

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

**KARDİYOTOKOGRAFİ İŞARETLERİNİN ANALİZİ VE MAKİNE  
ÖĞRENMESİ TEKNİKLERİ İLE SINIFLANDIRILMASI**

**ZAFER CÖMERT**

**DOKTORA TEZİ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**HAZİRAN 2017**

Tezin Başlığı : Kardiyotokografi İşaretlerinin Analizi ve Makine Öğrenmesi  
Teknikleri ile Sınıflandırılması

Tezi Hazırlayan : Zafer CÖMERT

Sınav Tarihi : 23/06/2017

Yukarıda adı geçen tez jürimizce değerlendirilerek Bilgisayar Mühendisliği Ana Bilim Dalında Doktora Tezi olarak kabul edilmiştir.

### **Sınav Jüri Üyeleri**

**Tez Danışmanı : Yrd. Doç. Dr. Adnan Fatih KOCAMAZ** .....  
İnönü Üniversitesi

**Prof. Dr. Ali KARCI** .....  
İnönü Üniversitesi

**Prof. Dr. İbrahim TÜRKOĞLU** .....  
Fırat Üniversitesi

**Prof. Dr. Mehmet KAYA** .....  
Fırat Üniversitesi

**Doç. Dr. Davut HANBAY** .....  
İnönü Üniversitesi

**Prof. Dr. H. İbrahim ADIGÜZEL**  
Enstitü Müdürü

## ONUR SÖZÜ

Doktora Tezi olarak sunduđum “*Kardiyotokografi İşaretlerinin Analizi ve Makine Öğrenmesi Teknikleri ile Sınıflandırılması*” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Zafer CÖMERT

# ÖZET

Doktora Tezi

## KARDİYOTOKOGRAFİ İŞARETLERİNİN ANALİZİ VE MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE SINIFLANDIRILMASI

Zafer CÖMERT

İnönü Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

181 + xii sayfa

2017

Danışman: Yrd. Doç. Dr. Adnan Fatih KOCAMAZ

Kardiyotokografi (KTG) fetal sağlık durumunun belirlenmesi amacıyla gebelik dönemi ve doğum sırasında yaygın şekilde kullanılan bir fetal gözetim tekniğidir. Bir KTG testi, fetal kalp hızı (FKH) ve rahim kasılmalarını (RK) içeren başlıca iki biyofiziksel işaretin eşzamanlı olarak kayıt edilmesiyle elde edilmektedir. Bir gözetim tekniği olarak KTG, düşük pozitif tahmin değeri, yüksek yanıltıcılık oranı, yorumlanmasındaki öznellik, yeniden üretilebilirlik değerindeki tutarsızlık ve yüksek seviyede gözlem içi ve gözlemciler arası anlaşmazlık seviyesi gibi çeşitli problemlere sahiptir. KTG testi 1960'lı yılların sonlarından günümüze, dünya genelinde kliniksel olarak rutin bir şekilde uygulanmasına karşın, bu tanı testinin geçerliliği ve faydaları üzerindeki tartışmalar literatürde hala devam etmektedir. KTG'nin sahip olduğu problemlerin üstesinden gelmek üzere bilgisayar destekli KTG analizi en umut verici yöntem olarak görülmektedir. Tez çalışmasında öncelikle KTG analizi için geleneksel olarak kullanılan morfolojik özellikler dikkate alınmıştır. Aynı zamanda tanı için öncelik arz eden FKH işaretlerinin doğrusal ve doğrusal olmayan özellikleri çıkartılmıştır. Ayrıca, kliniksel açıdan vazgeçilmez olarak kabul edilen FKH değişkenliğini saptamak üzere zaman ve frekans alanında araştırmalar yürütülmüştür. Entropi tahmin edicilerine dayalı doğrusal olmayan analiz gerçekleştirilmiştir. Zaman-frekans alanında, farklı frekans aralıklarına odaklanan ve doku tanımlayıcılarına dayalı yeni bir özellik çıkarma yöntemi önerilmiştir. Bu kapsamda, gri seviyeli eş oluşum matrisi, lokal ikili desen ve bölütleme tabanlı fraktal doku analiz metotları literatüre kazandırılmıştır. Tez sürecinde yapılan çalışmalar neticesinde, KTG işaretlerini morfolojik, doğrusal, doğrusal olmayan, frekans ve zaman-frekans alanlarında analiz edilmesini sağlayan bir yazılım geliştirilmiştir. KTG işaretlerinin normal ve hipoksik olarak sınıflandırılmasını sağlamak üzere yapay sinir ağı, aşırı öğrenme makinesi, destek vektör makinesi, radyal tabanlı fonksiyon ağı gibi çeşitli makine öğrenmesi tekniklerinin kullanılması sağlanmıştır.

ANAHTAR KELİMELELER : Kardiyotokografi, fetal kalp hızı, sınıflandırma, makine öğrenmesi.

## **ABSTRACT**

Ph.D. Thesis

### **ANALYSIS OF CARDIOTOCOGRAPHY SIGNALS AND CLASSIFYING WITH MACHINE LEARNING TECHNIQUES**

Zafer CÖMERT

İnönü University  
Graduate School of Natural and Applied Sciences  
Department of Computer Engineering

181 + xii pages

2017

Supervisor: Asst. Prof. Adnan Fatih KOCAMAZ

Cardiotocography (CTG) is a fetal surveillance technique which is widely used to determine fetal well-being during pregnancy and delivery. A CTG test consists of two biophysical signals which are fetal heart rate (FHR) and uterine contraction (UC) recorded simultaneously. As a surveillance technique, CTG has various problems, such as poor positive prediction value, high false positive rate, subjective of interpretation, inconsistency in reproducibility value and high level of disagreement between intra- and inter-observers. Although CTG has been practiced routinely in clinics since end of the 1960s, the debates on validity and usefulness of this diagnosis test have been carried on still in the literature. The computerized CTG analysis is seen as the most promising method to overcome these drawbacks. In the thesis, the traditionally used morphological features were taken into consideration primarily. At the same time, the linear and nonlinear features of FHR that are prominent indices in terms of diagnosis were extracted. Besides, several studies have been carried out in time and frequency domain to determine FHR variability that is regarded as indispensable part of clinic assessment. Nonlinear analysis based on entropy estimators was performed. In time-frequency field, a novel feature extraction method focusing on different frequency intervals and based on texture descriptors has been proposed. In this context, gray level co-occurrence matrix, local binary pattern, and segmentation fractal texture analysis methods have been added to the literature. As a result of the studies conducted in the thesis process, a software has been developed which enables the analysis of CTG signals in morphological, linear, nonlinear, frequency, and time-frequency fields. Various machine learning techniques, such as artificial neural network, extreme learning machine, support vector machine, radial basis network were employed to provide the classification of CTG signals as normal and hypoxic as well as the performance comparison.

**KEYWORDS:** Cardiotocography, fetal heart rate, classification, machine learning

## TEŐEKKÜR

Tez alıőmamın her aőamasında gerek bilgi ve tecrübesiyle, gerekse samimi ve insani yönüyle bana destek olan ve akademik anlamda ufkumu aan danıőman hocam Sayın Yrd. Do. Dr. Adnan Fatih KOCAMAZ'a;

Yeni aılan bir üniversitede biliőim alanında görev yapmanın zorluklarına raėmen, doktora baőlama ve devam etme sürecinde göstermiő olduėu anlayıő ve büyük desteklerinden ötürü Bitlis Eren Üniversitesi kurucu rektörü Prof. Dr. Mahmut DOėRU'ya;

Doktora süreci boyunca saėlamıő oldukları iőbirliki, profesyonel ve huzurlu alıőma ortamından dolayı baőta Prof. Dr. Ali KARCI olmak üzere, Do. Dr. Davut HANBAY, Do. Dr. M. Fatih TALU, Yrd. Do. Dr. Berat DOėAN ve İnönü Üniversitesi Bilgisayar Mühendisliėi Bölüm alıőanlarının tümüne;

Yürütölen tez alıőmasının klinik ayaėında bizi destekleyen ve gönüllü olarak yardımcı olan baőta Dr. Sami GÜNGÖR ve diėer uzman doktora;

Görev yaptığım üniversitede, bulunduėum birimdeki iő yoğunluėuna raėmen doktora alıőması yapmamda bana maddi ve manevi her türlü desteėi veren, teknik aıdan tartıőmalar yapan ve yayın yazımı noktasında tecrübelerini paylaőan deėerli arkadaşlarıma;

Ayrıca bu süreçte sabır ve anlayıőından ötürü, her zaman yanımda olan sevgili eőim Özge CÖMERT'e, biricik oėlum Yiėit Muaz CÖMERT'e, aileme ve tüm dostlarıma teőekkür ederim.

Zafer CÖMERT

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>İÇİNDEKİLER</b> .....	<b>iv</b>
<b>ŞEKİLLER LİSTESİ</b> .....	<b>vii</b>
<b>ÇİZELGELER LİSTESİ</b> .....	<b>ix</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>x</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1. Fetal Fizyolojisi.....	2
1.1.1. Fetal Hücre Yapısı.....	2
1.1.2. Fetal Stres Seviyeleri.....	4
1.1.3. Fetal Kalp Hızı Değişkenliği.....	5
1.1.4. Fetal Sağlık Durumunun Değerlendirilmesi için Kullanılan İlave Testler .....	5
1.1.5. Doğum Sonrası Geriye Dönük Fetal Değerlendirmesi için Asit-Baz Analizi ...	7
1.2. Kardiyotokografi Testine Genel Bakış.....	8
1.2.1. Teknik Açından Kardiyotokografi .....	9
1.2.2. Kliniksel Açından Kardiyotokografi.....	10
1.2.3. Kardiyotokografi İşaretinin Analizi .....	11
1.2.4. Kardiyotokografi İşaretinin Sınıflandırılması .....	12
1.2.5. Bilgisayarlı Kardiyotokografi Analizi.....	13
1.3. Tez Hakkında .....	14
1.3.1. Tezin Hedefleri.....	14
1.3.2. Tezin Organizasyonu .....	16
1.3.3. Tezin Çıktıları .....	16
<b>2. KAYNAK ÖZETLERİ</b> .....	<b>18</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>45</b>
3.1. Veri Koleksiyonları.....	46
3.1.1. UCI-KTG Veri Seti.....	46
3.1.2. CTU-UHB Veri Tabanı.....	47
3.2. Önışleme .....	49
3.3. Morfolojik Özellikler .....	51
3.3.1. Temel Kalp Hızı.....	51
3.3.2. Temel Kalp Hızı Tahmin Algoritması .....	52
3.3.3. Hızlanma Örüntülerinin Tespit Edilmesi .....	54
3.3.4. Yavaşlama Örüntülerinin Tespit Edilmesi .....	57

3.3.5. Değişkenlik .....	59
3.4. Doğrusal Özellikler .....	59
3.5. Doğrusal Olmayan Özellikler .....	60
3.5.1. Yaklaşım Entropi .....	61
3.5.2. Örnek Entropi.....	62
3.5.3. Lempel Ziv Karmaşıklığı .....	63
3.6. Zaman-Frekans Özellikleri.....	64
3.6.1. Zaman-Frekans Analizi.....	64
3.6.2. Kısa Zamanlı Fourier Dönüşümü ve Spektrogram .....	64
3.6.3. Güç Spektrum Yoğunluğu .....	65
3.7. İmge Tabanlı Zaman-Frekans Özellikleri .....	67
3.7.1. Gri Seviyeli Eş Oluşum Matrisi .....	71
3.7.2. Yerel İkili Desen .....	74
3.7.3. Bölme Esaslı Fraktal Doku Analizi .....	75
3.8. Dalgacık Dönüşüm Özellikleri.....	76
3.9. Özellik Seçimi.....	79
3.9.1. <i>t</i> -Testi .....	79
3.9.2. Geriye Doğru Özellik Seçimi.....	81
3.9.3. Temel Bileşenler Analizi.....	81
3.10. Sınıflandırıcılar .....	82
3.10.1. Yapay Sinir Ağları .....	82
3.10.2. Aşırı Öğrenme Makineleri .....	84
3.10.3. Destek Vektör Makineleri .....	86
3.10.4. <i>k</i> -EK Yakın Komşu Sınıflandırıcısı.....	90
3.10.5. Radyal Tabanlı Fonksiyon Ağı .....	91
3.10.6. Rastgele Orman.....	93
3.11. Performans Ölçütleri .....	94
3.11.1. Karmaşıklık Matrisi .....	94
3.11.2. Çok-Sınıflı Sınıflandırıcılar için Performans Metrikleri.....	98
3.11.3. AİK Eğrisi .....	98
3.11.4. <i>k</i> -Katlı Çapraz Doğrulama .....	99
<b>4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....</b>	<b>101</b>
4.1. Sentetik EKG İşaretleri Üzerinde QT Aralığının Belirlenmesi .....	101
4.2. Makine Öğrenmesi Tekniklerinin Karşılaştırılması.....	105
4.3. YSA Öğrenme Algoritmalarının Değerlendirilmesi .....	108
4.4. YSA ve AÖM ile KTG Analizi.....	113



4.5. Eş Oluşum Matrisi ve YSA'ya Dayalı FKH Analizi .....	115
4.6. Doğrusal ve Doğrusal Olmayan Özelliklere Dayalı FKH Analizi.....	117
4.7. BFDA ve AÖM'ye Dayalı FKH Analizi .....	122
4.8. Dalgacık Dönüşümüyle KTG İşaretlerinin Sınıflandırılması .....	125
4.9. FKH Analizi için Yeni Bir Prognostik Model Önerisi.....	130
4.10. Kardiyotokografi Analiz Yazılımı .....	140
4.10.1. Dosya İşlemleri .....	142
4.10.2. Temel Araç Kutusu İşlemleri .....	142
4.10.3. Önışleme İşlemleri .....	142
4.10.4. Gelişmiş Analiz İşlemleri.....	143
4.10.5. Çizim İşlemleri.....	148
4.10.6. Gözlemci Görüşlerinin Değerlendirilmesi .....	149
4.10.7. Sınıflandırma İşlemleri.....	149
4.11. KTG Analizi için Yapılan Diğer Çalışmalar Üzerine Bir Karşılaştırma .....	151
<b>5. SONUÇ VE ÖNERİLER.....</b>	<b>161</b>
<b>6. KAYNAKAR .....</b>	<b>165</b>
<b>ÖZGEÇMİŞ.....</b>	<b>180</b>

## ŞEKİLLER LİSTESİ

Şekil 1.1. Hücre enerji metabolizması .....	3
Şekil 1.2. Kan gazları ve kalp fonksiyonu arasındaki ilişki.....	3
Şekil 1.3. Fetüs sağlık durumu değerlendirme testleri.....	6
Şekil 1.4. Fetal kalp hızı ve rahim aktivitesinin kayıt edilmesi .....	9
Şekil 1.5. KTG'nin kliniksel olarak uygulanması.....	11
Şekil 1.6. Örnek bir KTG şeridi .....	11
Şekil 3.1 CTU-UHB kayıtlarının etiketlenmesi.....	48
Şekil 3.2 Ham bir FKH işaret örneği .....	50
Şekil 3.3 Önışleme öncesi ve sonrası örnek bir FKH işareti .....	51
Şekil 3.4 TKH tahmin algoritması .....	53
Şekil 3.5 (a) Örnek bir FKH işareti, (b) FKH için TKH tahmini.....	55
Şekil 3.6 Hızlanma örüntülerinin tahmini için akış şeması.....	56
Şekil 3.7 Hızlanma örüntülerinin tespit edilmesi.....	57
Şekil 3.8 Yavaşlama örüntülerinin tespit edilmesi.....	59
Şekil 3.9 (a) Normal ve (b) Hipoksik FKH işaretleri ve spektrogramları.....	65
Şekil 3.10 Güç spektral yoğunluk tahmini .....	67
Şekil 3.11 Normal bir FKH işareti için spektral bant aralıkları ve gri imgeler.....	68
Şekil 3.12 Hipoksik bir FKH işareti için spektral bant aralıkları ve gri imgeler .....	69
Şekil 3.13 Normal ve hipoksik FKH işareti için ait spektrogramlar .....	70
Şekil 3.14 Açısal en yakın komşular.....	72
Şekil 3.15 GSEM algoritması .....	72
Şekil 3.16 Yerel ikili desenin hesaplanması .....	74
Şekil 3.17 Dalgacık dönüşümünün alt-bant ayrışması.....	77
Şekil 3.18 Dalgacık ayrışımı .....	78
Şekil 3.19 Deneysel kümülatif dağılım grafiği .....	80
Şekil 3.20 Yapay sinir ağı modeli .....	82
Şekil 3.21 DVM için verilerin dağılımı ve en büyük aralıklı sınıflandırıcı.....	87
Şekil 3.22 Tipik bir radyal tabanlı fonksiyon ağı.....	91
Şekil 3.23 Rastgele orman algoritması.....	94
Şekil 3.24 Hata matrisi.....	95
Şekil 3.25 Örnek bir AİK grafiği .....	99
Şekil 3.26 10-katlı çapraz doğrulama.....	100
Şekil 4.1 Bir elektrokardiyografi işaretinin karakteristik özellikleri .....	102
Şekil 4.2 EKG işareti üzerinde Q ve T noktalarının tespit edilmesi .....	103
Şekil 4.3 Sentetik EKG işaretleri üretme ekranı .....	104
Şekil 4.4 QT analiz ekranı.....	104
Şekil 4.5 AÖM'nin yapılandırılması.....	106
Şekil 4.6 AÖM'nin gizli katmandaki düğüm sayısına karşılık performansı.....	107
Şekil 4.7 YSA topolojisi .....	109
Şekil 4.8 YSA eğitim algoritmaları performans sonuçları.....	111
Şekil 4.9 Eğitim algoritmalarının performans ve eğim karakteristikleri .....	112
Şekil 4.10 LM algoritması AİK eğrileri.....	112
Şekil 4.11 Adım adım ağ eğitimi .....	113
Şekil 4.12 Veri setinin iki boyutlu TBA eksenine yansıtılması.....	116

Şekil 4.13 Doğum aşamaları boyunca analizin blok şeması .....	119
Şekil 4.14 Doğum aşamaları boyunca verilerin dağılımı, analizin 1. aşaması .....	119
Şekil 4.15 Doğum aşamaları boyunca verilerin dağılımı, analizin 2. aşaması .....	120
Şekil 4.16 Doğum aşamaları boyunca verilerin dağılımı, analizin 3. aşaması .....	120
Şekil 4.17 Yeni bir prognostik model önerisi .....	130
Şekil 4.18 Deneysel frekans aralıklarına göre spektrogramlar .....	133
Şekil 4.19 Verilerin 2 boyutlu TBA eksenine dağılımı ve marjinal histogramları ..	135
Şekil 4.20 Kardiyotokografi yazılımı ana ekranı .....	141
Şekil 4.21 Kayıp atımları gösteren ekran .....	142
Şekil 4.22 Önişleme öncesi ve sonrası FKH işaretinin grafiksel gösterim ekranı ...	143
Şekil 4.23 Hızlanma ve yavaşlama örüntülerinin saptanması ekranı.....	144
Şekil 4.24 Bir hızlanma örüntüsüne ait istatistiksel özellik ekranı .....	145
Şekil 4.25 Bir yavaşlama örüntüsüne ait istatistiksel özellik ekranı .....	145
Şekil 4.26 Komut isteminde hızlanma örüntülerinin elde edilmesi .....	146
Şekil 4.27 TKH tahmin ekranı .....	147
Şekil 4.28 Doğrusal ve doğrusal olmayan özelliklerin hesaplandığı ekran .....	147
Şekil 4.29 ÇDF'ye İTZF özellikleri ekranı .....	148
Şekil 4.30 DF'ye İTZF özellikleri ekranı.....	148
Şekil 4.31 Gözlemci görüşlerinin değerlendirilme ekranı .....	149
Şekil 4.32 YSA sınıflandırma ekranı .....	150
Şekil 4.33 YSA için karmaşıklık matrisi ve performans değerlerini gösteren ekran	150

