105-113.
- Hoppenfeld, S. *Physical Examination of the Spine and Extremities*. Appleton - Century -Crofts. 1976.
- Jongbloed, L. J. Prediction of Function After Stroke: a critical review. *Stroke*. 1986; 17, 765-776.

Jorgensen, H., Nakayama, H., Raaschou, H., & Olsen, T. Recovery of Walking Function in Stroke Patients: the Copenhagen Stroke Study. *Archives of Physical Medicine and Rehabilitation*. 1995; 76(1), 27-32.

Karaduman, A., Aksu Yıldırım, S., & Tunca Yılmaz, Ö. Serebrovasküler Olay. A. S. Otman içinde, Hemipleji Rehabilitasyonunda Nörofizyolojik Yaklaşımlar. Hipokrat Yayınevi. 2018.

Kartal, E. Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin bir Uygulama. İstanbul Üniversitesi Fen Bilimleri Enstitüsü Enformatik Anabilim Dalı Doktora Tezi, 2015, İstanbul (Danışman: Prof. Dr. M E Balaban).

Kaur, G., & Chhabra, A. Improved J48 Classification Algorithm for the Prediction of Diabetes. *International Journal of Computer Applications*. 2014; 98(22), 13-17.

Kaya Ayana, E. Öznitelik Seçiminin Geliştirilen Bir Yapay Sinir Ağı Sınıflandırılması Üzerine Etkisi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Kontrol ve Otomasyon Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, 2016, İstanbul (Danışman: Doç. Dr. K Gülez)

Kılıç, S. Kappa Testi. *Journal of Mood Disorders*. 2015; 5(3), 142-144.

Kimmeskamp, S., & Hennig, E. Heel To Toe Motion Characteristics İn Parkinson Patients During Free Walking. *Clin. Biomech*. 2001; 16, 806-812.

Kobsar, D., Osis, S., Hettinga, B., & Ferber, R. Classification Accuracy of a Single Tri-axial Accelerometer for Training Background and Experience Level in Runners. *Journal of Biomechanics*. 2014; 47, 2508-2511.

Kuan, T.-S., Tsou, J.-Y., & Su, F.-C. Hemiplegic Gait of Stroke Patients: The Effect of Using a Cane. *Archives of Physical Medicine and Rehabilitation*. 1999; 80(7), 777-784.

Kwon, D., & Gross, M. Combining Body Sensors And Visual Sensors For Motion Training. In *Proceedings Of The 2005 ACM SIGCHI International Conference On Advances İn Computer Entertainment Technology*. 2005; 94-101. Valencia, Spain.

- L Lelas, J., Merriman, G., Riley, P., & Kerrigan, D. Predicting Peak Kinematic and Kinetic Parameters from Gait Speed. *Gait & Posture*.2003; 17(2), 106-112.
- Landis, J., & Koch, G. The measurement of observer agreement for. *Biometrics*. 1977; 33, 159-174.
- Mazzoni, P., Rowla, L., & Pearson, T. Merritt's Nöroloji El Kitabı. (O. Doğu, Çev.) İstanbul: Güneş Tıp. 2009.
- Merker, J., Hartmann, M., Kreuzpointner, F., Schwirtz, A., & Haas, J.-P. Pathophysiology of Juvenile Idiopathic Arthritis Induced Pes Planovalgus in Static and Walking Condition—A functional View Using 3D Gait Analysis. *Pediatric Rheumatology*. 2015; 13(1).
- Metcalf, A. B., & Lawes, N. A Modern Interpretation of the Rood Approach. *Physical Therapy Reviews*. 1998; 3(4), 195-212.
- Meyer, Y. *Wavelets: Algorithms and Applications*. Philadelphia: PA: Society for Industrial and Applied Mathematics. 1993.
- Miller, F., & Bachrach, S. *Cerebral Palsy : A Complete Guide for Caregiving*. Johns Hopkins University Press. 2008.
- Misiti, M., Misiti, Y., Oppenheim, G., & Poggi, J.-M. *Wavelet Toolbox 4 User Guide*. The MathWorks. 2009.
- Moore, S., Macdougall, H., & Ondo, W. Ambulatory Monitoring Of Freezing Of Gait in Parkinson's Disease. *J. Neurosci. Methods*. 2008; 167, 340-348.
- Muro-De-La-Herran , A., Garcia-Zapirain , B., & Mendez-Zorrilla, A. Gait Analysis Methods: An Overview Of Wearable And Non-Wearable Systems, Highlighting Clinical Applications. *Sensors*. 2014; 14, 3362-3394.
- Neville, B., & Goodman, R. *Congenital Hemiplegia*. Mac Keith Press. 2001.
- Oskoui, M., Coutinho , F., & Dykeman, J. An Update on the Prevalence of Cerebral Palsy: a Systematic Review and Meta-analysis. *Developmental Medicine & Child Neurology*. 2013; 55, 509-519.