## ÇİZELGELER LİSTESİ

Çizelge 1.1. FIGO sınıflandırma ölçütleri .....	13
Çizelge 3.1 UCI-KTG veri setinin sahip olduğu özelliklerin açıklanması .....	47
Çizelge 3.2 CTU-UHB veri tabanı için hasta ve doğum sonuçları ait veriler.....	48
Çizelge 3.3. Deneysel frekans aralıkları .....	66
Çizelge 3.4 Yapay sinir ağı eğitim algoritmaları .....	84
Çizelge 4.1 ECGSYN parametreleri ve varsayılan değerleri.....	102
Çizelge 4.2 Standart QT aralığının özellikleri .....	103
Çizelge 4.3 Makine öğrenmesi tekniklerinin performans sonuçları .....	105
Çizelge 4.4 YSA eğitim algoritmaları.....	108
Çizelge 4.5 YSA eğitim algoritmaları performans sonuçları.....	110
Çizelge 4.6 YSA ait performans sonuçları.....	114
Çizelge 4.7 YSA ve AÖM sonuçlarının karşılaştırılması .....	114
Çizelge 4.8 GSEM dayalı analiz için elde edilen özellik seti .....	115
Çizelge 4.9 GSEM ve YSA'ya dayalı performans sonuçları.....	116
Çizelge 4.10 Örnek bir kaydın uzmanlar tarafından etiketlenmesi.....	118
Çizelge 4.11 Doğum aşamaları boyunca kayıtların dağılımı .....	118
Çizelge 4.12 Doğum aşamaları boyunca kullanılan özellikler.....	121
Çizelge 4.13 Sadece doğrusal özellikler ile elde edilen sonuçlar .....	121
Çizelge 4.14 Sadece doğrusal olmayan özellikler ile elde edilen sonuçlar.....	122
Çizelge 4.15 Doğrusal ve doğrusal olmayan özellikler ile elde edilen sonuçlar .....	122
Çizelge 4.16 BFDA ve AÖM'ye dayalı özellik seti .....	123
Çizelge 4.17 Frekans alanında elde edilen özellikler.....	124
Çizelge 4.18 AÖM sınıflandırma sonuçları .....	124
Çizelge 4.19 Haar dalgacık ailesi ve k-EK sonuçları.....	126
Çizelge 4.20 db5 dalgacık ailesi ve k-EK sonuçları .....	126
Çizelge 4.21 sym5 dalgacık ailesi ve k-EK sonuçları.....	127
Çizelge 4.22 haar dalgacık ailesi ve YSA sonuçları .....	127
Çizelge 4.23 db5 dalgacık ailesi ve YSA sonuçları .....	128
Çizelge 4.24 sym5 dalgacık ailesi ve YSA sonuçları .....	128
Çizelge 4.25 Deneysel frekans aralıkları .....	132
Çizelge 4.26 Prognostik model için organize edilmiş tüm özellikler .....	134
Çizelge 4.27 GDÖS algoritmasına göre seçilen özellikler.....	134
Çizelge 4.28 Prognostik model için elde edilen özellik setleri .....	135
Çizelge 4.29 Prognostik model ile elde edilen sınıflandırma sonuçları.....	136
Çizelge 4.30 $p < 0.01$ ve $p < 0.05$ için anlamlı İTZF özellikleri .....	138
Çizelge 4.31 Boyut indirgemesi sonucu elde edilen performans sonuçları .....	139
Çizelge 4.32 KTG analizi için kullanılan veri setlerine genel bir bakış .....	152
Çizelge 4.33 KTG analizi için kullanılan veri setlerine dair ek bilgiler .....	154
Çizelge 4.34 Makine Öğrenmesi Tekniklerinin Karşılaştırılması.....	157
Çizelge 4.35 UCI-KTG veri seti üzerinde yapılan çalışmalar .....	159

## SİMGELER VE KISALTMALAR

$M_{\delta, \theta=0}(p, q)$	Eş oluşum matrisi
$\mu_x$	Matris satırlarının ortalama değeri
$\mu_y$	Matris sütunlarının ortalama değeri
$\sigma_x$	Matris satırlarının standart sapması
$\sigma_y$	Matris sütunlarının standart sapması
$s(.)$	YİD operatörü
$I$	Gri ölçekli imge
$I_b$	İkili imge
$\Delta$	Çerçeve imge
$n_l$	Gri seviye aralığı
$T$	Eşik değer seti
$D$	Fraktal boyut
$D_0$	Hausdorff fraktal boyutu
$\epsilon$	Kutu sayma algoritmasında kutu boyutu
$V_{BFDA}$	BFDA özellik vektörü
$\psi$	Ana dalgacık fonksiyonu
$h[n]$	Yüksek geçiren filtre
$g[n]$	Alçak geçiren filtre
$H$	Aşırı öğrenme makinesi için aktivasyon matrisi
$H^\dagger$	$H$ matrisinin genelleştirilmiş tersi (Moore-Penrose)
$b$	Hiper düzlemin yönelimi
$K$	Kernel fonksiyonu
$L$	Saçılım (kovaryans) matrisi
$L_p$	Lagrange fonksiyonu
$\alpha_i$	Lagrange çarpanları
$\zeta_i$	DVM eğitim hata sapması
$x$	Girdi vektörü
$y$	Sınıf vektörü
$N$	Girdi vektörlerinin uzunluğu
$\mathcal{S}$	Destek vektörleri
$d_E$	Öklid mesafesi
$h$	Radyal tabanlı fonksiyon (RTF)
$h_p$	p'ninci nöronla ilişkili RTF
$H$	RTFA için tasarım matrisi

$c$	RTF için merkez parametresi
$r$	RTF için yarıçap parametresi
ACOG	Amerikan Doğum Uzmanları ve Jinekolog Meclisi
ADD	Ayrık dalgacık dönüşümü
AE	Aralık Endeksi
AİK	Alıcı işletim karakteristiği
AİK-AKA	Alıcı işletim karakteristiği altında kalan alan
BCO	Bulanık c-ortalama
BDFD	Bilgisayar destekli fetal değerlendirici
BFDA	Bölme esaslı fraktal doku analizi
CTU-UHB	CTU-UHB doğum dönemine ait veri tabanı
ÇDF	Çok-düşük frekans
ÇKAM-SA	Çok-katmanlı algılayıcı model sinir ağı
ÇÖE	Çok ölçekli entropi
DA	Diskriminant analizi
DAS	Dakikadaki atım sayıları
DDA	Doğrusal diskriminant analizi
DF	Düşük frekans
DMA	Deneysel/Ampirik mod ayrışımı
DN	Doğru Negatif
DP	Doğru Pozitif
DVM	Destek vektör makinesi
EEG	Elektroensefalografi
EFM	Elektronik fetal monitör
EK-DVM	En küçük kareler destek vektör makineleri
EKG	Elektrokardiyografi
EYK	En yakın komşu
FEKG	Fetal elektrokardiyogram
FFS	Fetal fizyolojik skoru
FIGO	Uluslararası Kadın Hastalıkları ve Doğum Federasyonu
FKH	Fetal kalp hızı
FKHD	Fetal kalp hızı değişkenliği
FKÖ	Fetal kan örnekleme
FOSS	Fetal otonom sinir sistemi
GDÖS	Geriye doğru özellik seçimi
GR-SA	Genelleştirilmiş regresyon sinir ağı
GSEM	Gri seviyeli eş oluşum matrisi
GSY	Güç spektrum yoğunluğu
GUGA	Geliştirilmiş uyarlamalı genetik algoritma
HFDE	Hızlanma fazı doğrultulmuş eğitim
İEİA	İki-eşik ikili ayrışım
İTZF	İmge tabanlı zaman-frekans
KA	Karar ağaçları
k-EK	k-En yakın komşu
KHD	Kalp hızı değişkenliği
KHSE	Kubik Hermit spline enterpolasyon

KST	Kasılma stres testi
KTG	Kardiyotokografi
KZD	Kısa zamanlı deęişkenlik
KZFD	Kısa zamanlı Fourier dönüşümü
LDVM	Lagrangian destek vektör makinesi
LZK	Lempel Ziv Karmaşıklığı
NST	Non-stres test
OF	Orta frekans
OFDE	Ortalama faz doğrultulmuş eğitim
OKH	Ortalama kare hata
O-SA	Olasılıksal sinir ağı
RİBS	Rahim-içi büyüme sınırlılığı
RK	Rahim kasılması
RO	Rastgele orman
RTF	Radyal taban fonksiyonu
RTFA	Radyal tabanlı fonksiyon ağı
STAN	ST Analizi
SVD	Sempatovagal denge
TBA	Temel bileşenler analizi
TKH	Temel kalp hızı
UBSÇS	Uyarlanabilir bulanık-sinir çıkarım sistemi
UCI-KTG	Sisporto veri seti
UDD	Uzun dönemli düzensizlik/deęişkenlik
US	Doppler ultrason
WEKA	Bilgi Analizi için Waikato Ortamı
<i>YaEn</i>	Yaklaşım entropisi
YF	Yüksek frekans
YFDE	Yavaşlama fazı doğrultulmuş eğitim
YİD	Yerel ikili desen
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay sinir ağı

## 1. GİRİŞ

Doğum tüm canlıların hayatındaki en önemli ve kritik gelişmelerden biridir. Bir ceninin anne rahmine düşmesiyle başlayan ve bebeğin dünyaya gelmesiyle sonlanan bu süreç, tekrar ve tekrar meydana gelen pek çok stresli durumu içinde barındırmaktadır. Doğum ve gebelik sürecinin hem anne hem de bebek açısından sağlıklı bir şekilde yönetilmesi hayati bir konudur. Bu bağlamda, gebeliğin çeşitli dönemlerinde pek çok farklı yöntem ve test hali hazırda zaten uygulanmaktadır.

Bu doktora tez çalışmasında, gebelik ve doğum sürecinin sağlıklı bir şekilde yönetilmesine katkı sunan yöntemlerden biri olan ve dünya genelinde kliniksel olarak yaygın bir şekilde kullanılan kardiyotokografi (KTG) testine odaklanılmıştır. Araştırma kapsamında, testin genel hatlarıyla tanıtılması, sahip olduğu avantaj ve dezavantajların ortaya konması, bilgisayar destekli yaklaşımlarla analiz edilmesi ve özellikle makine öğrenmesi teknikleriyle KTG örneklerinin normal ya da patolojik olarak sınıflandırılmasını sağlamak üzere geniş ölçekte bir araştırma yürütülmüştür.

Bu amaç kapsamında, öncelikle KTG testi ve sağladığı örüntüleri yorumlayabilmek için fizyolojik arka plan açıklanmış, daha sonra literatürde yapılan çalışmalar kronolojik bir sırayla incelenmiştir. Sonraki adımda, gelişmiş pek çok işaret ve imge işleme metotlarına ek olarak, imge tabanlı zaman-frekans özelliklerinin çıkarımına dayanan yeni bir yöntem önerilmiştir. Morfolojik, doğrusal, doğrusal olmayan ve zaman-frekans alanlarından elde edilen pek çok prognostik göstergelerle fetal kalp hızı (FKH) işaretlerini tanımlayan özellik setleri oluşturulmuş ve çeşitli makine öğrenmesi yöntemleri kullanılarak tanı sürecini destekleyecek bilgisayar destekli KTG analiz yaklaşımları önerilmiştir. Ayrıca, KTG işaretlerinin analizinin bilgisayar-destekli olarak objektif bir şekilde yapılmasını sağlamak ve işarete dair yorumların yeniden üretilebilmesine olanak sağlamak üzere bir yazılım geliştirilmiştir. Nihai olarak, elde edilen sonuçlar paylaşılarak, mevcut çalışmalarla kıyaslanmış ve gelecekte gerçekleştirilmesi öngörülen araştırma önerileri sunulmuştur.

Bu bölümde, öncelikle KTG testinin anlaşılmasını sağlamak üzere, fetüs fizyolojisi genel hatları açıklanmış, KTG testi genel olarak özetlenmiş ve son olarak tezin amaçları, organizasyonu ve çıktıları sunulmuştur.



## 1.1. Fetal Fizyolojisi

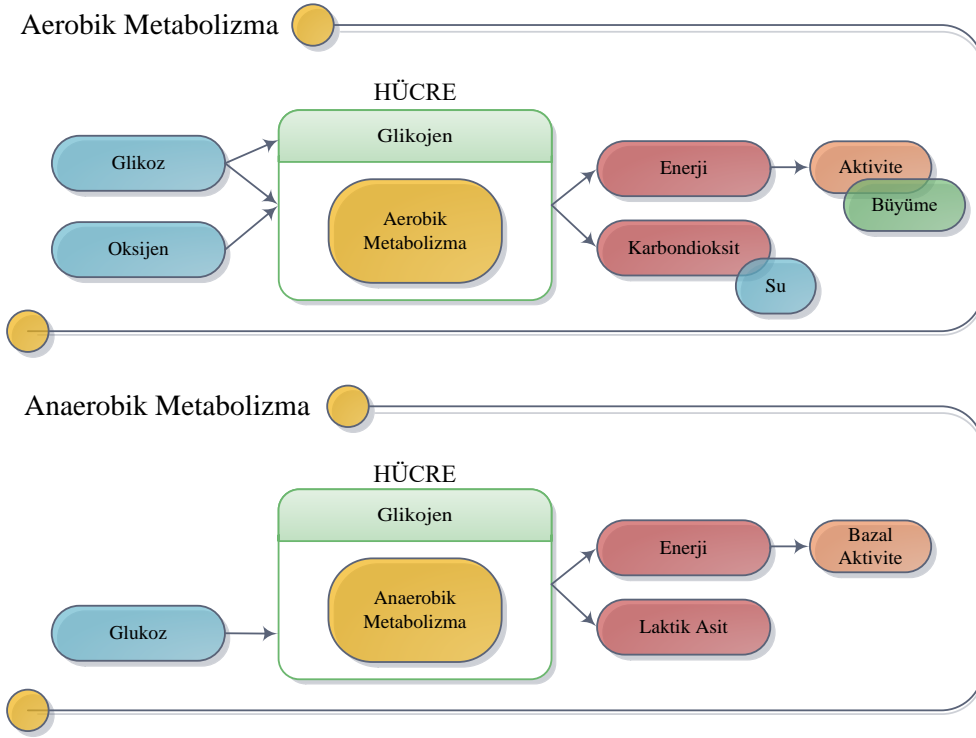
Güvenilir bir KTG yorumu gerçekleştirebilmek için fetüs fizyolojisinin anlaşılması ve risk oluşturabilecek dönemlerin belirlenmesi önemlidir. Doğum, gebelik dönemiyle kıyaslandığında, çok daha kısa süren bir süreç olmasına rağmen oksijen yetmezliğine bağlı olarak gerçekleşen pek çok istenmeyen olay bu süreçte ortaya çıkmaktadır [1]. Buna karşın, doğum stresiyle baş etmek üzere fetüs, güçlü bir savunma mekanizmasıyla donatılmıştır.

Normal bir gebelik yaklaşık olarak kırk hafta kadar sürmektedir. Dolaşım, solunum ve sinir gibi karmaşık sistemlerin gelişimi, bir başka ifadeyle “*fetüs olgunlaşması*” da bu dönem içerisinde gerçekleşmektedir. Doğal olarak en temel yaşam belirtisi olan FKH işareti, çeşitli dönemlere ve durumlara has bir takım karakteristik özellikler taşımaktadır. Bu nedenle, fetüs fizyolojisine ek olarak fetüsün, otonom sinir sistemi ve rahim aktiviteleriyle olan ilişkisinin anlaşılması, FKH örüntülerinin anlaşılması ve yorumlanması açısından önemlidir.

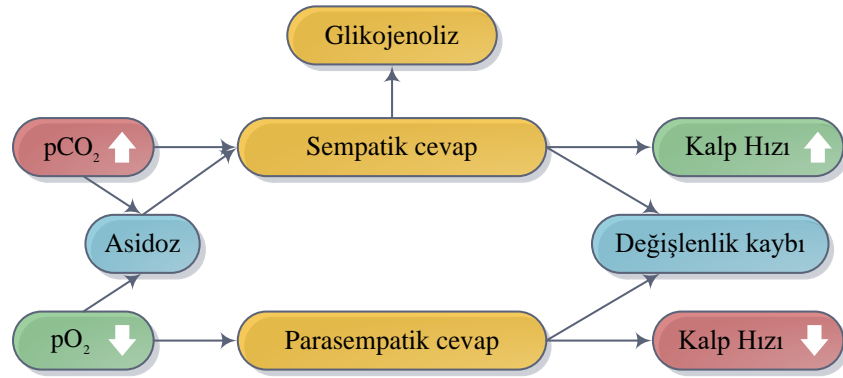
### 1.1.1. Fetal Hücre Yapısı

Fetüs fizyolojisini tanımlamak üzere öncelikle hücre yapısına değinilmelidir. Şekil 1.1’de bir hücrenin enerji metabolizmasına yer verilmiştir. Hücre metabolizması ağırlıklı olarak glikoz ve oksijenden faydalanır. Bu aerobik, oksijen-bağımlı metabolizma olarak ifade edilir. Bazı glikozlar hücreler tarafından alınıp glikojen olarak depolanabilir. Bu depolama son üç ay boyunca gerçekleşir. Aerobik metabolizma sırasında üretilen enerji, aktivite ve büyüme için kullanılır. Bu sırada açığa çıkan karbondioksit ve su atık maddelerdir ve hücrelerden taşınması gerekir [2].

Otonom sinir sistemi oksijen eksikliğine bağlı olarak farklı davranışlar sergilemektedir. Otonom sinir sistemi, humoral (salgıya dayalı) ve nöral (sempatik ve parasempatik) sistemlerden oluşur. Parasempatik sistem ani değişikliklere hemen tepki verir ve fetal kalp hızının yavaşlamasına neden olur; tersine sempatik sinir sistemi ise fetal kalp hızının artmasını sağlamaktadır [2]. Sempatik ve parasempatik sinir sistemlerinin kalp hızını düzenleme refleksi doğrusal olarak değişmemektedir [3]. Fetal kalp hızındaki değişiklikler dönüşümlü olarak çevresel faktörlerin etkisinde sempatik ve parasempatik sinir sistemleri ile kontrol edilmektedir. Sempatik ve parasempatik sinir sistemi fetal kalp hızını ve kan dağıtımını çevresel değişimlere bağlı olarak Şekil 1.2’de gösterildiği gibi düzenlemektedir.



Şekil 1.1. Hücre enerji metabolizması



Şekil 1.2. Kan gazları ve kalp fonksiyonu arasındaki ilişki

Hipoksi sırasında fetüs, aerobik metabolizmayı oksijen-bağımsız metabolizma olan anaerobik metabolizma ile destekleme yeteneğine sahiptir. Kan şekeri ve depolanan glikojen bazal aktivite süresince enerji kaynağı olarak kullanılır. Bu sürecin sonunda Şekil 1.1’de gösterildiği gibi laktik asit üretilir. Hipoksi neticesinde fetal gelişim kısıtlanır. Eğer oksijen desteği tekrar sunulmaz ise hipoksemi, hipoksi ve sırasıyla asfeksi gelişir. Bu terimler fetal arter oksijen doygunluk oranını temsil etmektedir [4].

### 1.1.2. Fetal Stres Seviyeleri

Fetüs oksijen yetmezliği ile karşı karşıya kaldığı anda savunma mekanizmasını çalıştırır. Bunu yaparken de kalp hızını yavaşlatarak enerji tüketimini düşürür ve buna bağlı olarak hipoksemi, hipoksi ve asfeksi olarak ifade edilen ve çeşitli seviyelerdeki oksijen yetmezliğini belirten stres durumları ortaya çıkar [5].

*Hipoksemi* en az risk taşıyan durum olarak ifade edilir ve yalnızca arteriyel kandaki oksijen düşüşünü ifade eder. Oksijen yetmezliğinin başlangıcıdır. Sağlıklı bir fetüs hipoksemi durumuyla günlerce, hatta haftalarca mücadele edebilir. Fetüs oksijen alımını daha verimli hale getirip, aktivitelerini azaltarak ve büyüme hızını düşürerek bu stres durumu ile mücadele eder. Fetüs aktivitesinin düşmesi, fetal solunumun yavaşlaması fetüs savunma mekanizmasının amacına hizmet eder. Öte yandan, hücreler ve organlar normal fonksiyonlarını sürdürür [2].

*Hipoksi*, çevresel dokuların etkilenmesi durumuna bağlı olarak ikinci derecedeki oksijen yetmezliğini temsil eder. Hipoksemi durumunun daha ileri taşınması sonucu ortaya çıkar. Kan akışı merkezi organların lehinedir ve aerobik metabolizmanın çalışmasını garanti eder. Buna karşın, anaerobik metabolizma periferik dokularda kullanılır. Hipoksi durumuna karşı ilk tepki stres hormonlarının (adrenalin, noradrenalin vb...) salgılanmasıdır. Hipoksi, fetüse herhangi bir zarar vermeden birkaç saat sürebilir. Eğer hipoksi sadece çevresel dokular üzerinde etkili olursa, fetüs zarar görmeden bu süreci atlatır. Bir başka ifadeyle, merkezi organlar doğru bir şekilde beslendiği sürece fetüs hipoksi ile mücadele edebilir [6].

*Asfeksi* en kritik stres aşamasıdır ve yüksek önceliğe sahip organların oksijensiz kalma durumunu temsil etmektedir. Asfeksi durumunda, kullanılabilir oksijen tükenmiştir ve yüksek önceliğe sahip olan organlar anaerobik metabolizmayı kullanmaktadır. Enerji için karaciğer ve miyokart üzerinde biriktirilen glikozlar kullanılır. Beyin çok düşük glikoz seviyesine sahiptir, bu nedenle glikoz karaciğer tarafından temin edilir. Fetüs, stres hormonlarının salınımını ve sempatik sisteminin aktive edilmesini sağlayarak asfeksi durumuna karşı tepki verir. Amacı, mümkün olduğunca merkezi organların işlevlerini yerine getirmesini sağlamaktır. Asfeksi birkaç dakikadan daha fazla devam ederse, kalıcı yaralanmalar ya da kalp ve beyin sisteminin felci-çökmesi şeklinde sonlanabilir [7].

### 1.1.3. Fetal Kalp Hızı Değişkenliği

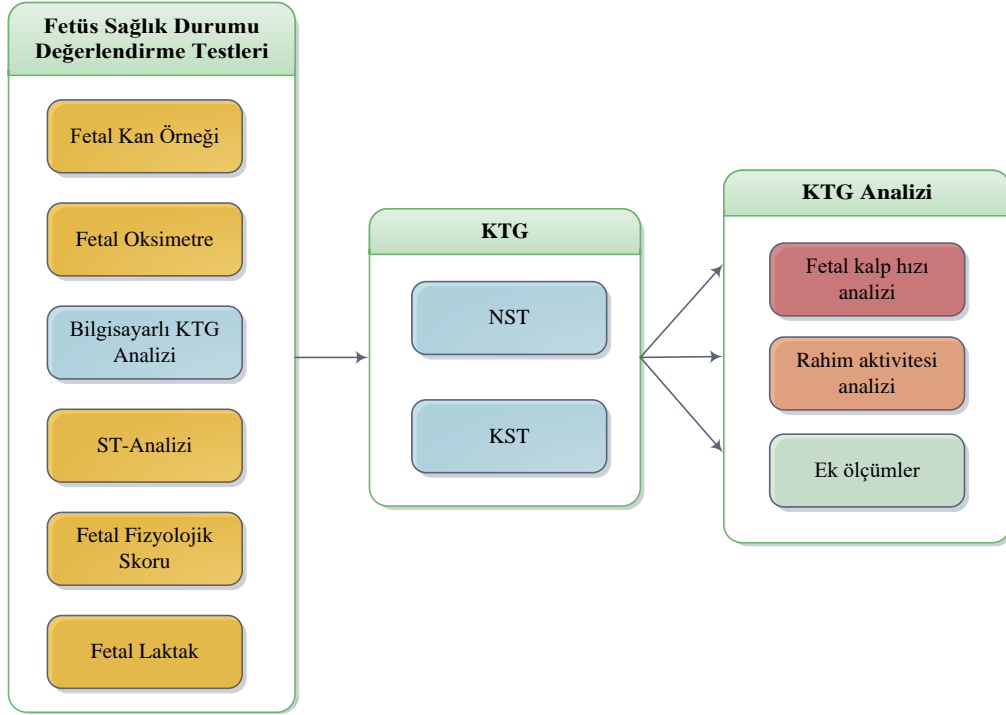
FKH üzerindeki değişikliklere oksijen yetersizliği, anne davranışı ya da harici etkenler sebep olabilir. Başlıca FKH değişim nedenleri aşağıda sıralanmıştır:

- *Normal değişimler:* FKH sessiz ve aktif uyku dönemlerinde farklılık gösterir. Otonom sinir sistemindeki ani değişimler değişkenliğin artmasına ve FKH'nin hızlanmasına neden olur.
- *Plasenta kan akışının değişimi:* Esas nedeni kordon sıkışması ya da baskısı olarak ifade edilir. Kordon sıkıştığında kan fetüs içerisine itilir. Kalp daha fazla kan pompalamak zorundadır ve FKH üzerinde artış görülür. Kan seviyesindeki artış kan basıncını da artırır. Böylelikle, baroreseptörler devreye girerek FKH'nin yavaşlamasına neden olur. Kordonun gevşemesiyle FKH normale döner.
- *Oksijen yetersizliğine karşı uyum:* Oksijen içeriği azaldığında, kemoreseptörler uyarılır, sempatik ve parasempatik sinir sistemi devreye girer. Hipoksi derecesine bağlı olarak FKH değişimi değişkenlik gösterir.
- *Harici uyarıcılar:* Anne rahmindeki kasılmalar nedeniyle fetüs kafa bölgesindeki basınç artar ve bu durum FKH üzerinde düşüşe neden olur. Ayrıca göz üzerindeki basınç bradikardi olayını tetikleyebilir.
- *Anne vücut ısısının yükselmesi:* Annenin vücut ısısı yükseldiğinde, fetüsün oksijen tüketimi artar, buna bağlı olarak fetal metabolizma hızlanır, taşikardi görülebilir.
- *İlaçların etkisi:* Fetüs çeşitli ilaçlardan etkilenebilir. İlaçların etkisine bağlı olarak doğum stresi azalabilir. Örneğin oksitosin ile anne aşırı uyarıldığında rahim aktivitesi artar ve bu yoğun daralmadan fetüs etkilenebilir.
- *Fetal aktivitesi:* Fetüsün uyku durumunda olması FKH spektrumunu etkilemektedir.

### 1.1.4. Fetal Sağlık Durumunun Değerlendirilmesi için Kullanılan İlave Testler

KTG prenatal dönemde, birincil basamak bir kontrol testi olarak kullanılmaktadır. Kullanımının kolay olması, uzmanlık istememesi ve hızlıca yorumlanabilmesi

nedeniyle kliniklerde KTG kullanımı standart bir prosedür haline gelmiştir [8]. Ancak KTG düşük pozitif tahmin değerine (yaklaşık olarak %30); buna karşın yüksek yanlılılık oranına (yaklaşık olarak %60) sahiptir [9].



Şekil 1.3. Fetüs sağlık durumu değerlendirme testleri

KTG üzerinde bir anormalliğin gözlenmesi durumunda ilave testler kullanılmaktadır. Şekil 1.3’de fetüs sağlık durumunu değerlendirmek üzere kullanılan ilave testler gösterilmiştir. Şekilden de anlaşılacağı üzere, fetüs sağlığını değerlendirmek üzere KTG analizi ile birlikte ek testler kullanılabilir. Bu durum KTG testinin özgüllüğünü artırmaktadır. Fetal sağlık durumunun belirlenmesi için kullanılan testler aşağıdaki listede kısaca açıklanmıştır.

- *Fetal Kan Örnekleme:* Fetal kan örnekleme (FKÖ), direk göbek bağı ya da fetüs üzerinden kan alınmasıdır. Anemi belirtilerini ya da diğer kan problemlerini test etmek için kullanılır. Fetal durumunun şüpheli olarak yorumlandığı durumlarda kesin pH değerini elde etmek için kullanılır. Uzmanlık gerektirir, zaman alır ve yan etkilere neden olabilir; ancak genel olarak güvenli olduğu kabul edilir. FKÖ’nün kullanılmasının sezaryen veya enstrümantal doğum oranı üzerinde bir etkisi yoktur ve yenidoğan sonuçlarını etkilememektedir.

- *Pulse Oksimetre*: Kandaki oksijen doymunluğunun ( $SO_2$ ) invaziv olmayan bir yöntemle izlenmesini sağlamaktadır. Fetal sonuçlarının değerlendirilmesinde ve sezaryen doğum oranının düşürülmesinde katkısı yoktur ancak KTG testinin özgüllüğünü arttırmaktadır.
- *ST Analizi*: ST analizi (STAN) bir elektrokardiyografi (EKG) işaretinin karakteristik bölümlerini teşkil eden “ST bölümü”, “T dalgası” ve “T/QRS” oranını analiz eder. Kalp hücrelerdeki hipoksi varlığında kullanılır. STAN’ın, KTG ile birlikte kullanılması tavsiye edilmektedir. Dokudan ziyade, merkezi organlardaki oksijen bilgisini ortaya çıkarabilmesi STAN kullanımının sağladığı en büyük avantajdır.
- *Fetal Fizyolojik Skoru*: Fetal fizyolojik skoru (FFS), 30 dakikanın üzerinde süren patolojik yavaşlamaların varlığında hipoksik strese karşı fetüsün verdiği fizyolojik cevaba dayanmaktadır. Temel kalp hızının (TKH) orijinal taban çizgisine kıyasla yüzdelerlik artışı, fetal kalp hızı değişikliğinin değişimi, kasılmalar-arası aralık ve yavaşlamalar-arası aralık özelliklerini analiz eder. 7’den büyük bir FFS skorunun normal APGAR skoruyla ilişkili olduğu bildirilmiştir.

#### **1.1.5. Doğum Sonrası Geriye Dönük Fetal Değerlendirmesi için Asit-Baz Analizi**

Doğum odasında kordon kanının alınması ve değerlendirilmesi nitelikli yenidoğan bakımı için neredeyse standart olarak yapılmaktadır. Bu analiz sayesinde klinik tedavi planı ortaya çıkartılmaktadır [10]. Göbek kordonundan alınan kanın analiz edilmesi bebeğin doğum sırasında hipoksi durumundan ne ölçüde etkilendiğini göstermektedir. Kandaki gazların hesaplanması biyokimyasal ölçüm desteği (pH, baz fazlalığı, baz açığı) ile gerçekleşmektedir. Bu aynı zamanda geriye dönük bir değerlendirmenin yapılabilmesine de imkan sunmaktadır [11].

pH değeri, solunum ve metabolik asitlerin varlığında belirlenir ve hidrojen iyon aktivitesinin logaritması alınarak hesaplanır. Logaritmik hesaplamadan dolayı, pH değerinin doğrusal olmayan şekilde; buna karşın baz fazlalığı (BE) ve baz açıklığının (BDecf) ise daha doğrusal olarak değiştiği bilinmektedir. pH değerini etkileyen pek çok durum söz konusudur. Bu açıdan en iyi örnek sezaryen doğum seçimidir ve pH değeri neredeyse yetişkinlerinkine eşittir. Biyokimyasal ölçümlerin (pH, BE, BDecf)

hangisinin en iyi olduđu ve eşik değerinin ne olması gerektiğine dair hiçbir genel mutabakat yoktur [12].

## **1.2. Kardiyotokografi Testine Genel Bakış**

Gebelik dönemiyle başlayıp doğum ile sonlanan süreçte, fetüs sağlık durumunun izlenmesi ve değerlendirilmesi sağlamak üzere dünya genelinde yaygın olarak kullanılan en temel test KTG'dir [13]. KTG, fetüs stres seviyesinin belirlenmesi amacıyla hem doğum öncesi, yani gebelik döneminde, hem de doğum sırasında klinik açıdan standart olarak uygulanan bir gözetim tekniğidir. KTG, fetal kalp hızı (FKH) ve rahim kasılmalarının (RK) eşzamanlı olarak kayıt edilmesiyle elektronik fetal monitör (EFM) cihazları ile oluşturulmaktadır [9]. FKH aktivitesinin kayıt edilmesi non-stres test (NST) ve RK aktivitesinin kayıt edilmesi kontraksiyon stres test (KST) olarak ifade edilmektedir. NST, anlık değışen FKH'nin izlenmesini sağlarken; KST ise NST'ye paralel olarak RK aktivitesinin izlenmesini sağlamaktadır [9].

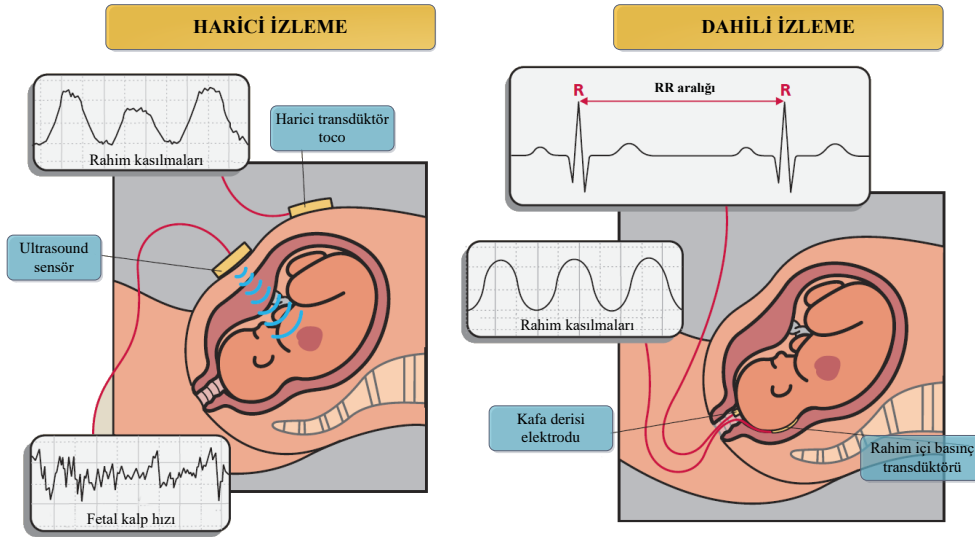
Geçmişte FKH'ı izlemek ve değışimlerini saptamak için stetoskop kullanılmıştır [14]. Ancak stetoskop ile incelik ve uzmanlık gerektiren kalp değışimlerini saptamak olanaksızdır. Ayrıca, stetoskop ile sürekli bir izlemenin yapılması da mümkün değildir [15]. Teknolojik gelişimlere bağılı olarak, EFM cihazları geliştirilmiştir. EFM, fetüs sağlık durumunun izlenmesi için kadın doğum uzmanları tarafından 1960'lı yıllardan beri yaygın olarak kullanılmaktadır [16]. EFM cihazlarının sağladığı en büyük avantaj, fetüs durumunun gebelik döneminde ve daha da önemlisi doğum sürecinde sürekli olarak izleme yapılabilmesine imkân vermesidir. Bunun dışında; kullanımı kolaydır, invaziv olmayan bir yöntemdir, ters-endikasyona sahip değildir, ayakta tedavi ünitelerinde kullanılabilir, tekrar eden bir şekilde uygulanması hususunda herhangi bir engel yoktur ve düşük maliyetli bir izleme tekniğidir [17]. Tüm bu avantajlarına rağmen, KTG hiçbir zaman iyi bir klinik muayenenin yerine geçemez veya doğum sırasında anneyi gözetimsiz bırakmak için hiçbir zaman geçerli bir mazeret olamaz [18].

KTG'nin faydasıyla ilgili somut eksiklere rağmen, bu tanı testi pek çok ülkede bir bakım standardı haline gelmiş durumdadır. KTG testine göre bir fetüsün iyi olduđu ifade ediliyorsa, bu çok yüksek ihtimalle fetüsün gerçekten de iyi bir koşulda olduđu anlamına gelir [19]. Ancak tersi durumda, eğer KTG testine göre bir fetüs anormal

olarak değerlendiriliyor ise bu uyarılardan yarısından fazlasının yanlış alarm olduğu tespit edilmiştir [20].

### 1.2.1. Teknik Açından Kardiyotokografi

FKH işaretleri, anne karın duvarına bağlanan ve ‘Doppler’ prensibi ile çalışan bir dönüştürücü yardımıyla harici olarak ya da fetüs kafa derisine bağlanan bir elektrot ile dahili olarak kayıt edilebilir. Bir başka harici dönüştürücü ‘toko’ olarak ifade edilmektedir ve RK aktivitesini kayıt etmek üzere kullanılmaktadır. Benzer şekilde, RK aktivitesini dahili olarak kayıt etmek üzere rahim içi basınç transdüktörü kullanılmaktadır. Şekil 1.4 FKH ve RK aktivitelerinin dahili ve harici olarak kayıt edilme şeklini göstermektedir. *RK işaretinin, kasılmaların süresi ve frekansı ile ilgili bilgi verdiği; ancak kasılmaların kuvvetiyle alakalı herhangi bir bilgi sağlamadığının farkında olmak gerekir* [9].



Şekil 1.4. Fetal kalp hızı ve rahim aktivitesinin kayıt edilmesi

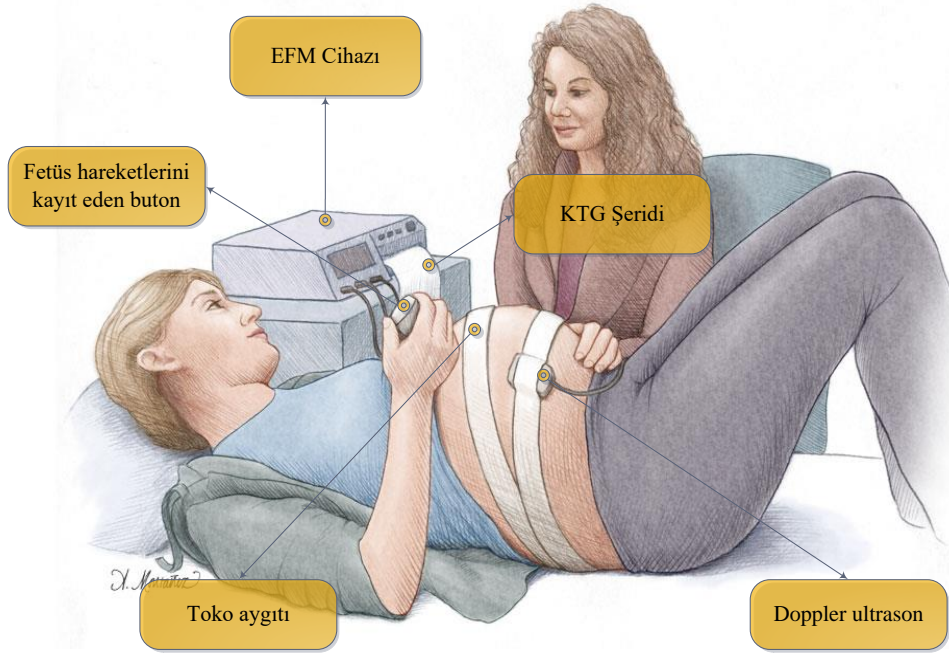
Şekil 1.4’de görüldüğü gibi dahili izleme yöntemi harici izleme yöntemiyle kıyaslandığında daha doğru ve detaylı bir ölçüm sağlamaktadır. Harici izleme yöntemi, anne ve bebek hareketleri, cihazdan kaynaklanan elektronik artefaktler ve daha pek çok istenmeyen girişim içermektedir. Buna karşın, dâhili izleme yönteminin pratikte uygulanmasının zor olması, zaman alması, uzmanlık gerektirmesi ve çeşitli riskler taşıması nedeniyle gereklilik arz etmedikçe kullanılmamaktadır.



### 1.2.2. Kliniksel Açıdan Kardiyotokografi

Kliniklerde KTG testini gerçekleştirmek üzere, genellikle annenin sırtüstü yatar pozisyonda ve sakin bir halde, Şekil 1.5’de gösterildiği gibi yatırılması sağlanır. Yana yatma, yarı oturma ve dik durma pozisyonları da tercih edilebilir alternatiflerdir. Annenin karın duvarına bağlanan ve daha önce ifade edilen bir Doppler ultrason yardımıyla NST ve bir güç dönüştürücü (toko aygıtı) yardımıyla da KST işaretleri kayıt edilir. Ayrıca fetüsün tekme atması durumunda annenin bir butona basması istenir. Test ortalama, 15 ile 30 dakika arasında tamamlanır ve test devam ederken EFM cihazı bir şerit üretir. Testin tamamlanmasının ardından KTG şeridinin gözlemciler (kadın doğum uzmanı, hemşire veya ebe) tarafından yorumlanması beklenir. Gözlemciler KTG test çıktısını, kılavuzlarda ayrıntılı olarak tanımlanan bir takım örüntüleri çıplak gözle ayırt edecek şekilde yorumlamaya çalışır. Şekil 1.6’da EFM cihazının ürettiği bir şerit görüntülenmiştir. Şeridin üst ve alt kısmında yer alan işaretler sırasıyla anlık olarak ölçülen NST ve KST testlerinin değerlerini göstermektedir [21].


KTG testi yapılmadan önce cihazın kalibre edilmesi gerekir. Bir başka ifadeyle, KTG izleme testi başladığında “*kâğıt hızı*” doğru bir şekilde ayarlanmış olmalıdır. Kâğıt hızı yaygın olarak 1 cm/dakika hızında kullanılır, ancak Kuzey Amerika ve Japonya’da 3 cm/dakika ve Avrupa ülkelerinde 2 cm/dakika olarak kullanılmaktadır. 1 cm/dakika kâğıt hızı, uzmanlar tarafından klinik bir yorum yapabilmek için yeterli görülmektedir [18].



Şekil 1.5. KTG'nin kliniksel olarak uygulanması

### 1.2.3. Kardiyotokografi İşaretinin Analizi

Bir KTG işareti değerlendirilirken TKH, hızlanma, değişkenlik ve yavaşlama olmak üzere dört adet özelliğin değerlendirilmesi gerekir. Çoğu zaman bu özellikler “morfolojik özellikler” olarak ifade edilir [22]. Ayrıca, kasılma örüntüleri de analiz sırasında genellikle dikkate alınmaktadır.



Şekil 1.6. Örnek bir KTG şeridi

TKH 5 ya da 10 dakikalık periyotlar dâhilinde hızlanma ve yavaşlama örüntüleri işaretten izole edilerek hesaplanır ve dakikadaki atım sayısını (das) birim olarak kullanır. TKH'nin dakikada 110-160 atım arasında olması normal olarak kabul edilir. TKH'nin dakikada 110 atımın altına düştüğü durumlar *bradikardi*, dakikada 150 atımın üzerine çıktığı durumlar ise *taşikardi* olarak değerlendirilir [18].

Kalp hızının 15 saniyeden daha uzun bir süre, TKH'den dakikada 15 atım daha fazla yükselmesi bir hızlanma örüntüsü olarak kabul edilir. Hızlanma örüntüleri, FKH analizi için geçici bir değişikliği temsil etmektedir. Ortalama 20 dakika içerisinde fetüsün iki ya da daha fazla hızlanma örüntüsüne sahip olması fetüs sağlık durumunun iyi olduğuna işaret etmektedir [21].