Otman, S., Karaduman, A., Livaneliođlu, A., Kōse, N., & ve diđerleri. Hemipleji Rehabilitasyonunda Nōrofizyolojik Yaklařımlar. Ankara: Dizayn Ofset. 2001.

Öner, İ., Yeřilyurt, M., & Yılmaz, E. Wavelet Analiz Tekniđi ve Uygulama Alanları. Ordu Üniv. Bil. Tek. Derg. 2017; 7(1), 42-56.

Pandian, S., Arya, K., & Davidson, R. Comparison of Brunnstrom movement Therapy and Motor Relearning Program in Rehabilitation of Post-stroke Hemiparetic Hand: A Randomized Trial. Journal of Bodywork & Movement Therapies. 2012; 16, 330-337.

Panteliadis , C., Tzitiridou, M., & Pavlidou, E. Kongenitale Hemiplegie. Der Nervenarzt. 2007; 78(10), 1188-1194.

Pope, M., Bevins, T., Wilder, D., & Frymoyer, J. The Relationship Between Anthropometric, Postural, Muscular, And Mobility Characteristics Of Males Ages 18–55. Spine. 1985; (10), 644-648.

Reichert, P., Kiełbowicz, Z., Kuryszko, J., & Bocheńska, A. Gait analysis after neurorrhaphy in the brachial plexus. Polish Journal of Veterinary Science. 2015; 18(2), 367-370.

Rossi, J. MicroRNA Methods. Academic Press. 2007.

Roth, E., Merbitz, C., Mroczek, K., Dugan, S., & Suh, W. Hemiplegic Gait. Relationships Between Walking Speed and other Temporal Parameters. American Journal of Physical Medicine & Rehabilitation. 1997; 76(2), 128-133.

Salarian, A., Russmann, H., Vingerhoets, F., Burkhard, P., & Aminian, K. Ambulatory Monitoring Of Physical Activities İn Patients With Parkinsonapōs's Disease. IEEE Trans. Biomed. Eng. 2007; 54, 2296-2299.

Samant , A., & Adeli, H. Feature Extraction for Traffic Incident Detection Using Wavelet Transform and Linear Discriminant Analysis. Computer-Aided Civil and Infrastructure Engineering. 2000; 15, 241–250.

Sekine, M., Tamura, T., Akay, M., Fujimoto, T., Togawa, T., & Fukui, Y. Discrimination of Walking Patterns Using Wavelet-Based Fractal Analysis. IEEE

Transactions on Neural Systems and Rehabilitation Engineering. 2002; 10(3), 188-196.

Sekine, M., Tamura, T., Ogawa, M., Togawa, T., & Fukui, Y. Classification of Acceleration Waveform in a Continuous Walking Record. Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 1998; 20.

Shwartz, S. S., & David, S. B. Understanding Machine Learning. New York: Cambridge University Press. 2014.

Smola, A., & Vishwanathan, S. Introduction to Machine Learning. Cambridge: Cambridge University Press. 2008.

Steultjens, M., Dekker, J., Van Baar, M., Oostendrop, R., & Bijlsma, J. Range Of Joint Motion And Disability İn Patients With Osteoarthritis Of The Knee Or Hip. Rheumatology. 2000; (39), 955-961.

Stinear, C. Prediction of Recovery of Motor Function after Stroke. Lancet Neurol. 2010;32(9), 1228-1232.

Takaoğlu, M. Birkaç Veri Kümesi ile WEKA ve MATLAB Üzerinde Kümeleme Algoritmalarının Karşılaştırılarak İncelenmesi. İstanbul Aydın Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, 2016, İstanbul (Danışman: Prof. Dr. Z Aslan).