Fetal kalp hızı değişkenliği (FKHD), hızlanma ve yavaşlama örüntüleri işaretten çıkartıldıktan sonra TKH seviyesindeki bant genişliği salınımları şeklinde ifade edilir. FKHD sempatik ve parasempatik sistemler arasındaki ilişki tarafından sürdürülür [9]. Dolayısıyla iyi bir FKHD varlığı aynı zamanda sağlıklı bir otonom sinir sistemine işaret eder. Dakikada 25 atımdan daha büyük değişimler ani sıçrama, dakikada 5 - 25 atım arasında değişimler normal ve dakikada 5 atımın altında olan değişkenlik ise patolojik belirti olarak sınıflandırılır.

Yavaşlama örüntüleri, fetüs kalp hızının geçici olarak TKH seviyesinden dakikada 15 atımdan daha fazla alçalma göstermesi ve bu alçalmanın en az 15 saniye sürmesi sonucu ortaya çıkan örüntüler olarak tanılanmaktadır. Yavaşlama örüntüleri, erken, geç ve değişken yavaşlama örüntüleri olarak sınıflandırılmaktadır [23].

#### **1.2.4. Kardiyotokografi İşaretinin Sınıflandırılması**

Çeşitli sağlık kuruluşları tarafından KTG işaretlerinin sınıflandırma sürecinin tanımlanması için farklı kılavuzlar yayımlanmıştır. İngiltere'den Uluslararası Kadın Hastalıkları ve Doğum Federasyonu (FIGO) [18], Ulusal Sağlık ve Bakım Üstünlüğü Enstitüsü (NICE) [23] ve Amerika'dan Amerikan Doğum Uzmanları ve Jinekolog Meclisi (ACOG) [22] bunlardan önde gelen otoritelerdir.

Geliştirilen bu standartlara rağmen hala KTG yorumlanmasının subjektif olarak yapıldığı ve gözlemden gözleme farklılıkların olduğu görülmektedir. Bir başka ifadeyle tüm topluluklar tarafından kabul görmüş tek bir standart kılavuz hala yoktur.

Bu tez çalışması kapsamında FIGO tarafından belirlenen kurallar dikkate alınmıştır ve bu kurallar Çizelge 1.1’de özetlenmiştir.

Çizelge 1.1. FIGO sınıflandırma ölçütleri

Normal Örüntü	Şüpheli Örüntü	Patolojik Örüntü
TKH dakikada 110–150 atım arasındadır. FKHD dakikada 5-25 atım arasındadır. Patolojik bir örüntü yoktur.	TKH dakikada 150-170 atım ya da 100-110 atım arasındadır. FKHD 40 dakikadan uzun bir süre dakikada 5-10 atım arasındadır.	TKH dakikada 100 atımdan aşağı ya da 170 atımdan yukarıdır. Kalıcı FKHD 40 dakikadan fazla bir süre dakikada 5 atımdan azdır. Şiddetli değişken yavaşlamalar Şiddetli ve tekrarlayan erken yavaşlamalar Uzun yavaşlamalar Geç yavaşlamalar Bir sinüzoidal örüntü

### 1.2.5. Bilgisayarlı Kardiyotokografi Analizi

KTG işaretinin yanlılcılık oranı ve KTG yorumunda gözlemciler-içi ve gözlemciler-arası anlaşmazlık seviyesi yüksektir [24]. Bu durum, KTG yorumundaki değişkenliği ortaya koymaktadır ve bu değişkenlik hem gebelik döneminde hem de doğum sürecinde yaşanmaktadır [25]. Ayrıca, yenidoğan sonuçlarının geriye dönük sınıflandırmayı etkilemesi, KTG yorumunun uzmanların bilgi seviyesi, iş yoğunluğu ve duygusal durumlarına göre öznel olarak gerçekleştirilmesi gibi nedenlerden ötürü KTG testine karşı bir güvensizlik söz konusudur [26]. Bu nedenle KTG testi birincil basamak bir test olarak uygulanmaktadır ve bir anormalliğin gözlenmesi durumunda kan örneği alma, pulse oksimetre, elektrokardiyogram, ST-analizör gibi çeşitli ek yöntemlerin kullanıldığı raporlanmıştır [12]. Bilgisayarlı KTG analizinin sağladığı en büyük avantaj, FKHD karakteristiğini temsil eden özelliklerin yeniden üretilebilmesine olanak sağlamasıdır [27].

Otomatik KTG analizi için Ayres-de-Campos ve arkadaşları [28] tarafından SisPorto isimli bir yazılım geliştirilmiştir. Bu yazılım günümüzde ticari olarak yaygın bir şekilde kullanılmaktadır. Strachan ve arkadaşları [29] doğumda, KTG işaretleriyle ilişkili olan arteriyel pH ve BDecf bilgisayarlı analizinin her bir bileşenini tanımlamak üzere bir çalışma yürütmüştür. Pardey ve arkadaşları [30] NST’nin geliştirilmesi, sayısal olarak analiz edilmesi ve kliniksel olarak doğrulanması amacıyla bir bilgisayarlı sistem geliştirmiştir. Magenes ve arkadaşları [31] FKHD’nin geleneksel özelliklerini dikkate alarak yeni bir örnek sistemin kurulması konu edinilmiştir. Al-

yousif ve Mohd Ali [32], KTG şeritlerini analiz eden bir Matlab programı geliştirmiştir. Czabanski ve arkadaşları tarafından [33], FIGO kriterlerine bağlı kalarak bir uzman sistem geliştirilmiş ve yenidoğan asidemi değerini tahmin etmek üzere iki aşamalı bir analiz gerçekleştirilmiştir. Romano ve arkadaşları [34], KTG işaretlerini analiz etmek üzere araştırma amacıyla kullanılacak bir yazılımın karakteristiğini ve potansiyelini ortaya koyan bir çalışma yürütmüştür.

Kısaca ifade edilen çalışmalardan da anlaşılacağı üzere, biyomedikal uygulamaların büyük çoğunluğunda, makine öğrenmesi tekniklerinin rolü ile bir hastalığa tanı koyma süreci pek çok açıdan iç içe geçmiş durumdadır. Bilgisayar destekli otomatik FKH analizi, işareti tanımlamak üzere geleneksel olarak kullanılan parametrelerden çok daha fazlasını sunabilmektedir. Bu kapsamda, işarete erişme, önişleme, özellik çıkarma ve sınıflandırma aşamalarından oluşan bir yaklaşım ile makine öğrenmesi tekniklerine dayanarak KTG işaretlerinin normal ve patolojik olarak sınıflandırılması sağlanmaktadır. Kullanılan makine öğrenmesi tekniklerinin karşılaştırılması eğitim süresi, sınıflandırma başarısı, özgüllük, hassasiyet ve doğruluk gibi ölçütlere bağlı olarak gerçekleştirilmektedir.

### **1.3. Tez Hakkında**

#### **1.3.1. Tezin Hedefleri**

KTG testi kapsamında, RK işaretlerinin FKH işaretleriyle eşzamanlı olarak kayıt edilmesi; fetüs otonom sinir sistemi ile plasentanın solunum fonksiyonu arasındaki ilişkinin gözlenebilmesini sağlamaktadır [15]. Diğer taraftan, kliniksel uygulamalarda KTG yorumu, çeşitli kılavuzlarda belirtilen morfolojik özelliklerin çıplak gözle taranmasına bağlı olarak, öznel bir şekilde gerçekleştirmektedir. Bu durum doğal olarak gözlemciler-arası ve gözlemciler-içi anlaşmazlık seviyesinin tırmanmasına neden olmaktadır. KTG düşük özgüllük değerine sahiptir; bir başka ifadeyle pozitif tahmin değeri yaklaşık olarak %30, buna karşın yanlıcılık oranı ise %60 seviyelerindedir [9]. *Daha nicel ve tutarlı bir KTG yorumunun yapılmasını sağlamak üzere bilgisayar destekli otomatik FKH analizi en umut verici yöntem olarak görülmektedir.* Bu kapsamda, daha iyi bir sınıflandırma sağlamak ve işareti daha iyi temsil edecek güvenilir bir özellik seti oluşturmak üzere motivasyonumuz yükselmiştir. Tez çalışması sınırlarında aşağıda belirtilen hedeflere ulaşılmak istenmiştir:

- 1) **KTG veri tabanlarını incelemek:** KTG 1960'lı yıllardan beri hemen hemen dünya genelinde standart bir prosedür olarak uygulanmasına karşın, açık-erişimli ve geniş ölçekli veri tabanlarının dağıtımı pek yaygın değildir. Bu kapsamda literatürde genellikle küçük ölçekli ve amaca yönelik veri setlerinin kullanıldığı görülmüştür. Tez çalışması kapsamında hali hazırda var olan ve erişilebilir veri tabanlarının detaylı olarak incelenmesi hedeflenmiştir.
- 2) **Kaliteli bir önışleme süreci tanımlamak:** KTG işaretleri genellikle 4 Hz'lik bir örnekleme frekansı kullanmaktadır. Pek çok biyomedikal işarete olduğu gibi KTG işaretleri de istenmeyen girişimler içermektedir ve bu girişimler işaret analiz edilirken sistemin güvenilirliğini düşürmektedir. Bu nedenle, işareti istenmeyen girişimlerden arındırmak ve daha güvenilir bir sistem sağlamak üzere kaliteli bir önışleme sürecinin tanımlanması hedeflenmektedir.
- 3) **Yeni bir özellik seti oluşturmak:** Bilgisayar destekli otomatik KTG analizi, ilk olarak kılavuzlarda belirtilen morfolojik özelliklerin zaman alanında tespit edilmesine odaklanmıştır. Kalp hızı değişkenliği üzerinde yapılan spektral analizin kardiyovasküler fizyolojinin anlaşılmasında ve hastalıkların sınıflandırılması üzerinde iyi sonuçlar verdiği görülmüştür. Güç spektrumunun yoğunluğu ve buna bağlı olarak türetilen parametreler FKH işareti için uygulanmıştır. Daha sonra doğrusal olmayan özelliklerin kullanımının kalp hızı değişkenliğine tanı koyulması sürecinde bazı yenilikleri ortaya koyduğu görülmüştür. Bu kapsamda Entropi tahmin edicileri ve çeşitli karmaşıklık endeksleri FKH analizi için tanımlanmıştır. Bu doktora tezi kapsamında, *FKH işaretlerinin zaman-frekans alanında daha iyi tanımlayacak imge tabanlı bir özellik çıkarma yönteminin kullanılması hedeflenmiştir.*
- 4) **Makine öğrenmesi tekniklerini karşılaştırmak ve en verimli makine öğrenmesi tekniğini saptamak:** Bu doktora tezinin öncelikli hedefi, FKH örüntülerini sınıflandırmak üzere pek çok farklı makine öğrenmesi tekniğinin kullanılmasına ilaveten doğruluk, özgüllük, hassasiyet, F-ölçütü ve kalite endeksi gibi başarı ölçütlerine göre en verimli makine öğrenmesi tekniğinin saptanmasıdır. Bu amaç için, hali hazırda var olan makine öğrenmesi algoritmaları detaylı bir şekilde incelenmesi ve kullanılması hedeflenmiştir.

5) **KTG analizi için gelişmiş bir yazılım geliştirmek:** KTG işaretinin doğrusal, doğrusal olmayan, zaman-frekans ve imge tabanlı zaman-frekans analizi için analizin her aşamasının görsel bir incelemeyle doğrulanmasını sağlayacak kullanıcı dostu grafiksel kullanıcı arayüzlerinin oluşturulması hedeflenmiştir.

### 1.3.2. Tezin Organizasyonu

Bu tezin birinci bölümünde, konuya ait genel çerçeve çizilerek analizi yapılan KTG işareti tanımlanmış, işaretin pratikteki kullanımı ve etki alanı hakkında genel bilgiler verilmiş, işaretin sahip olduğu sorunlar ortaya konmuş ve tezin hedefleri açıklanmıştır.

İkinci bölümde, kaynak özetleri ve alanda yapılan başlıca çalışmalar tarihsel bir sıra içerisinde ve sistematik bir şekilde özetlenerek sunulmuştur. Kaynaklar kendi içinde kronolojik bir sırasıyla verilirken makine öğrenmesi açısından önem arz eden önişleme, özellik çıkarma ve sınıflandırma aşamaları dikkatli bir şekilde incelenmiştir.

Üçüncü bölümde, kullanılan metotlar ve yöntemler, veri koleksiyonları, çeşitli gelişmiş işaret işleme ve makine öğrenmesi teknikleri ve özel eğitim algoritmaları özlü bir şekilde açıklanmıştır.

Dördüncü bölümde, araştırma bulguları ortaya konmuştur. Bulgular tablo, şekil ve grafiklerle desteklenmiştir. Bu bölümde, tez kapsamında yapılan işler yorumlanmış ve literatürdeki çalışmalar ile karşılaştırılmıştır.

Beşinci bölümde yürütülen deneysel çalışmalar neticesinde elde edilen sonuçlar özlü bir şekilde sunulmuş ve gelecekte yapılması öngörülen çalışmalar ifade edilmiştir.

Altıncı bölümde, doktora tez çalışması kapsamında istifade edilen çeşitli kaynakların listesi yer almaktadır.

### 1.3.3. Tezin Çıktıları

Bu doktora tezi kapsamında gerçekleştirilen yayın ve bildirimlerin listesi aşağıda verilmiştir.

- 1) Cömert, Z. and Kocamaz, A. F. (2016), “*Evaluation of Fetal Distress Diagnosis during Delivery Stages based on Linear and Nonlinear Features of*

*Fetal Heart Rate for Neural Network Community,*” International Journal of Computer Applications, 156 (4)

- 2) Cömert, Z. and Kocamaz, A. F. (2017), “*Prognostic Model for Predicting of Hypoxic Fetuses from CTG Signals using Discrete Wavelet Transform and Image-based Time-Frequency Analysis,*” Biomedical Signal Processing and Control
- 3) Cömert, Z. and Kocamaz, A. F. (2015). “*Determination of QT interval on synthetic electrocardiogram,*” 23rd Signal Processing and Communications Applications Conference (SIU).
- 4) Cömert, Z., et al. (2016). “*Cardiotocography signals with artificial neural network and extreme learning machine,*” 24th Signal Processing and Communication Application Conference (SIU), IEEE.
- 5) Cömert, Z. and Kocamaz, A. F. (2016). “*A Study Based on Gray Level Co-Occurrence Matrix and Neural Network Community for Determination of Hypoxic Fetuses,*” International Artificial Intelligence and Data Processing Symposium (IDAP'16)
- 6) Cömert, Z. and Kocamaz, A. F. (2016). “*Comparison of Machine Learning Techniques for Fetal Heart Rate Classification,*” 3rd International Conference on Computational Experimental Science and Engineering. Antalya, Turkey: 601.
- 7) Cömert, Z. and Kocamaz, A. F. (2016). “*Performance Comparison of Neural Network Training Algorithms for Fetal Heart Rate Patterns,*” 3rd International Conference Computational and Experimental Science and Engineering, Antalya, Turkey.

Bu doktora tez çalışması kapsamında yukarıda ifade edilen akademik çalışmalara ilaveten, akademik amaçlarla kullanılmak üzere KTG işaretlerinin morfolojik, doğrusal, doğrusal olmayan, frekans ve imge tabanlı zaman frekans alanlarında analizini gerçekleştirecek bir yazılım geliştirilmiştir. Yazılım Matlab®’da kodlanmıştır.



## 2. KAYNAK ÖZETLERİ

Literatürdeki çalışmalarda, KTG işaretleri analiz edilirken FKH ve RK işaretlerinin hem ayrı ayrı hem de birlikte dikkate alındığı görülmüştür. Ayrıca, araştırmalar bazen sadece yeni bir göstergenin tanımlanması veya hali hazırda var olan bir göstergenin farklı yaklaşımlarla tespit edilmesi, bir başka ifadeyle örüntü tanıma veya örüntülerin karakteristiklerini ortaya koyma amacıyla yapılmıştır. Ayrıca, farklı sınıflandırıcıların performanslarının karşılaştırılması, boyut indirgeme, veri sıkıştırma ve veri depolama gibi pek çok farklı amaç için yine çok sayıda çalışmanın yapıldığı açıktır. Bu bölümde, bilgisayarlı KTG analizi üzerine yapılan çeşitli çalışmalar kronolojik bir sırayla özetlenmiştir.

Dawes ve arkadaşları [35], normal FKH kayıtlarında geniş varyasyonların olduğunu belirterek, bu kayıtlarda darbe aralıklarının düz veya bimodal frekans dağılımlarının varlığının istatistiksel yöntemlerle bir taban çizgisinin türetilmesini zorlaştırdığını ifade etmişlerdir. Çalışmada, hızlanma veya yavaşlamaların ölçülebileceği uygun bir taban çizgisi elde etmek için bir sistem önerilmiştir.

Mantel ve arkadaşları [36] tarafından, taban çizgisi tahmini yapmak üzere bir algoritma geliştirilmiştir. Geliştirilen algoritma bu amaç için daha önce önerilen algoritmalarla karşılaştırılmış ve gebelik dönemindeki 50 kayıt üzerinde test edilmiştir. Algoritma iki fonksiyonel birim olarak; bir dijital filtre ve bir kesim fonksiyonuna bağlı olarak geliştirilmiştir. Sonuç olarak, bu algoritmanın fetal sonuçlarına göre en yüksek tahmin değerine eriştiği ifade edilmiştir.

Mantel ve arkadaşları [37], daha önce temel kalp hızı tahmini üzerine geliştirdikleri algoritmayı bir adım öteye taşıyarak FKH işareti üzerindeki hızlanma ve yavaşlama örüntülerini tespit etmek amacıyla bilgisayarlı bir analiz önerisinde bulunmuşlardır. İşaretin genlik ve süresine bağlı olarak gerçekleştirilen analiz umut verici bir yaklaşım olarak değerlendirilmiştir.

Bernardes ve arkadaşları [38] tarafından, rutin kliniksel KTG analizi gerçekleştirmek üzere bir sistem geliştirilmiştir. 70 dakikalık FKH işaretleri üzerinde sistem çalıştırılmıştır. TKH, hızlanma ve yavaşlama örüntülerinin tespiti ve uzun dönemli değişkenlik parametrelerine bağlı olarak analiz gerçekleştirilmiş ve tatmin edici sonuçlar elde edilmiştir.

Karin ve arkadaşları [39], FKH'nin fetüs canlılığının ana göstergesi olarak ifade edip, anne karnından elde edilen EKG işaretleri üzerinden R-R atımlarının kolayca elde edilebileceğini ve invaziv olmayan, basit bir yöntemle otonom sinir sistemi aktivitesinin gözlemlenebileceğini ifade etmişlerdir. Araştırma sonucunda, 1-2 dakikalık periyotlarla yüksek frekans fetal otonom sinir sistemi aktivitesinin 0,4 Hz'den büyük olduğu bulunmuştur. Nefes alma frekans aralığı 0,7 - 1,3 Hz arasında rapor edilmiştir. 0,6 - 0,8 Hz bandının solunum hareketinin başlaması ile ilişkili olduğu bulunmuştur. Solunum hareketi, bu frekans bandında otonom sinir sistemi aktivitesindeki bir yükselmeden sonra ortaya çıkmıştır. Yazarlar otonom sinir sistemi aktivitesinin fetal aktivitesini değerlendirmek için etkili bir yöntem olduğuna ve günümüzde henüz erişilememiş bilgiler sağladığına inandıklarını belirtmişlerdir.

Groome ve arkadaşları [40], sessiz uykudaki insan fetüsleri için solunum sinüs aritminin kalp hızı değişkenliğine göreceli katkısını saptamak istemiştir. Solunum sinüs aritmi yüksek frekansta kalp hızı değişkenliğinin güç yoğunluğu olarak tanımlanan parasempatik sinir sisteminin klinik bir bulgusudur. Çalışma popülasyonu doğal solunum sırasında ve normalde apneik periyotlarla ortaya çıkan, gebeliğin 36 ve 40. haftaları arasındaki 13 normal insan fetüsünden oluşmaktadır. Fetal solunum, gerçek zamanlı sonografi kullanılarak sürekli olarak izlenmiştir. Fetal elektrokardiyogram (FEKG), anne karnından 833 Hz hızında 3 dakikalık bloklar halinde yakalanmış ve uyarlamalı sinyal işleme teknikleri kullanılarak ham sinyalden fetal R dalgaları çıkarılmıştır. Fetal davranış durumu, her 3 dakikalık veri toplama periyodunun başında ve sonunda saptanmıştır. Araştırma sonucunda 13 fetüsten 11'inde (%85) fetüs solunumu sırasında yüksek frekans zirvesi görülürken, solunum sinüs aritmi toplam gücün yaklaşık %20'sinden sorumlu olarak rapor edilmiştir.

Alonso-Betanzos ve arkadaşları [41], NST-EXPERT olarak adlandırdıkları bir uzman sistemi fetal durumunu, özellikle yüksek riskli gebelikleri değerlendirmek üzere tasarlanmışlardır. Sistem her bir durum için bir tanı koyup, tedaviye yönelik bir plan hazırlayıp ve bir erken yenidoğan sonuç tahmini önermektedir.

Alonso-Betanzos ve arkadaşları [42], doğum öncesi dönemde, fetüsleri izlemek üzere geliştirdikleri ve NST-EXPERT olarak adlandırdıkları uzman sistemin prototipini tanımlamayı bu çalışmada konu edinmişlerdir. Prototip, başlıca tanı ve

terapötik amaçlı kullanılan iki adet modülden oluşmaktadır. Kayıtların değerlendirilmesi için yapay sinir ağı (YSA) istihdam edilmiştir.

Todros ve arkadaşları [43], KTG'nin yaygın kullanılmasına rağmen tanı gücünün memnun edici olmadan çok uzak olduğunu belirterek, uzmanlar ve bilgisayarlı bir sistem arasında karşılaştırmalı bir çalışma yapmışlardır. Araştırmanın amacı, KTG işaretlerinin yeniden üretilebilirliğini gözlemciler-içi, gözlemciler-arası ve bir bilgisayarlı sistem arasında değerlendirmektir. Araştırmada 2 deneyimli, 2 deneyimsiz uzman, 2CTG adı verilen bir bilgisayarlı sistem ve 63 FKH işareti kullanılmıştır. Araştırma sonunda, deneyimli gözlemciler, deneyimsiz gözlemciler ve 2CTG bilgisayarlı sistem arasındaki değişkenlik anlamlı olarak bulunmuştur ve bir bilgisayarlı sistemin bu sorunu aşabileceği vurgulanmıştır.

Mongelli ve arkadaşları [44], doğum sırasında TKH tahmini yapmak ve değerlendirmek üzere bilgisayarlı bir TKH tahmin algoritması önermişlerdir. Çalışmada, geriye dönük bir değerlendirme yapılmıştır. Bir EKG cihazıyla doğum sırasında hastalardan kayıtlar toplanmıştır. 60 kayıt, 12 uzman ve önerilen algoritma tarafından değerlendirilmiştir. Sonuçlar, sınıf-içi korelasyon ve farklılıklar yöntemiyle değerlendirilmiştir. %95 güven aralığı dikkate alınarak, bilgisayarlı sistem ve uzmanlar arasındaki fark, dakikadaki kalp atım sayısına bağlı olarak -12 / 15 arasında; uzmanlar arasındaki fark -10 / 10 aralığında elde edilmiştir. Korelasyon değeri 0,9'dan büyük bulunmuştur. Dolayısıyla uzmanlar ve bilgisayarlı sistem arasında önemli bir farklılığın olmadığı rapor edilmiştir.

Mante ve arkadaşları [45], gebelik yaşına bağlı olarak hangi FKH örüntülerinin değiştiğini öğrenmek ve fetal dinlenme-aktivite durumlarıyla ilişkisini göstermek üzere bir araştırma yürütmüşlerdir. Çalışma için gerekli veriler, gebelik döneminin 26. haftasında bulunan, 12 normal gebeden elde edilmiştir. 60 dakika uzunluğuna sahip olan 72 kayıt Sonicaid Sistem 8000 ile değerlendirilmiştir. Dinlenme ve aktivite durumlarının karşılaştırılması için Spearman'ın sıralama korelasyon testi, regresyon analizi ve Wilcoxon'un imzalı-sıralama testi kullanılmıştır. Araştırma sonuçlarına göre yükselme örüntülerinin etkisi, FKHD ve yüksek çeşitlilik atakları gebelik yaşıyla orantılı olarak artmaktadır, ancak bu parametreler arasında istatistiksel olarak ciddi bir farklılık yoktur. Sonuç olarak, ilgili parametrelerdeki artışın gebelik yaşının ilerleyişine bağlı olarak gelişen fetal aktiviteden kaynakladığı rapor edilmiştir.

Ulbricht ve arkadaşları [46], fetüs için şüpheli bir durumun tespit edilmesiyle, bu duruma müdahale edilmesi arasındaki geçen süreyi kısa tutmak üzere otomatik bir KTG izleme sistemi önerisinde bulunmuşlardır. Otomatik bir alarm sistemi şüpheli bir örüntünün tespit edilmesi durumunda devreye girmektedir. Karşılaştırmalı bir yaklaşım ile yapay zekâ teknikleri ve geleneksel olarak kullanılan yöntemler çalışma kapsamında değerlendirilmiştir. Yapay zekâ tabanlı tekniklerin geleneksel yöntemlere göre çok daha üstün olduğu ortaya çıkarılmıştır.

Bernardes ve arkadaşları çalışmalarında [47], KTG analizi için bilgisayarlı bir metodolojinin geçerliliğini, TKH için tanımlanmış tekrarlanabilir görsel kestirimine dayanarak değerlendirmeyi amaçlamışlardır. 42 doğum öncesi döneme, 43 doğum dönemine ait KTG kaydı çalışmada kullanılmıştır. Hesaplamalar için FIGO kriterleri dikkate alınmıştır. Değerlendirme için anlaşma oranları, kapa istatistiği, duyarlılık, özgülük ve %95 güven aralığı kullanılmıştır. Genel anlaşma oranı ve kapa istatistiği ve KTG kayıtları ve sınıflandırma arasında sırasıyla 0,79 (%95 güven aralığı: 0,69 - 0,87) ve 0,78 (%95 güven aralığı: 0,41-0,83) olarak rapor edilmiştir. Sonuç olarak, daha önce tarif edilen ve tekrarlanabilir TKH tahminlerine dayalı KTG analizi için objektif bir metodoloji ile iyi klinik öngörünün mümkün olduğu ifade edilmiştir.

Taylor ve arkadaşları [48], doğumda FKH'nın izlenmesi ve karakteristiğinin yorumlanması için bilgisayarlı bir algoritmanın geliştirilmesi ve doğrulanmasını kapsayan bir araştırma sunmuşlardır. Araştırma kapsamında geriye dönük bir gözlemsel çalışma yürütülmüştür. Araştırmaya 24 hastadan gelen ve 25 dakikadan oluşan kayıtlar kaynaklık etmiştir. Kayıtlar hem uzmanlar hem de bilgisayarlı bir algoritma yardımıyla TKH, yükselme ve alçalma örüntülerinin sayısının tespit edilmesi amacıyla değerlendirilmiştir. Araştırma sonuçlarına göre, bilgisayarlı algoritmanın yüksek bir geçerlilik değerine eriştiği raporlanmıştır.

Ayres-de-Campos [28] ve arkadaşları, bilgisayarlı KTG analizi için geliştirdikleri SisPorto isimli programın operasyonel süreçlerini detaylı olarak tanımlamak ve elde edilen sonuçları duyurmak üzere bir araştırma yürütmüşlerdir. Geliştirilen yazılım, 10 dakikalık KTG işaretini topladıktan sonra analize başlamakta ve devamında her 5 dakikada bir güncelleme yapmaktadır. Program, analizi FIGO kriterlerini [18] dikkate alarak yürütmüştür. Araştırma sonucunda %100 duyarlılık, %99 özgülük değeri elde edilmiştir.

Magenes ve arkadaşları çalışmalarında [49], normal KTG işaretleri ile patolojik bir duruma bağlı anomalileri ortaya koyan işareteler arasındaki farklılıkları artıracak yeni algoritmalar bulmayı amaçlamışlardır. 500'den fazla kayıttan oluşan bir veri tabanında, potansiyel patolojik fetüsleri normallerden ayırt etmek için farklı sınıflandırma yöntemlerini test etmişlerdir. Çok Katmanlı Bir Algılayıcı Sinir Ağı (ÇKAM-SA) ve Uyarlanabilir Bulanık-Sinir Çıkarım Sistemi (UBSÇS) klasik istatistiksel yöntemlerle karşılaştırılmıştır. ÇKAM-SA ve UBSÇS istatistiksel yöntemlere göre daha iyi sonuçlar üretmiştir.

Strachan ve arkadaşları [29], doğumda KTG işaretleriyle ilişkili olan arteriyel pH ve baz açıklığının bilgisayarlı analizinin her bir bileşenini tanımlamak üzere bir çalışma yürütmüştür. İşaretler geriye dönük bir gözlem ile analiz edilmiştir ve bir EFM cihazı ile kayıt edilen kayıtların, sadece doğumdan önceki 30 dakikalık bölümleri dikkate alınmıştır. Araştırma sonucunda, doğumda asidemi tahmini yapmak üzere FKH'nin bilgisayarlı analizinin her bir bileşenin değeri tespit edilmiştir.

Fontenla-Romero ve arkadaşları [50] tarafından, anormal bir durumun tespiti ve tıbbi müdahalenin yapılması arasındaki geçen süreyi kısa tutmak üzere ÇKAM-SA ve temel bileşenler analizi (TBA) yöntemlerinden faydalanan bir bilgisayarlı bir yaklaşım önerilmiştir. FKH işareti direkt bir giriş olarak uygulandığı için işaretin TKH seviyesinden bağımsız hale getirilmesi sağlamak üzere TBA'dan faydalanılmıştır. Önerilen yaklaşımın performansı üç uzmana karşı sınanmıştır.

Jimenez ve arkadaşları çalışmalarında [51], FKH işaretleri için TKH tahmini yapmak üzere bir algoritma önermişlerdir. Bu algoritma, birinci türev ile işarete stabil olmayan bölümleri tanımladıktan sonra, doğum öncesi döneme ait KTG işaretleri için TKH tahmini yapmaktadır. Araştırmada, 5 dakika uzunluğuna sahip olan 50 KTG işareti kullanılmıştır. Önerilen algoritma, Dawes ve Mantel'in önerdiği algoritmalarla karşılaştırılmıştır. Algoritmalar arasındaki istatistiksel farklılık ortaya çıkarıldıktan sonra önerilen yöntemin, karşılaştırılan diğer iki yönteme göre %76 oranında daha uygun olduğu rapor edilmiştir.

Salamalekis ve arkadaşları [52] tarafından, doğum aşamasında fetal hipoksinin erken teşhisine yardım edecek, normal ve asfeksi fetüsleri ayıracak, FKH ve fetal nabız oksimetre işaretlerine dayalı bir bilgisayarlı sistem önerilmiştir. Araştırmada 61

hastadan veri toplanmıştır. Doğumun ikinci aşamasında, 10 dakikalık periyotlara çok çözünürlüklü dalgacık analizi farklı frekans aralıklarında uygulanmıştır. 10 dakikalık işaretleri sınıflandırmak için öz-organizasyon haritası sinir ağı kullanılmıştır. Araştırma sonucunda %83,3 duyarlılık ve %97,9 özgüllük değeri elde edilmiştir.

Berdinas ve arkadaşları [53], bilgisayar destekli fetal değerlendirici (BDFD) olarak ifade ettikleri doğum öncesi dönemde fetal gözetimini sağlamak amacıyla kullanılan bir hibrit model önerisinde bulunmuşlardır. Model, kural tabanlı bir sistem ve YSA ekseninde modellenmiştir. BDFD'nin mimarisi, bileşenleri ve fonksiyonel karakteristiği detaylı olarak çalışmada tanımlanmıştır. 53 farklı hastadan gelen 3450 dakikalık işaret üzerinde modelin geçerliliği sınanmıştır. Çalışma sonucunda yapay zeka uygulamalarının doğum öncesi dönemde fetal izleme için uygun olduğu sonucuna varılmıştır.

Pardey ve arkadaşları [30], NST'nin numerik analizi için bilgisayarlı bir sistemin geliştirilmesi ve doğrulanması üzerine gebelik dönemi için bir incelemede bulunmuşlardır. Araştırmada re-aktiviteyi tanımlamak üzere 73,802 NST kaydı okunmuştur. KTG işaretlerinin normal olduğu durumlarda, analiz izleme süresini asgariye indirmiştir. Yazılım potansiyel olarak sinüs örüntülerinin taramakta ve işaretin kaybedilmesi durumunda, eğer önemlisiyle, operatörü uyurabilmektedir.

Kazandı ve arkadaşları tarafından [54], doğum döneminde farklı yavaşlama örüntülerinin prognostik öneminin saptanması amacıyla bir araştırma gerçekleştirilmiştir. 96 FKH işareti, analiz kapsamında değerlendirilmiştir. Çalışmadaki verilerin %66'sı (64 adet veri) altı farklı türde yavaşlama örüntüsü örneği olarak değerlendirilmiştir. Nihai değerlendirmeyi sağlamak üzere 1. ve 5. dakikadaki Apgar skoru ile pH değeri kullanılmıştır. Araştırma sonucunda, tipik olmayan yavaşlama örüntüleri, düşük Apgar skoruyla ilişkilendirilmiştir.

Signorini ve arkadaşları çalışmalarında [55], FKH ve RK işaretlerinin geleneksel olarak kullanılan özelliklerinden çok daha fazla bilgi taşıdığını vurgulayarak, çalışmalarında otoregresif modeller ve doğrusal olmayan niteliklere dayalı çok parametrelili bir FKH analizi önermişlerdir. Çalışmada, geleneksel olarak değerlendirilen TKH, yükselme örüntülerinin sayısı, kısa zamanlı değişkenlik (KZD), uzun dönemli değişkenlik (UDD) ve aralık endeksi (AE) nitelikleri kullanılmıştır.

Yavaşlama örüntüleri iki nedenle ihmal edilmiştir. Birincisi, yavaşlama örüntülerinin sayısı özellikle rahim kasılmalarına bağlıdır ve araştırmada kullanılan kayıtlar doğum öncesi dönemi içerdiği için ciddi bir rahim aktivitesi yoktur. İkincisi, KST işaretleri daha çok doğum sürecinde önem arz etmektedir ve araştırmanın amacı stresli koşullarda FKHD değerini belirlemektir. Spektral alanda analizi gerçekleştirmek üzere güç spektrum yoğunluğu (GSY) kullanılmıştır. Spektral alan, çok düşük frekans (ÇDF, 0 - 0.03 Hz), düşük frekans (DF, 0.03-0.15 Hz), orta frekans (OF, 0.15 – 0.5 Hz) ve yüksek frekans (YF, 0.5 – 1 Hz) arasında incelenmiştir. ÇDF'nin uzun dönemle ve doğrusal olmayan niteliklerle ilişkili olduğu vurgulanmıştır. DF'nin genel olarak sinirsel sempatik aktivite ile ilişkili olduğu vurgulanmıştır. OF fetal hareketlerine ve annenin solunum aktivitesine bağlıdır. YF ise fetüs solunumunu ifade etmektedir. Bu niteliklere bağlı olarak spektral alanda “ÇDF, DF, OF, YF ve  $DF / (OF+YF)$ ” nitelikleri kullanılmıştır. Ayrıca, doğrusal olmayan özellik kapsamında *yaklaşım entropisi* dikkate alınmıştır. Araştırma sonucunda, yalnızca geleneksel özelliklerin kullanılmasıyla yapılan analizlerin düşük bir güvenilirlik ve tahmin değerine sahip olduğunu vurgulayan araştırmacılar, bu değerlerin yeni gösterge indeksleri kullanılarak arttırılabileceği sonucuna varmıştır ve spektral alandaki güç dağılımları frekans bantlarına bağlı olarak pasif ve aktif dönemdeki fetüsler için rapor edilmiştir.

Chuang ve arkadaşları [56], fetal stresin bir işareti olan, FKH yavaşlamasının prognostik önemini ortaya koymayı amaçlamışlardır. Araştırma 169 hasta üzerine yürütülmüştür. Araştırma sonucunda 169 hastadan 11'inde doğal FKH yavaşlama formu gözlemlenmiştir. Bu kayıtlardan %45,5'inin 5. dakikadaki Apgar skor değeri <7 olarak raporlanmıştır.

Magenes ve arkadaşları [57], rahim içi gelişme sınırlılığı yaşayan fetüsleri ve normal fetüsleri ayırt etmek üzere çok parametrelili bir analiz gerçekleştirmişlerdir. Çalışmada morfolojik, zaman, frekans ve karmaşıklık alanlarından çeşitli endekslerin sınıflandırıcıları besleyen özellikler olarak kullanılması sağlanmıştır. Morfolojik özelliklerden hızlanma ve yavaşlama örüntülerinin sayısı tüm işaret için hesaplanmıştır. Ortalama kalp hızı, UDD, YF, OF, DF,  $DF/(OF+YF)$ , *YaEn*, Delta, KZD ve AE özellikleri işaretin her üç dakikasında bir hesaplanıp daha sonra ortalaması alınmıştır. Çalışmada 35 adet normal ve 35 adet RİGS yaşayan fetüs değerlendirilmiştir. Sınıflandırma aşamasında destek vektör makinesi (DVM) için üç

farklı çekirdek kullanılmıştır. Bunlar; birinci ve ikinci dereceden polinom çekirdekler ve Radyal tabanlı çekirdeklerdir. Araştırma sonucuna göre, en iyi özgüllük değeri ikinci dereceden polinom çekirdek kullanan DVM ile %78 olarak elde edilmiştir.

Georgoulas ve arkadaşları çalışmalarında [58], hipoksik ve normal yeni doğanlara ait FKH izlerinin otomatik sınıflandırılmasına yönelik bir yaklaşım sunmuşlardır. Sınıflandırma, FKH işaretinden ve iki Gizli Markov Modeli'nden çıkarılan parametre setleri kullanılarak gerçekleştirilmiştir. Sonuçlar, FKH'nin geleneksel olarak kullanılan çok daha fazla bilgiyi taşıdığını gösterdiğinden tahmin edici olarak yorumlanmıştır.

Ayres-de-Campos ve Bernardes [59], bazal kalp hızı tahmininin bilgisayarlı KTG analizinde en zorlu yönlerden biri olduğunu belirterek, SisPorto 2.01 tarafından yapılan TKH tahminlerini üç uzmandan oluşan bir grubun tahminleri ile karşılaştırmıştır. 150 yüksek-riskli gebelik ve 150 doğum dönemine ait olmak üzere 300 FKH işareti üzerinde çalışma yürütülmüştür. Yazılım ve gözlemciler arasındaki fikir birliği kapa istatistik değeri kullanılarak ölçülmüştür. Gebelik döneminde üç uzman ve SisPorto 2.01 yazılımına ait kapa istatistik değerleri 0,97, 0,97 ve 0,98 olarak elde edilirken; doğum dönemine ait kayıtlar için bu değerler sırasıyla 0,87, 0,89 ve 0,95 olarak elde edilmiştir. Sonuç olarak, hem gebelik hem de doğum döneminde SisPorto 2.01 yazılımı ile üç uzmandan oluşan grup arasında mükemmel bir uyumun olduğu gözlemlenmiştir.

Ayres-de-Campos ve arkadaşları [60], çeşitli yenidoğan sonuç göstergelerini tahmin etmek üzere SisPorto® 2.0 programının kapasitesini değerlendirmeyi amaçlamıştır. Sakatlıkla sonlanan doğumlar, çoklu gebelikler, 30 dakikadan az olan kayıtlar ve kayıp veri oranı %15'i aşan kayıtlar elimine edildikten sonra araştırma toplam 345 vaka üzerinde yürütülmüştür. Çalışmada, erişilebilir durumda olan kayıtların 30 dakikalık bölümleri üzerinde durulmuştur. SisPorto® 2.0 programının ürettiği: TKH, hızlanma örüntülerinin sayısı, anormal KZD oranı, ortalama KZD oranı, anormal UDD oranı ve hafif, uzun ve şiddetli yavaşlama örüntülerinin sayısı analiz kapsamında kullanılmıştır. Her bir FKH parametresinin kapasitesi yenidoğan sonuç göstergelerini tahmin etmek üzere %95 güven aralığı ile alıcı işletim karakteristiği (AİK) eğrileri kullanılarak değerlendirilmiştir ve istatistiksel analiz için SPSS programı kullanılmıştır. Çalışma sonucu, SisPorto® 2.0 FKH parametrelerinin



Apgar 1 ve Apgar 5 skorlarının tahmini için mükemmel bir ayırım kapasitesine sahip olduğunu göstermiştir.

Georgoulas ve Glavas [61], FKH işaretinden çıkarılan bilgilere dayanılarak KTG'nin etkin sınıflandırılması sağlamak üzere özellik konstrüksiyonu için yeni bir yöntem sunmuşlardır. Önerilen yöntem, doğrusal olmayan dönüşümler kullanarak var olanlardan yeni özellikler oluşturmak için gramatik gelişim üzerinde kurgulanmıştır. Bu yöntem, doğum dönemi verilerine ait olan bir veri seti üzerinde test edilmiş ve %92,5'lik doğruluk başarımına erişilmiştir.

Warrick ve arkadaşları [62], doğum sırasında fetüs durumunun değerlendirilmesi için uzmanların değerlendirme sürecini destekleyecek tutarlı ve güvenilir ölçümler sağlayarak FKH örüntülerinin otomatik olarak belirlenmesinin potansiyel olarak doğum bakım sürecini geliştirebileceğini belirtmişlerdir. Araştırmada, FKH işaretlerinin TKH, hızlanma ve yavaşlama örüntülerini tanımak için işaret işleme teknikleri ve sinir ağlarının kombine araçlarını kullanmışlardır. Elde edilen sonuçlar literatür ile karşılaştırılmıştır. Önerilen yöntem ve uzmanlar arasında yüksek bir korelasyon (0,95) raporlanmıştır.