Tao, W., Liu, T., Zheng, R., & Feng, H. Gait Analysis Using Wearable Sensors. Sensors. 2012; 2255-2283.

Taswell, C. The What, How, and Why of Wavelet Shrinkage Denoising. Technical Report, Computational Toolsmiths, Stanford. 1999.

Toprak, İ. B. EEG Sinyallerinin Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Analizi. Süleyman Demirel Üniversitesi Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, 2007, Isparta (Danışman: M Merdan).

Turcot, K., Aissaoui, R., Boivin, K., Pelletier, M., Hagemester, N., & De Guise, J. New Accelerometric Method To Discriminate Between Asymptomatic Subjects And

Patients With Medial Knee Osteoarthritis During 3-D Gait. *IEEE Trans. Biomed. Eng.* 2008; (55), 1415-1422.

Vaughan-Graham, J. The Bobath Concept in Contemporary Clinical Practice. *Topics in Stroke Rehabilitation.* 2009; 57-58.

Wang, L., Hu, W., & Tan, T. Recent Developments in Human Motion Analysis. *Pattern Recognit.* 2003; 36, 585-601.

Wang, N., Ambikairajah, E., H. Lovell, N., & G. Celler, B. Accelerometry Based Classification of Walking Patterns Using Time-frequency Analysis. *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale.* 2007; 23-26. Lyon.

Watanabe, K., & Hokari, M. Kinematical Analysis And Measurement Of Sports Form. *IEEE Trans. Syst. Man Cybern. Part A.* 2006; 36, 549-557.

Yardımcı, A. Fuzzy Logic Based Gait Classification for Hemiplegic Patients. *Lecture Notes in Computer Science.* 2007; 4669, 69-79.

You, Y., & Chung, S. The Effects of Gait Velocity on the Gait Characteristics of Hemiplegic Patients. *Journal of Physical Therapy Science.* 2015; (27), 921-924.

YUAN, J., WANG, J., MA, J., ZHU, D., ZHANG, Z., & Jianan, L. Paediatric Cerebral Palsy Prevalence And High-Risk Factors in Henan Province, Central China. *Journal of Rehabilitation Medicine.* 2018; 50, 48-54.

Yüksel, İ. *MATLAB ile Mühendislik Sistemlerinin Analizi ve Çözümü.* Nobel. 2004.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı	Hazal	Uyruğu	T.C.
Soyadı	Taş Atılgan	Tel no	5065110289
Doğum tarihi	06.08.1990	e-posta	hazaltas@akdeniz.edu.tr

Eğitim Bilgileri

	Mezun olduğu kurum	Mezuniyet yılı
Lise	Serik Lisesi	2008
Lisans	Ankara Üniversitesi	2013
Yüksek Lisans	Akdeniz Üniversitesi	Devam ediyor
Doktora		

İş Deneyimi

Görevi	Kurum	Süre (yıl-yıl)
Araştırma Görevlisi	Akdeniz Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıbbi Bilişim ABD	2017-halen

Yabancı Dilleri	Sınav türü	Puanı
İngilizce	YÖKDİL	75

Proje Deneyimi

Proje Adı	Destekleyen kurum	Süre (Yıl-Yıl)

Burslar-Ödüller:

11. Tıp Bilişimi Kongresi, Ankara “en iyi sözlü bildiri” ödülü

Yayınlar ve Bildiriler:

Taş H., Bilge U. NeuroSky Mindwave Beyin Dalgası Sensörü Kullanılabilirlik Testi. Tıp Bilişiminde Yenilikler Sempozyumu, 25 Mart 2017, Ankara

Atılgan Taş H., Bilge U., Yardımcı A. Hemiplejik Yaşlılarda Yürüme Analizi ve Değerlendirilmesi. Uluslararası Katılımlı X. Tıp Bilişimi Kongresi, 12-15 Ekim 2017, Antalya

Atılgan Taş H., Bilge U., Yardımcı A. Hemiplejik Yürüyüşün Dalgacık Dönüşümü ve Yapay Öğrenme Yöntemleri ile Sınıflandırılması. XI. Tıp Bilişimi Kongresi, 16-17 Kasım 2018, Ankara