Tongsong ve arkadaşları tarafından [63], FKHD'nin yorumu Ulusal Çocuk Sağlığı ve İnsani Gelişim Enstitüsü'nün ölçütlerine bağlı olarak değerlendirmek ve bilgisayar-destekli bir analiz ile karşılaştırmak için bir araştırma yapılmıştır. Çalışmada, doğum periyodunda olan yüksek-riskli hamile gebelerden kafa derisi elektrotları aracılığıyla elde edilen 114 EKG kaydı değerlendirilmiştir. Kayıtların tamamı, bahsi geçen kuruluşun ölçütleri bir altın standart kabul edilerek bilgisayar ile analiz edilmiştir. Altı deneyimli uzman üç guruba bölünerek her bir gurubun bilgisayar-destekli analizin ürettiği sonuçlar bir kappa değerine dayanarak karşılaştırılmıştır. Araştırma sonuçlarına göre bilgisayar destekli analiz kullanıldığında sırasıyla %81,58, %86,84 ve %82,46'lık doğruluk değerleri ile birlikte %83,62 kappa değeri elde edilmiştir. Üç grupta değerlendirilen uzmanların eriştiği doğruluk ve kappa değeri ise sırasıyla %79,82, %67,54, %79,82 ve %75,73 olmuştur. Sonuç olarak, uzmanlardan oluşan grup ve bilgisayarlı grubun *t*-test ile karşılaştırılmasına bağlı olarak *p* değeri 0,14 olarak elde edilmiş ve iki grup arasında anlamlı bir farklılığın olmadığı görülmüştür.

Ortiz ve arkadaşları [64], deneysel mod ayrışım (DMA) yöntemini kullanarak FKHD'nin yüksek frekans bilgisini analiz etmek üzere bir araştırma yürütmüşlerdir. Gebelik dönemi 36 – 40 hafta arasında olan 13 hastalardan R-R atımlarını içeren 24 kayıt elde edilmiştir. DMA kullanılarak işaretin yüksek frekans bileşenleri ( $>0.3$  Hz) elde edilmiştir. Araştırma sonuçlarına göre yüksek frekans bileşenlerinin gücünde solunumun olup olmaması ve bedensel hareketliliğin olup olması konusunda önemli farklılıklar gözlemlenmiştir ( $p < 0.05$ ). DMA'nın durağan olmayan FKH işaretlerinin değişkenliğini analiz etmede kullanışlı bir araç olduğu ifade edilmiştir.

Kupka ve arkadaşları [65], bilgisayarlı fetal izlemenin FKHD'nin otomatik analizine dayandığını belirtmişlerdir. Bu kapsamda, ilk adımın FKH için TKH tahmini olduğu vurgulanmıştır. TKH'nin değerlendirilmesi için önceden belirlenmiş temel bileşene dayalı olarak sinyalin modellenmesi yöntemi geliştirilmiştir. En iyi algoritmanın, FKH işaretini modellemek için kullanılan temel taban çizgisi ile aynı taban çizgisini sağlamaları beklenmiştir. Üretilen işaretler, iki algoritma ile tahmin edilen TKH'yi karşılaştırmak için kullanılmıştır: bu algoritmalarından ilki, yapay sinir ağlarına ve diğeri ise klasik FKH işaretlerinin doğrusal olmayan filtrelemesi temel alan bir modele dayandırılmıştır.

Georgoulas ve arkadaşları [66], özellik çıkarma ve sınıflandırma üzerine yeni bir tümleşik metot önerisinde bulunmuşlardır. Özellik çıkarımı için dalgacık dönüşümü, sınıflandırma içinse DVM'nin kullanılması sağlanmıştır. Araştırma doğum sırasında kayıt edilen örnekler üzerinde yürütülmüştür ve sınıflandırma pH değeriyle ilişkilendirilmiştir. Araştırma sonuçlarına göre her iki sınıf (normal ve riskli) üzerinde tatmin edici sonuç elde edilmiştir.

Cattani ve arkadaşları [27], çoklu regresyon yöntemini kullanarak, gebelik döneminde asfeksi tahmini yapmak üzere yeni bir tanı metodu önermişlerdir. Çalışmada 121 FKH işareti veri seti olarak ve dalgacık dönüşümü özellik çıkarmak üzere kullanılmıştır.

Ferrario ve arkadaşları [67], farklı ölçeklerde zaman serilerinin düzenliliğini tahmin etmek için çok ölçekli entropi (ÇÖE) yaklaşımını ele almışlardır. Her iki kestiricinin temel özelliklerini geliştirmek için ÇÖE analizinde simüle edilen veriler üzerinde örnek entropi ( $\text{ÖrnEn}$ ) ve yaklaşık entropi ( $\text{YaEn}$ ) değerlendirilmiştir.  $\text{YaEn}$

ve  $\text{ÖrnEn}$  entropileri FKH işaretlerine hem tek hem de çoklu ölçeklerde uygulanmıştır ve doğum öncesi dönemde stres tanımı için kullanılmıştır. Araştırma sonuçlarına göre,  $\text{YaEn}$  endeksinin, gebeliğin 30. ve 35. haftaları arasındaki normal fetüslerden sıklıkla farklı olduğu görülmüştür. Dahası, veriler ÇÖE değerlerinin doğumda patolojik bir durumun varlığı ile ilişkili fetal stresin tahmini için güvenilir göstergeler olduğunu da ispatlamıştır.

Gonçalves ve arkadaşları [68], fetal kalp hızının doğrusal ve doğrusal olmayan özelliklerini doğumdan hemen önce analiz etmişlerdir. Doğrusal özelliklerin doğumdan hemen önceki süreçte ciddi derecede arttığı, buna karşın doğrusal olmayan özelliklerde ise ciddi bir azalmanın olduğu gözlemlenmiştir. Çalışma sonuçlarına göre, orta dereceli hipoksik fetüslerden şiddetli hipoksik fetüslere geçiş ve kalan diğer kayıtlar arasındaki ayırım en verimli şekilde AE ve  $\text{YaEn}(2,0.15)$  niteliklerinin birleşimi ile yapılmıştır.

Georgoulas ve arkadaşları [69], metabolik asidoz olan yenidoğan fetüslerin tahmini için FKH işaretlerini analiz etmişlerdir. Önileme aşamasında, bebek hareketlerinden ve cihazlardan kaynaklanan gürültüyü gidermek üzere, bitişik örnekler arasında dakikada 25 atımdan daha büyük bir farklılık oluşması durumunda, bu ilk iki örnek için bir doğrusal interpolasyon uygulanmıştır. İstenmeyen girişimler ya da kayıp atımlar yavaşlama veya hızlanma gibi bir fetüs örüntüsünün içerisinde gözlemlenmesi durumunda özel bir prosedür uygulanmamıştır. Çalışmada, zaman alanından, frekans alanından ve morfolojik alandan özellikler çıkartılmıştır. Zaman alanından çıkarılan özellikler “*ortalama, standart sapma, delta, KZD, AE, UDD ve delta total*” niteliklerinden oluşturulmuştur. Frekans alanından çıkarılan özellikler ise iki farklı grup altında incelenmiştir. Birinci grup: “*ÇDF, DF, YF ve DF/YF*” niteliklerinden oluşturulmuştur. Frekans alanı için ikinci özellik seti: “*ÇDF, DF, OF, YF, DF/(OF+YF)*” niteliklerinden oluşturulmuştur. Morfolojik özellikler de frekans alanında olduğu gibi iki farklı grup altında oluşturulmuştur. Birinci grup: “*TKH, hızlanma örüntülerinin sayısı, yavaşlama örüntülerinin sayısı ve yavaşlama örüntülerinin neden olduğu zaman yüzdesi*” niteliklerinden oluşturulmuştur. Morfolojik özelliklerin ikinci grubunda alçalma örüntülerinin kategorik olarak değerlendirilmesi sağlanmıştır ve “*TKH, hızlanma örüntülerinin sayısı, hafif şiddetli yavaşlama örüntülerinin sayısı, uzun süreli yavaşlama örüntülerinin sayısı, şiddetli*

*yavaşlama örüntülerinin sayısı ve yavaşlama örüntülerinin neden olduğu zaman yüzdesi*” dikkate alınmıştır. Bu özellik setleri yalnız ve 11 farklı kombinasyon ile sınıflandırıcılara uygulanmıştır. Sınıflandırma aşamasında k-EK, doğrusal diskriminant analizi (DDA), ikinci dereceden DA, Radyal taban fonksiyonlu (RTF) DVM ve polinom çekirdekli DVM kullanmıştır. RTF çekirdeği kullanan DVM ile en iyi sonuçlara erişilmiştir ve kalite endeksi %77,14 olarak rapor edilmiştir.

Romano ve arkadaşları [70], KTG'nin fetüs olgunlaşmasını, yani otonom sinir sistemini, takip etme amacıyla kullanışlı bir araç olduğunu belirterek, fetal aktivitesini değerlendirmek üzere frekans alanında bir çalışma yürütmüşlerdir ve fetal otonom sinir sistemi (FOSS) aktivitesinin frekans alanındaki karakteristiğini ortaya koymaya çalışmışlardır. Temel amaç aktif ve aktif olmayan fetüsleri gebelik döneminde birbirinden ayırmayı sağlayacak frekans karakteristiğini ortaya koymaktır. FKHD'nin güç spektrum yoğunluğu kullanılarak frekans karakteristiği değerlendirilmiştir. Araştırmada 95 adet KTG kaydı değerlendirilmiştir. Frekans aralığı 0 – 0.2 Hz olarak belirlenmiştir. Aktif ve aktif olmayan popülasyonun özelliklerini ayırmak için önemli farklılıklar testi (*t*-test) uygulanmıştır. Araştırma sonucuna göre aktif ve aktif olmayan fetüsler arasında frekans alanında önemli farklılıkların olduğu belirtilmiş ancak sonuçların daha geniş bir analiz ile doğrulanması gerektiği vurgulanmıştır.

David ve arkadaşları [71], FKHD türetilen FOSS olgunlaşmasını tahmin etmek için niceliksel parametrelerin belirlenmesini amaçlamışlardır. Araştırma, 35 sağlıklı gebe üzerinde, gebelerin hamilelik yaşına göre üç grup altına ayrılması sağlanarak yürütülmüştür. FKHD bir zaman-frekans ayrışım metodu olan sürekli dalgacık dönüşümü ile yapılmıştır. *p* değerinin 0.05'den küçük olması durumunda gruplar arası farklılığın olduğu kabul edilmiştir. Grupları ayırmak üzere istatistiksel bir metot olan ANOVA kullanılmıştır. Araştırma sonuçları, fetüsün son üç aylık dönem sırasında sinirsel bir organizasyona uğradığını ve sempatik-vagal dengesinin gebelik yaşı ile azaldığını göstermiştir.

Romano ve arkadaşları [72], RK aktivitelere karşılık FKHD'nin güç yoğunluğunun analiz edilmesini hedeflemişlerdir. Sağlıklı fetüslerin RK aktivitesine karşılık olarak FKHD işaretinin spektral cevabı araştırılmıştır. 127 RK aktivitesine karşılık, 30 sağlıklı fetüse göre analiz gerçekleştirilmiştir. DF ve YF bantlarındaki spektral bileşenlere odaklanılmıştır. RK segmentleri ve spektral güç popülasyonlarını

ayırmak için  $t$ -testi kullanılmıştır ve  $p < 0.01$  olarak dikkate alınmıştır. DF ve YF bantları için kısa zamanlı Fourier dönüşümü (KZFD) ortalama güç değerleri 164,86 ve 75,13 olarak; RK için ise bu değerler 373,75 ve 159,5 olarak rapor edilmiştir.

Gonçalves ve arkadaşları [73], dahili ve harici olarak elde edilen FKH işaretlerini karşılaştırarak, bu iki farklı yaklaşım üzerindeki doğrusal ve doğrusal olmayan parametrelerin etkisini araştırmışlardır. Araştırma, 33 normal doğum yapan hasta üzerinde yürütülmüştür. Analiz 5, 10 ve 20 dakikalık FKH işaretlerinin bölümleri üzerinde gerçekleştirilmiştir. Pek çok zaman alanı parametreleri dahili ve harici olarak elde edilen işaretlerde benzer olarak gözlemlenmiştir. Ancak, doğrusal frekans alanı parametrelerinde zayıf bir korelasyon görülmüştür. Ayrıca, doğrusal olmayan özellikler de ise ciddi bir farklılığın olduğu ortaya konmuştur.

Georgoulas ve arkadaşları [74], asidemik fetüsleri normal fetüslerden ayırt etmek amacıyla gramatik gelişime dayanan bir metot önerisinde bulunmuşlardır. Çalışmada 20 dakika uzunluğunda olan KTG işaretleri kullanılmıştır. Zaman alanından FKH'nin ortalama, standart sapma, delta, KZD, AE, UDD ve delta total değerleri, frekans alanından ÇDF (0-0.03 Hz), DF (0.03-0.15 Hz), OF (0.15-0.5 Hz), YF (0.5-1 Hz) ve DF/(OF+YF) oranı, morfolojik olarak ise TKH, yükselme sayıları, orta, uzun ve şiddetli yavaşlama örüntüleri ve yavaşlama örüntülerinin oluşturduğu zaman oranı özellik olarak dikkate alınmıştır. Araştırma sonucunda özgüllük ve duyarlılık için %90'lık bir başarıya erişilmiştir.

Magenes ve arkadaşları [31], KTG analizi için yeni bir sistem geliştirip bu sistemin tanıtılmasını araştırma konusu olarak belirlemişlerdir. Çalışmada, FKH analizi için kullanılan geleneksel özelliklerin dışında, "*tespit edilmiş dalgalanma analizi, çok parçalı entropi (ÇPE) ve Lempel Ziv karmaşıklığı*" endekslerini birer özellik olarak kullanmışlardır. Araştırmacılar KTG analizi gerçekleştirmek üzere FKH'nin geleneksel özelliklerini geliştirerek dikkate almış ve yeni bir sistemin prototipinin tanıtılmasını çalışmalarına konu edinmişlerdir. Önerilen sistem TKH, hızlanma ve yavaşlama örüntüleri, FKHD ve ilgili parametreleri tespit edebilmektedir. Ayrıca farklı fiziksel kontrol mekanizmalarıyla ilişkili olan spektral analiz bileşenleri ile işaretin düzensizliğini ölçen yaklaşım entropisi dikkate alınmıştır.

David ve arkadaşları [75], FOSS değerlendirmek üzere niceliksel bir ölçüm tasarımı yapmış ve bunun gebelik yaşına bağlı bir fonksiyon olarak geliştirmişlerdir. Anne karnı üzerinden elde edilen 200 EKG kaydı üzerinde sürekli dalgacık dönüşümü yardımıyla araştırma yürütülmüştür. Araştırmaya göre, FKH dalgalanmalarının araştırılması için fetal kardiyak otonom kontrolünün olgunlaşması gerektiği ifade edilmiştir. Bu çalışma aslında daha önce yayımlanmış bir çalışmanın genişletilmiş yeni bir sürümü olarak sunulmuştur [71].

Gonçalves ve arkadaşları [76], fetal davranışlar durumların fetal fizyolojisi ve tipik FKH örüntüleriyle ilişkili patolojinin önemli göstergeleri olduğunu vurgulayarak, doğum öncesi dönemde fetal davranışsal durumlarla ilişkili kalp atım örüntülerinin doğrusal ve doğrusal olmayan analizini gerçekleştirmiştir. Normal dönemde bulunan gebelerden SisPorto 2.01 sistemi kullanılarak ve ortalama 40,3 dakikalık 50 kayıt üzerinde analiz gerçekleştirilmiştir. Her kayıt ardışık 10 dakikalık bölümlere ayrılmıştır ve her segment iki uzman tarafından A, B, C, D şeklinde sınıflandırılmıştır. FKH ortalaması, LDD, ÇDF, LF, YF frekans bileşenleri, *YaEn* ve *ÖrnEn* prognostik endeksler hesaplanmıştır. Uzmanlar arasındaki anlaşmazlığı değerlendirmek üzere kappa istatistiği ve anlaşma oranları kullanılmıştır. Araştırma sonucunda, kappa istatistiği ve anlaşma oranı 0,74 ve 0,94 olarak elde edilmiştir. Araştırmada, doğrusal özelliklerin değerleri artarken; doğrusal olmayan özelliklerin değerlerinde ise bir düşüşün gözlemlendiği rapor edilmiştir.

Van Laar ve arkadaşları [77], KTG'nin düşük bir tanı değerine sahip olduğunu belirterek, FOSS'nin izlenmesi için FKHD'nin spektral analizinin kullanılabileceğini ifade etmişlerdir. Yazarlar, araştırmada fetal gözetim için spektral analizin değerini saptamaya çalışan bir derleme sunmuşlardır. Araştırmada, 2007 yılına kadar yayımlanan ve spektral analizi içeren çalışmalar seçilmek üzere çeşitli veri tabanları üzerinde sistematik bir arama yapılmıştır. Sonuç olarak, altı adet çalışmayla karşılaşılmıştır. ÇDF bandı, stresli fetüsleri tanımlamak üzere %97,5'lik duyarlılık ve %86,1'lik özgüllük değeri sağlamıştır. Araştırmaya göre, FKHD'nin spektral analizi normal ve asidoz fetüsleri ayırt etmek üzere umut verici bir yöntem olarak görülmüştür. Gelecek çalışmalarda spektral analizin standartlaştırılması gerektiği vurgulanmıştır.

Niranjana Krupa ve arkadaşları [78], çalışmalarında, FKH işaretinde bulunan belli başlı FKH oluşumlarının sayısının ve oluşum sürekliliğini göz önüne alarak, TKH'nın tahmin edilmesi için bir yöntem sunmuşlardır. Sonuçlar iki uzmanın tahminleriyle karşılaştırılmıştır. Algoritma ve uzmanlar TKH tahmininde, 15 veri örneği haricinde benzer sonuçlar elde edilmiştir.

Schiermeier ve arkadaşları [79], doğum sırasında fetal asidoz için bilgisayarlı KTG analizinin duyarlılık ve özgüllüğünü belirlemek amacıyla bir araştırma gerçekleştirmiş ve geriye dönük bir gözlem çalışması tasarlamışlardır. Çalışmada, KTG ve fetal kafa derisi ölçümlerinin erişilebilir olduğu doğum verileri kullanılmıştır. CTGOnline® isimli bir yazılım ile fetal kafa derisinden elde edilen pH değerleri ve FIGO tarafından tanımlanan bilgisayarlı KTG yorum kriterlerine bağlı olarak bir korelasyon analizi yapılmıştır. Fetal asidoz için her iki koleksiyon yüksek bir duyarlılık (%95,0) ile düşük bir özgüllük (%21,8) göstermiştir. En hassas tek FIGO parametresi olarak yavaşlama örüntüsü rapor edilmiştir.

Ayres-de-Campos ve arkadaşları [80], araştırmalarında Omniview-SisPorto 3.5 olarak adlandırdıkları, KTG ve ST olay özelliklerinin bilgisayarlı analizine dayalı görsel ve sesli uyarılar sağlayan merkezi bir izleme sistemi üzerinde bir çalışma yürütmüşlerdir. KTG işaretlerinin görsel analizi zayıf şekilde yeniden üretilebilir ve STAN halen metodolojinin temel zayıflığı olarak kabul edilmektedir. Araştırmada, geliştirilen yazılımın temel özellikleri açıklanmakta ve sistemin çevrimiçi uyarılarına genel bir bakış sunulmaktadır.

Chudacek ve arkadaşları [81], gebelik sonuçlarının sınıflandırması için, fiili doğumdan önceki son 20 dakikanın KTG kaydına dayanarak, özelliklerin birkaç alt kümesini değerlendirmişlerdir. Özelliklerin alt kümeleri, TBA, bilgi kazancı ve uyarlanmış modellerin evrim grubu sinirsel seçicilik ağı algoritmasına dayanılarak oluşturulmuştur. 104 doğum dönemine ait FKH işareti çalışmada kullanılmıştır. Sonuçlar, zaman-alanlı ve doğrusal olmayan özelliklerin karışımından oluşan en iyi alt-kümenin, %70'in üzerinde hassasiyet ve özgünlükle tüm veri seti boyunca tutarlı bir şekilde performans gösterdiğini ve bunun da gözlemciler arası varyasyonlarla karşılaştırılabilir olduğunu göstermiştir.

Ferrario ve arkadaşları [82], doğum öncesi dönemde yapılan FKHD analizi temelinde, rahim-içi büyüme sınırlılığı (RİBS) yaşayan fetüslerin doğru bir şekilde tanımlanması için yeni indeksler önermektedir. Çalışmada 59 FKH zaman serisi analiz edilmiştir. Lempel Ziv Karmaşıklık endeksi (LZK) ve ÇÖE hesaplanması, yani çok parçalı bir yaklaşımla entropi tahmini de dahil olmak üzere ileri analiz teknikleri benimsenmiştir. Patolojik ve normal fetüsleri ayırmak için k-ortalama küme analizine dayanan çok parametrelili bir sınıflandırıcı da çalışma kapsamında istihdam edilmiştir. Sonuçlar, önerilen LZK'nın ve ÇÖE'nin, gerçek RİBS yaşayan fetüsleri tanımlamak ve normal fetüslerden ayırmak için faydalı olabileceğini göstermiştir. Araştırma sonucunda, iyi bir duyarlılık (%77,8) ve doğruluk (%82,4) değerleri elde edilmiştir.

Romano ve arkadaşları [83], gebelik ve doğum sürecinin sağlıklı bir şekilde planlanabilmesi için FKH işaretlerinin klinik açıdan çok önemli bir rolü olduğunu vurgulayarak, KTG tarafından sağlanan FKHD'nin otonom sinir sisteminin temel bileşenleri olan sempatik ve parasempatik sinir sistemi aktivitelerine ilişkin bilgiler taşıdığını ifade etmişlerdir. Araştırmada, zamana bağlı spektrum analizi gerçekleştirilmiş ve GSY ile farklı fetal koşulları arasında bir ilişki kurulmuştur. Araştırma sonucunda, FKHD'nin GSY ile ilişkili olan sempatovagal denge (SVD) gibi bazı önemli klinik parametrelerin KTG'nin uygun olmayan depolama hızından dolayı hatalı tahmin edilebildiği rapor edilmiştir.

Cesarelli ve arkadaşları [84], FKH değişkenliğinin ölçülmesini sağlamak üzere özlü endekslerin kullanımına dikkat çekerek, bu endekslerden en fazla odak noktası olan KZD üzerine bir araştırma gerçekleştirmişlerdir. Dokuz KZD değişkenlik indeksi (Arduini, Dalton, Organ, Sonicaid 8000, Van Geijn, Yeh, Zugaib, Arduinin düzenlenmiş bir sürümü ve standart sapma) çalışmaya konu edinmiştir. Araştırma sentetik ve gerçek kayıtlar üzerinde uygulanmıştır. Sonuç olarak, algoritmalar arasında ciddi farklılıkların olduğu rapor edilerek, standart sapma endeksinin bağımsız değişkenler göz önüne alındığında verimli sonuçlar sağlayabileceği ifade edilmiştir.

Nidhal ve arkadaşları [85], TKH tahmini için yeni bir algoritma önermişlerdir. Çalışmada 15 adet FKH işareti kullanılmıştır. TKH tahmini için Royal Kadın Hastalıkları ve Doğum Koleji kriterleri baz alınmıştır. Tahmin sonuçları uzman görüşleriyle karşılaştırılmıştır. Önerilen algoritma ve uzman görüşleri arasında hafif farklılıkların olduğu rapor edilmiştir.



Krupa ve arkadaşları [86], gebelik döneminde KTG işaretlerinin sınıflandırılması için DMA ve DVM üzerine kurulu yeni bir öneride bulunmuşlardır. Çalışmada 15 farklı denekten alınan verilerden, 20 dakika uzunluğuna sahip 90 kayıt rastgele seçilerek analiz gerçekleştirilmiştir. Tüm kayıtlar uzmanlar tarafından normal ve riskli olarak etiketlenmiştir. Analiz aşamasında, 60 kayıt eğitim için, geriye kalan 30 kayıt ise test için kullanılmıştır. DMA bileşenlerinin standart sapmaları birer özellik olarak DVM'ye uygulanmıştır. Neticede, 5-katlı çapraz sorgulama ile %86 doğruluk değeri elde edilirken, %94,80'lik bir kalite endeksine ulaşılmıştır.

Cesarelli ve arkadaşları [87], fetal durumunu daha doğru bir şekilde tespit etme amacıyla FKHD'nin spektral alandaki durumu üzerinde bir araştırma yürütmüşlerdir. Araştırmacılar özünde, FKH'nin eşit aralıklarla kayıt edilmeyen bir işaret olduğunu vurgulayarak, bu sorunu aşmak ve eşit aralıklı işaretler elde etmek üzere bir sıfır-dereceden, doğrusal veya kübik eğri enterpolasyon tekniklerinin kullanılabileceğini vurgulamışlardır. Ancak bu durumun, FKHD'nin spektral alandaki analizini olumsuz yönde etkilediği ifade edilmiştir. Özellikle, enterpolasyon sürecinin GSY'de değişiklikler üretebileceği ve bu durumda SVD'nin yanlış tahmin edilmesine neden olabileceği vurgulanmıştır. Araştırmada, SVD değerini tahmin etmek üzere, eşit aralıksız işaretlere karşılık, bu işaretlerin eşit aralıklı hale getirilmiş sürümleri kullanılmıştır. Elde edilen sonuçlar, eşit aralıklı işaretlerinden elde edilen SVD değerinin enterpolasyon ve depolama oranı nedeniyle aşırı tahmin edildiğini, buna karşılık kübik eğri enterpolasyon tekniğinin sağlam ve doğru sonuçlar ortaya koyduğunu göstermiştir.

Kwon ve arkadaşları [88], doğumda fetal göbek bağı arteriyel pH'ı ile ilgili spektral gücün değişimini saptamak üzere vakaları ön-dönem (31-36 hafta) ve normal dönem ( $\geq 37$ ) olarak ikiye ayırmıştır. Araştırmada, bir vaka-kontrol çalışması yürütülmüştür. 514 doğum durumu, düşük-pH grubu ( $\text{pH} < 7,2$ ) ve kontrol grubu ( $\text{pH} \geq 7,2$ ) olarak değerlendirilmiştir. Araştırmada, doğumda 2 saat süreyle kayıt edilen KTG işaretleri kullanılmıştır. FKHD'nin çeşitli bantlardaki spektral güçleri ölçülmüştür. Ön-dönemdeki fetüsler, toplam, DF ve OF spektral güçleri ve  $DF/YF$  oranı, kontrol grubuna göre önemli derecede düşük çıkmıştır. Ön-dönem ve normal dönem fetüsleri için AİK'nin altında kalan alan (AİK-AKA), 0,794 ve 0,595 olarak rapor edilirken;

özgüllük %86,8 ve %93,3 olarak rapor edilmiştir. Sonuç olarak, FKHD'nin spektral analizinin asidoz tahmini için kullanışlı bir araç olabileceği vurgulanmıştır.

Warrick ve Hamilton [89], doğum ve doğumdan alınan KTG verilerini kullanarak, FKHD'ni kasılmayla ilgisiz durgun bileşenler ve kasılmaya tepki veren bir tepe bileşen içinde otoregresif güç spektrum yoğunluğu analizine dayanarak ayırmayı amaçlamışlardır. Doğum eylemi ve doğumun son üç saatlik periyodunda, bu yaklaşım OF'de 18 fetüsten 15'ini, DF'de 18 fetüsten 11'ini normal ve patolojik olarak ayırt edebilmiştir. Bu sonuçlar, daralma ve kasılma aralıkları arasında ayırım yapmayan daha uzun bir zaman aralığına dayanan önceki sonuçlardan daha üstün olarak değerlendirilmiştir. Ayrıca yaklaşımın, hipoksiye ilişkin tarama konusunda da çok umut verici olduğu vurgulanmıştır.

Czabanski ve arkadaşları [33], çalışmalarında yenidoğan asidemi tahmini yapmak üzere iki aşamalı bir analiz önermişlerdir. Birinci aşamada, FIGO tanımlamalarına [18] dayanan bir bulanık sınıflandırıcının fetüs durumunu tahmin etmesi sağlanmıştır. Bu aşama bir nevi izleme aşaması gibi çalışmaktadır. İkinci aşamada, birinci aşamada anormal olarak işaretlenmiş kayıtlar üzerinde analiz yürütülmüştür ve YSA ile Lagrange DVM (LDVM) kullanılmıştır. Çalışma sonucunda doğru sınıflandırma ve kalite endeksi sırasıyla %92,0 ve %88,2 olarak raporlanmıştır. Bu değerlere LDVM kullanılarak erişilmiştir.

Huang ve Hsu [90], fetal stres seviyesinin değerlendirilmesini sağlamak üzere diskriminant analizi (DA), karar ağacı (KA) ve YSA'yı kullanmışlardır. UCI-KTG veri seti çalışmada kullanılmıştır. DA, KA ve YSA için sırasıyla %82,10, %86,36 ve %97,78 doğruluk değerleri elde edilmiştir.

Cesarelli ve arkadaşları [91], doğrusal çalışmaların geniş ölçüde FKHD ve FOSS'nin gelişimi ile korelasyonu arasına yoğunlaştığını ifade ederek, doğrusal olmayan bir yöntem olarak kabul edilen sembolik dinamiğe dayalı bir analiz gerçekleştirmişlerdir. Araştırmada 300 adet FKH işareti kullanılmıştır. Analiz SVD'nin ve değişkenlik endeksinin üzerine inşa edilen 5 farklı sembolle (yüksek bir SVD aktivitesi "V", SVD aktivitesi "D", değişkenliğin yokluğu "O", sempatik aktivite "A", yüksek sempatik aktivite "S") ifade edilmiştir. Araştırma sonucunda, sembolik

dinamiklerin FKHD'yi göstermek ve karakterize etmek için kullanışlı bir araç olduğu ifade edilmiştir.

Sundar ve arkadaşları [92], KTG testinin duyurulmasından hemen sonra kliniklerde yaygın bir şekilde kullanıldığını belirterek, testin tahmin kapasitesine ait tartışmaların devam ettiğini ifade etmişlerdir. UCI-KTG veri seti araştırmada kullanılmıştır. Çalışmada, bir denetimli öğrenme yaklaşımı olarak YSA kullanılmıştır. Sınıflandırıcının performansını değerlendirmek üzere hassasiyet, duyarlılık, F-skor ve Rand endeks metrikleri kullanılmıştır. Araştırma sonucuna göre, YSA'nın normal, şüpheli ve patolojik KTG örneklerini ayırt etme konusunda başarılı olduğu rapor edilmiştir.

Spilka ve arkadaşları [93], doğrusal olmayan FKH özelliklerini kullanarak normal ve asidemik fetüsleri ayırt eden bir analiz gerçekleştirmiştir. Çalışmada 217 adet FKH işareti kullanılmıştır. Araştırmada doğrusal ve doğrusal olmayan özellikler karşılaştırılmıştır. En iyi sonuçlara doğrusal ve doğrusal olmayan özelliklerin birleşimi ile ulaşılmıştır. En iyi doğrusal olmayan özellikler olarak Lempel Ziv karmaşıklığı, basit entropi ve Higuchi tarafından tahmin edilen fraktal boyut seçilmiştir. Araştırma sonucunda, %73,4 duyarlılık ve %76,3 özgüllük rapor edilmiştir.

Sundar ve arkadaşları [94], bir denetimli öğrenme metodu olan YSA ile yapılan sınıflandırma sonuçlarını, en yaygın şekilde kullanılan bulanık C-ortalama ve k-ortalama kümeleme teknikleriyle karşılaştıran bir araştırma yapmışlardır. Çalışmada, UCI-KTG veri seti kullanılmıştır. Araştırma sonuçlarına göre, denetimsiz öğrenme modelleriyle kıyaslandığında YSA, sınıflandırma performansı üzerinde çok daha iyi sonuçların elde edilmesini sağlamıştır.

Romano ve arkadaşları [95], fetal re-aktivitesini ve refahını vurgulamak amacıyla FKHD'nin önemli bir parametre olarak kabul edildiğini vurgulayarak, doğrusal olmayan yöntemlerle KTG analizi için sembolik bir uygulama gerçekleştirmiş ve FKHD'yi ölçmek amacıyla yeni bir endeks tanımlı yapmışlardır. Çalışmada 334 doğum öncesi döneme ait kayıt değerlendirilmiştir. Sonuç olarak, önerilen endeksin FKHD değişimindeki farklılıkları vurgulayabildiği ve farklı doğum türleriyle (doğal veya sezaryen) yüksek bir korelasyona sahip olduğu ve özellikle yüksek değişkenlik endeksinin normal doğuma karşılık geldiğini rapor etmişlerdir.

von Steinburg ve arkadaşları [10], normal olarak değerlendirilebilecek FKH için standart bir aralığın tanımlanmadığını ifade ederek, kesin bir tanımlama yapmak üzere bir araştırma yürütmüşlerdir. Çalışmada 2000 - 2007 yılları arasında Almanya'da toplanan 78,852 adet kayıt kullanılmıştır. Araştırma sonucuna göre dakikada 115-120 ile 160 atım arası normal aralık olarak ifade edilmiştir ve FKH'nın gebelik yaşına bağlı olarak düştüğü vurgulanmıştır.

Ocak ve Ertunç [96], fetal durumunun değerlendirilmesini sağlamak üzere UBSÇS önerisinde bulunmuşlardır. Metot UCI-KTG veri seti üzerinde yürütülmüştür ve veri seti kullanılırken şüpheli örnekler dikkate alınmamıştır. UBSÇS yapay sinir ağı ile kıyaslandığında az bilinen yumuşak bir hesaplama tekniğidir. Metot, ileri-beslemeli hesaplama çıkışı ve bulanık mantığın insan-gibi nedenselliğini birleştirmektedir. Araştırma sonucunda, normal ve hastalıklı verileri ayırt etmek üzere sırasıyla %97,2 ve %96,6 doğruluk değerleri elde edilmiştir.

Ocak [97] tarafından yapılan çalışmada, DVM ve genetik algoritma (GA) kullanılarak fetal refah seviyesinin belirlenmesi amacıyla bir araştırma yürütülmüştür. Araştırmada UCI-KTG veri tabanı kullanılmıştır. GA, DVM için maksimum sınıflandırma performansını verecek alt özellik setlerinin bulunması ve mevcut özellik setindeki boyutun düşürülmesi amacıyla istihdam edilmiştir. Araştırma sonucuna göre normal hipoksik fetüsleri ayırt etmek üzere sırasıyla %99,3 ve %100 doğruluk değerleri elde edilmiştir. Geleneksel olarak kullanılan YSA ve UBSÇS tabanlı metotlara göre önerilen yöntem daha iyi sonuç üretmiştir.

Cesarelli ve arkadaşları [98], sembolik dinamikleri dayalı bir uygulama geliştirmişlerdir. Amaç, doğum öncesi dönemde KTG işaretlerinin sınıflandırılması için bir endeks tanımlamaktır. Bu amaç için önerilen endeks FKH farklılıklarını vurgulayacak yeteneği göstermiştir ve doğumdaki Apgar skoru ile ilişkilendirilebilmiştir.

Fanelli ve arkadaşları [99] tarafından, fetal iyilik halinin nicel olarak değerlendirilmesine katkı sağlamak üzere ortalama faz doğrultulmuş eğitim (OFDE) tabanlı yeni bir endeks tanımı yapılmıştır. Amaç normal ve RİBS yaşayan fetüsleri ayırt etmektir. Bu endeks tanımı hızlanma ve yavaşlama örüntüleri için sırasıyla hızlanma fazı doğrultulmuş eğitim (HFDE) ve yavaşlama fazı doğrultulmuş eğitim

(YFDE) olarak ayrı ayrı tanımlanmıştır. OFDE yaklaşımı, tüm periyodik bileşenlerin fazını senkronize ederek, gürültü ve girişimlerden etkilenen durağan olmayan sinyallerdeki yarı-periyodik salınımların saptanmasına ve sayısallaştırılmasına olanak tanımaktadır. Çalışmada veriler elde edilirken otokolerasyon yöntemi kullanılmıştır. İşaretler, 3 dakikalık parçalara bölünerek prognostik indislerin hesaplanması sağlanmış ve daha sonra her bir indis değerinin ortalaması alınarak özellik seti oluşturulmuştur. KZD, UDD, AE ve Delta zaman alanı parametreleri,  $YaEn(1,0.2)$  doğrusal olmayan endeks ve OFDE endeksleri özellik olarak kullanılmıştır. Araştırma sonuçlarına göre, özellik seti üzerinde uygulanan  $t$ -testi ile zaman alanında KZD ve Delta parametrelerinin normal ve RİBS yaşayan fetüsleri ayırmak üzere en iyi performansı sergilediği görülmüştür. UDD parametresinin de ayırım gücü olduğu belirtilmiştir.  $t$ -testine göre AE'nin ayırım gücü anlamlı bulunmamıştır. OFDE tabanlı yaklaşıma göre ise HFDE ve YFDE özelliklerinin ayırım gücü olduğu vurgulanmıştır. Optimal ayırım eşiğini belirlemek için AİK eğrileri en verimli parametreler için hesaplanmıştır. HFDE için bir kesim değeri 0,1327 olarak belirlenmiştir ve eşik değeri %74,13'lük duyarlılık ve %80,33'lük bir özgüllük değerini garanti etmektedir. Buna karşılık gelen AİK-AKA değeri 0,8235 olarak rapor edilmiştir. Benzer şekilde, YFDE için eşik değeri -0,1426, buna karşılık %77,05 duyarlılık ve %75,41'lik özgüllük değeri garanti edilmiştir. AİK-AKA değeri ise 0,8371 olarak belirtilmiştir.

Tarvainen ve arkadaşları [100], doğrudan FKH işaretleri için olmasa da kalp hızı değişkenliğini (KHD) ölçen bir yazılım geliştirmişlerdir. Bu yazılım, ayarlanabilir çeşitli parametrelere aracılığı ile farklı veriler için metotların optimize edilebilmesini sağlamaktadır. Yazılım zaman, frekans ve doğrusal olmayan alanlardan elde edilen özellikler ile KHD'yi analiz edebilmekte ve çeşitli formatlarda raporlar oluşturabilmektedir.

Improta ve arkadaşları [101], son yıllarda KTG işaretlerinin analizi için pek çok bilgisayarlı metodun geliştirildiğini ve kullanıldığını ifade etmişlerdir. Bilgisayarlı KTG analizinin temel amacının başta KTG yorumunda gözlemciler arası ve hatta gözlemciler içi yüksek anlaşmazlık seviyesinin düşürmek ve KTG yorumunda yeniden üretilebilirliğin tutarlı bir şekilde sağlanması ve nihai olarak KTG'ye dair dezavantajların üstesinden gelinmek istediğini vurgulamışlardır. Bu amaç doğrultusunda, sentetik KTG işaretleri üreten bir yazılım geliştirilmiştir. Yazılımın

ürettiği işaretler TKH, hızlanmalar, yavaşlamalar ve kasılma niteliklerini de kapsamakla birlikte; kullanıcıdan alınan parametreler doğrultusunda patolojik örneklerinde oluşturulmasına olanak tanımaktadır.

Karabulut ve İbrikçi tarafından [102], KTG verilerini analiz etmek üzere bilgisayarlı bir yaklaşım önerilmiştir. Bu amaçla KA için uyarlanabilir bir yükseltme topluluğu önerilmiştir. Çalışmada, UCI-KTG veri seti kullanılmıştır. Verilerin işlenmesi için WEKA yazılımından faydalanılmıştır. Önerilen modelin değerlendirilmesini sağlamak üzere ortalama mutlak hata (OMH), kapa istatistik ve doğruluk metrikleri kullanılmıştır. Araştırma sonuçlarına göre %95,01'lik doğruluk değeri elde edilmiştir.

Jezewski ve arkadaşları [103], bilgisayarlı KTG analizinde makine öğrenmesi tekniklerinin verimliliği arttırmak üzere TBA, AİK ve FIGO kılavuzunu içeren üç farklı özellik seçim yönteminin fetal durumunu değerlendirme üzerindeki etkisini araştırmışlardır. Çalışmada UCI-KTG veri seti kullanılmıştır. Sınıflandırma aşamasında LDVM istihdam edilmiştir. Sınıflandırma öncesinde veri setindeki özellikler [-1, +1] aralığına çekilmiştir ve veriler %50 eğitim, %50 test amacıyla kullanılacak şekilde bölünmüştür. Normal, şüpheli ve patolojik sınıfların tamamı öneride değerlendirilmiştir. Araştırma sonuçlarına göre tüm özellikler kullanılarak elde edilen doğruluk, TBA, AİK ve FIGO'ya göre daha üstün olarak, sırasıyla %88,01, %86,88, %85,07 ve %86,40 olarak rapor edilmiştir.

Spilka ve arkadaşları [104], KTG yorumunda yüksek seviyedeki gözlemciler-arası ve hatta gözlemciler-içi anlaşmazlık seviyesine dikkate çekerek, genellikle kapa istatistiği gibi niceliksel ölçütlerin kullanıldığını; ancak bu ölçütlerin klinik tanı açısından anlamlı olmadığını ifade etmişlerdir. Bu nedenle, çalışmalarında klinik değerlendirmenin verilere dayalı bir analizin yapılmasını amaçlamış ve gizli sınıf modeli yaklaşımını önermişlerdir. Araştırma sonunda özellikle patolojik örnekleri değerlendirme konusunda önemli bir gelişmeye erişilmiştir. Dahası, gizli sınıf modelinin analizi, klinik değerlendirmenin üç sınıfın tanımlandığı FIGO kurallarına dayansa da, uzmanların KTG kayıtlarını değerlendirirken bilinçsizce dört sınıfa girdiklerini ortaya koymuştur.

Ravindran ve arkadaşları [105], fetüs sađlık durumunu deđerlendirmek üzere geliřtirilmiř uyarlamalı genetik algoritmaya (GUGA) ve AÖM'ye dayalı yeni bir klinik karar destek sistemi önermiřlerdir. GUGA erken yakınsamayı engellemek üzere yeni bir ölçekleme tekniđi kullanmaktadır. Ayrıca, arama fonksiyonu performansı deđerlendirmek üzere üç farklı uygunluk fonksiyonu çalıřtırmaktadır. Çalıřmada, UCI-KTG veri seti kullanılmıřtır. Sonuç olarak %94'lük dođruluk deđerleri elde edilmiřtir.

Sahin ve Subařı çalıřmalarında [106], dođum öncesi KTG verilerinde sekiz farklı makine-öđrenme yönteminin sınıflandırma performanslarını deđerlendirmeyi amaçlamıřtır. Çalıřmada UCI-KTG veri seti kullanılmıřtır. En yüksek dođruluk deđerine rastgele orman (RO) algoritmasıyla (%99,2 olarak) eriřilmiřtir.

Shah ve arkadaşları [107], KTG verilerini kullanarak normal ve patolojik fetal durumunun saptanması için üç geleneksel karar ađaç algoritması (rasgele orman, Azalan Hata Budama Ađacı (REPTree) ve J48) ile birlikte torbalama yaklařımını kullanmıřlardır. Çalıřmada UCI-KTG veri seti kullanılmıřtır. Arařtırmalar, karar ađaçları algoritmalarının ve torbalamanın, tıbbi alanda sađlıklı ve patolojik sınıfların sınıflandırılmasında muazzam ilerlemeler gösterdiđini göstermektedir. Sınıflandırıcıların parametreleri, veri setlerine uygulanmadan önce optimize edilmiřtir. 10-katlı çapraz-dođrulama, sınıflandırıcıların sađlamlıđını incelemek için kullanılmıřtır. Daha sonra, korelasyon özelliđi seçimi - alt küme deđerlendirme yöntemini kullanarak, daha düşük bir özellik alanı elde edilmiř ve önerilen yöntem kullanılarak analiz edilmiřtir. Tam ve azaltılmıř özellik uzayı ile 0,90'dan büyük deđerler elde edilmiřtir. Önerilen yöntem, hem tam hem de azaltılmıř özellik alanı senaryolarında daha iyi sınıflandırma göstermiřtir.

Romano ve arkadaşları [108], FKHD'nin zaman ve frekans alanında yapılan analizlerinin klinik açıdan ilgi çekici olduđunu vurgulayarak, frekans alanı analizi ve zaman alanı analiz üzerine bir derleme çalıřması sunmuřlardır. Ayrıca, 400'ün üzerinde gerçek FKH iřareti üzerinde en fazla önerilen endekslere bađlı olarak bir analiz gerçekteřtirilmiřtir. Sonunda, bu endeksler arasındaki iliřki dođrulanmıřtır. Çalıřma sonuçlarına göre FKHD'nin deđerlendirilmesi için gebelik yařı ve fetal durumunun analizden önce dikkate alınması gerektiđi vurgulanmıřtır.

Jyothi ve arkadaşları [109], çalışmalarında KST işaretlerini analiz etmişlerdir. KST işaretleri yüksek ve alçak frekans gürültüleri içermektedir. Doğumun yaklaşmasına bağlı olarak artan doğum stresi neticesinde, işaretin içerdiği yüksek frekans gürültüsü de artmaktadır. Araştırmacılar bir hareketli ortalama filtre kullanarak bu problemi gidermiştir. Düşük-frekans gürültüsü, çoğu zaman baz çizgisi dolaşımı olarak da tanımlanır, interpolasyon tekniği kullanılarak problem de aşılmıştır. Çalışmada, sonlu dürtü yanıtı bir yüksek geçiş filtresi kullanılarak, işaretin içerdiği alçak frekans gürültüsü eleme edilmiştir. Yüksek geçiş filtresinin kesim frekansı, düşük frekans gürültüsünün GSY'ye bağlı olarak belirlenmiştir. Sınıflandırma aşamasında kullanılmak üzere yoğunluk, süre, her bir kasılmanın alanı ve gücü, yükselme zamanı, düşme zamanı, ortalama süre ve standart sapma süresini nitelikleri dikkate alınmıştır. Jyothi ve arkadaşları KST işaretlerini hafif, orta ve güçlü olarak sınıflandırırken ağırlıklı en yakın komşu (EYK) ve KA'ı kullanmışlardır. Farklı türlerdeki ağırlıklı EYK sınıflandırıcı ile en iyi sınıflandırma doğruluk sonuçları her bir sınıf için sırasıyla %90,91, %77,50 ve %85,71 olarak elde etmişlerdir. KA ile elde edilen doğruluk sonuçları ise %81,82, %92,50 ve %89,29 olarak rapor edilmiştir.

l'Aulnoit ve arkadaşları [110], çalışmalarında TKH analizinin yapılmasına olanak sağlayan ve literatürde önde gelen 11 farklı algoritmayı değerlendirmişlerdir. Önişleme sürecinde, TKH'yi tanımlamak üzere neredeyse tüm algoritmelerde *doğrusal filtre* ve *kayma modu* kullanılmıştır. Doğrusal filtreleme, ortalama filtrenin uygulanmasını sağlayan kayan bir pencere yardımıyla kullanılır. Filtreleme TKH seviyesindeki değişkenliği ortadan kaldırır. Yalnız tek başına kullanıldığında bir takım sinyal işleme problemlerine yol açtığı rapor edilmiştir. Kayma modunda ise TKH için salınımları takip eden bir çizginin çizdirilmesi önerilmiştir. Mongeli, Lu, Pardey ve Wrobel tarafından geliştirilen TKH tahmin algoritmalarının en iyi sonuçları verdiği raporlanmıştır. Bilgisayarlı FKH analizinin morfolojik özellikleri analiz etmede bir uzman ya da uygulayıcıdan daha üstün olduğu; ancak TKH tespitinde uzmanların bilgisayarlara göre daha iyi değerlendirmeler yaptığı çalışmada raporlanmışlardır.

Horoba ve arkadaşları [111], kasılma işaretlerinin otomatik olarak tespit edilmesini sağlamak üzere 4 farklı algoritma üzerinde çalışmıştır. Bu algoritmalar üç tanesi işaretlerin frekans dağılımlarına; bir tanesi de rahim aktivitesinin değişim oranlarına odaklanmıştır. Kasılmaların tespiti için algılama seviyesi, başlama zamanı,



en yoğun zaman, süre, tepe genliği ve bazal ton gibi özellikler kullanılmıştır. Tüm algoritmalar %91'in üzerinde başarı elde etmiştir.

Jezewski ve arkadaşları [112], TKH tahmin algoritmalarının karşılaştırılabilmesi için *sentetik tutarsızlık katsayısı* olarak ifade ettikleri yeni bir endeksin kullanılmasını önermiştir. Çalışmada iyi bilinen 11 farklı TKH tahmin algoritmasını kullanılmıştır. Bu çalışma sayesinde, TKH tahmin algoritmaları kontrol etmek üzere yeni bir endeksin kullanılabilmesi sağlanmıştır.

Magenes ve arkadaşları [113], normal ve RİBS olan fetüsleri ayırt etmek için bir araştırma yürütmüşlerdir. "*Zaman alanında delta, KZD, UDD ve AE; frekans alanında DF, OF, YF ve DF/(OF+YF); doğrusal olmayan analize bağlı olarak LZK, Yaklaşım entropisi (YaEn), HFDE ve YFDE özelliklerini kullanılmıştır*". Toplamda 12 adet indis ve 15 adet veri madenciliği tekniği kullanılmışlardır. Araştırma 61 sağlıklı, 61 RİBS olmak üzere toplam 122 fetüs üzerinde yürütülmüştür. Performans sonuçlarına karşılaştırmak üzere AİK-AKA dikkate alınmıştır. Araştırma sonuçlarına göre RO ve lojistik regresyon algoritmaları en iyi sınıflandırma doğruluğunu üretmişlerdir.

Romano ve arkadaşları [34], KTG işaretlerini analiz etmek üzere kapsamlı bir araştırma neticesinde bir yazılım üretmişlerdir. Temel amaç KTG işaretlerini analiz etmek için araştırma amacıyla kullanılacak bir yazılımın karakteristiğini ve potansiyelini ortaya koymaktır. Yazılım gerçek ve sentetik KTG işaretleri üzerinde çalışabilmektedir. Sentetik KTG işaretlerinin kullanılması altında yatan temel düşünce karakteristiği önceden bilinen bir işaretin analizinde yazılımın performansını ölçmeye imkan tanınmasıdır. Ayrıca, bu senaryo çeşitli karakteristik KTG işaretleri için standart bir kliniksel yaklaşım ortaya konabilmesine de katkı sağlamak üzere tasarlanmıştır. Geliştirilen yazılım esasen kliniksel açıdan hayati önem taşıyan morfolojik özelliklere odaklanmakla birlikte, çıplak gözle tespit edilmesi olası olmayan zaman alanı ve doğrusal olmayan özelliklerinde ortaya çıkarılmasını sağlamaktadır.

Yılmaz [114], fetüs durumunu normal, şüpheli ve patolojik olarak sınıflandırmak üzere üç farklı YSA kullanmıştır. Bunlar ÇKAM-SA, olasılıksal sinir ağı (O-SA) ve genelleştirilmiş regresyon sinir ağı (GR-SA) ağlarıdır. Çalışmada UCI-KTG veri seti kullanmıştır. Sınıflandırıcıların performanslarını karşılaştırmak üzere hata matrisi, AİK eğrisi ve Cobweb metotları kullanılmıştır. Araştırma sonucuna göre hata

matrisine bağılı olarak elde edilen doğruluk deęerleri KAM-SA, O-SA ve GR-SA iin sırasıyla %90,35, %92,15 ve %91,86 olarak elde edilmiřtir. Dolayısıyla, en iyi sınıflandırıcı olarak O-SA rapor edilmiřtir.

Wosiak ve arkadaşları [115], makine öğrenme yöntemlerini kullanarak RİBS tiplerinin otomatik tanımlanmasıyla ilgilenmişlerdir. Arařtırmada, kümelenmenin yanı sıra, tek ve melez sınıflandırmayı kapsayan üstün ve denetlenmemiş öğrenmenin bir karşılařtırması sunulmuřtur. Denetlenen öğrenme teknikleri arasında Naive Bayes, k-en yakın komřu (k-EK), C4.5 ve SMO temel sınıflandırıcılar, RO, baz ağacı sınıflandırıcısı olarak bir karar ağacı ve DVM iin sıralı minimum optimizasyon algoritmaları kullanılmıştır. Denetimsiz öğrenme, k-ortalama ve beklenti maksimizasyonu algoritmalarını kapsamıştır. alıřmadan elde edilen en önemli sonu, melez sınıflandırıcıların simetrik ve asimetrik RİBS türlerini daha doğru olarak tanımlama potansiyelini göstermesine karşı denetimsiz öğrenme tekniklerinin en kötü sonuları vermesi řeklide ifade edilmiřtir.

Yu ve arkadaşları [116], FKH işaretlerinin hiyerarşik Dirichlet yöntemi karışım modelleri ile analiz edilmesini önermiştir. Bu modellerle elde edilen gerek FKH zaman serilerinin kümeleme sonularının bir fetüsün saęlık durumunun belirlenmesi aısından bilgilendirici olup olmadığını arařtırılmıştır. Kayıtlar saęlıklı ve patolojik olarak pH deęeri göz önüne alınarak iki sınıfa ayrılmıştır. Her bir grupta görünen kümelerin frekansları hesaplanmış ve frekansları karşılařtırmak iin Mann-Whitney U testi uygulanmıştır. Sonular, belirli kümelerin ortaya ıkıř sıklıklarının iki grupta istatistiksel olarak önemli derecede farklı olduğunu göstermiştir. Bir bařka ifadeyle, bazı kümelerin patolojik fetal nabız modelleri ile iliřkili olabileceęi sonucuna varılmıştır.

Czabanski ve arkadaşları [117], fetal durum deęerlendirmesinin doęum sonularından sonra elde edilen parametrelerin bulanık analizine bağılı olarak, geri dönük bir deęerlendirmenin yapılması iin bir yöntem sunmuşlardır. Yazarlar, gerek klinik veri kümelerinde, anormal fetal durumyla ilgili işaretler sınıfının genellikle yetersiz olduğunu vurgulayıp, bu durumun otomatik deęerlendirmenin verimlilięini olumsuz yönde etkiledięini ifade etmişlerdir. Buna ek olarak, önerilen bulanık modele dayanan sınıf boyutları arasındaki orantısızlıęı azaltmak iin bir yöntem anlatılmıştır.

Araştırma sonucunda, LDVM bulanık çıkarım tabanlı öğrenmenin, fetal durum değerlendirmesinde nihai olarak verimliliği arttırdığını ifade etmişlerdir.

Jezewski ve arkadaşları [118], sundukları çalışmada, prototip çiftleri ile bulanık kümeleme temelli KTG işaretlerinin değerlendirilmesini anlatmışlardır. Önerilen yöntemin etkinliği, KTG işaretlerinin analizi için yaygın olarak kullanılan iki farklı veri seti üzerinde (CTU-UHB ve UCI-KTG) doğrulanmış ve üç sınıflı sınıflandırma problemleri dikkate alınmıştır. Elde edilen sonuçlar, uygulanan referans prosedürlere göre otomatik fetal durum değerlendirmesinin gelişmiş kalitesini Bulanık (c + p)-means kümeleme ve LDVM referans metotları üzerinde göstermiştir.

Yılmaz [119], fetal refah seviyesinin belirlenmesi amacıyla bir karar destek sistemi önermiştir. Önerilen sistem en küçük kareler destek vektör makineleri (EK-DVM) ve TBA üzerinde temellendirilmiştir. TBA özellik setinde boyut indirimi yapmak üzere kullanılmıştır. Boyutu indirgenen özellik seti EK-DVM'ye girdi olarak uygulanmıştır. Sınıflandırma noktasında daha güvenilir sonuçlar elde etmek üzere 10-katlı çapraz doğrulama tekniği çalışma kapsamında dikkate alınmıştır. Önerilen sistem %98,74 sınıflandırma doğruluğuna, %98,86 duyarlılığa ve %98,73 özgüllük oranına sahip olmuştur.

Ayres-de-Campos ve arkadaşları [120], SisPorto 4.0 olarak adlandırdıkları yazılım ile KTG ve ST analizini gerçekleştirmektedirler. Sistem 2015 yılında FIGO kabullerine bağlı olarak güncellenmiştir. Çalışmada, temel KTG özelliklerinin belirlenmesinde kullanılan sinyal işleme algoritmaları ve elde edilen gerçek zamanlı uyarılar da dahil olmak üzere, sistem tarafından gerçekleştirilen analizin detaylı bir tarifi sağlanmıştır.

### 3. MATERYAL VE YÖNTEM

Gebelik ve doğum sürecinde yaygın olarak kullanılan bir tanı testi olan KTG'nin bilgisayarlı analizi için önışleme, özellik çıkarımı, özellik seçimi ve sınıflandırma adımları takip edilmesi gereken başlıca analiz aşamalarıdır [38].

KTG testi invaziv olmayan bir testtir ve testi oluşturan kayıtlar genellikle harici bir yolla elde edilmektedir. Bu nedenle KTG testi, işaretlerin bozulmasına sebep olan ve istenmeyen pek çok girişim içermektedir [12]. Önışleme sürecinde, işaretin, doğasında taşıdığı ve tanı için önem arz eden özellikleri kaybetmemek koşuluyla istenmeyen girişimlerden, bir başka ifadeyle gürültülerden arındırılması hedeflenir. Analizin diğer aşamalarını doğrudan ve dolaylı olarak etkilediğinden, önışleme adımı kritik bir öneme sahiptir [121].

KTG için başta morfolojik olmak üzere, zaman, frekans ve doğrusal olmayan alanlardan çıkartılan pek çok prognostik endeks bulunmaktadır [34]. Özellikle morfolojik özellikler, kliniksel açıdan taşıdığı öneme ilaveten, neredeyse KTG analizi için önerilen bilgisayarlı destekli yaklaşımların tümünde vazgeçilmez bir özellik kümesi olarak değerlendirilmektedir [18], [22]. Ayrıca zaman alanından elde edilen doğrusal özellikler, işaretin düzensizliği üzerine tahmin yapan entropi tahmin edicileri ve doğrusal olmayan özellikler de FKH işaretinin temsil gücünü arttırmaktadır [68], [73]. Bahsi geçen tüm endeksler, işaretin bütünü yerine bir takım sayısal metriklerle işareti temsil etmek üzere kullanılmaktadır. Bu noktada bir diğer önemli konu, amaca yönelik özelliklerin seçilmesi ve bir başka ifadeyle özellik boyutunun indirgenmesidir [81]. Bu süreç sınıflandırma doğruluğunu arttırmakla birlikte sınıflandırma aşamasında ortaya çıkması olası olan hesaplama karmaşasının ve gereksiz işlem yükünün de önlenmesini sağlamaktadır [103].

Tanı koyma ve karar verme sürecini destekleyen sınıflandırma aşaması, ağın eğitiminden sonra kendisine verilen kaydın normal, şüpheli ya da patolojik gibi önceden tanımlanan sınıflardan hangisinde yer alacağına dair kararın verildiği analizin son aşamasıdır. Bu aşamada sağlam ve gelişmiş pek çok sınıflandırıcı hali hazırda zaten kullanılmaktadır [106], [113].

Özetle, günümüzde kliniksel olarak bir hastalığa tanı koyma süreci, gelişmiş işaret ve imge işleme yöntemleri ve makine öğrenmesi tekniklerinin kullanımıyla iç içe

geçmiş durumdadır. Bu bağlamda oldukça zengin bir literatür bulunmaktadır. Bu bölümdeki amacımız, KTG işaretlerinin elde edilmesiyle başlayıp, sınıflandırılmasıyla son bulan analiz süreci için kullanılan veri kaynaklarını ve yöntemlerini belirli bir çerçevede kapsamında ifade etmektir.

### **3.1. Veri Koleksiyonları**

Bu tez çalışması kapsamında, KTG işaretlerinin analiz edilmesi amacıyla açık erişilebilir durumda olan, hali hazırda pek çok çalışmaya kaynaklık etmiş, “*UCI-KTG veri seti*” ve “*CTU-UHB veri tabanı*” kullanılmıştır.

İlgili veri seti ve veri tabanı sırasıyla Bölüm 3.1.1 ve Bölüm 3.1.2 altında detaylı olarak incelenmiştir.

#### **3.1.1. UCI-KTG Veri Seti**

UCI-KTG veri seti, FIGO kılavuz ilkelerini yakından takip eden ve KTG işaretlerinin otomatik analizini gerçekleştirmek üzere geliştirilen SisPorto® isimli yazılım tarafından otomatik olarak oluşturulmuş bir veri setidir. SisPorto® programı çok büyük veri setleri üzerinde kullanılmış, kliniksel olarak sağladığı fayda doğrulanmış ve hali hazırda ticarileşmiş bir yazılımdır [28].

SisPorto® yazılımı, 10 dakika süreyle veri topladıktan sonra, KTG işaretinin analizine başlayıp, her 1 dakikada bir ardışık olarak analizi güncellemektedir [120]. Yazılım, FKH işaretlerinde, anormalliklerin kaldırılması, TKH'ı tahmini, hızlanma ve yavaşlama örüntülerinin tespiti gibi morfolojik özelliklerin çıkartılması işlemlerini otomatik olarak gerçekleştirmektedir. Ayrıca, yazılım rahim kasılması aktivitelerini içeren işaretlerin filtrelenmesi ve taranması gibi KTG analizi için gerekli pek çok adımı otomatik olarak gerçekleştirebilme yeteneğine de sahiptir [122]. SisPorto® yazılımı ST analizinin de yapılabilmesine imkan tanımaktadır.

UCI-KTG veri seti, SisPorto® yazılımı tarafından otomatik olarak çıkartılan, FKH ve RK işaretlerini temsil eden 21 adet nicel parametreden ve 2126 kayıttan oluşmaktadır. İşaretleri temsil eden özelliklerin 8 tanesi ayrık, 12 tanesi sürekli ve 1 tanesi kategorik değerlerden oluşmuştur [90]. Kayıtların 1655 tanesi normal, 295 tanesi şüpheli ve 176 tanesi patolojik olarak uzmanlar tarafından etiketlenmiştir.

Çizelge 3.1 UCI-KTG veri setinin sahip olduğu özelliklerin açıklanması


No	Özellik	Açıklama	Ölçek
1	TKH	Temel kalp hızı	Ayrık
2	HÖ	Hızlanma örüntüleri	Sürekli
3	FH	Fetal hareketler	Sürekli
4	RK	Rahim kasılmaları	Sürekli
5	YÖ	Yavaşlama örüntüleri	Sürekli
6	ŞYÖ	Şiddetli yavaşlama örüntüleri	Sürekli
7	UYÖ	Uzun süreli yavaşlama örüntüleri	Sürekli
8	AKZD	Anormal kısa vadeli değişkenliğe sahip zaman yüzdesi	Ayrık
9	KZD	Kısa vadeli değişkenliğin ortalama değeri	Sürekli
10	AUDD	Anormal uzun vadeli değişkenliğe sahip zaman yüzdesi	Sürekli
11	OUIDD	Uzun vadeli değişkenliğin ortalaması	Ayrık
12	HG	Histogram genişliği	Ayrık
13	MIN	Histogramın düşük frekansı	Ayrık
14	MAK	Histogramın yüksek frekansı	Ayrık
15	NMAK	Histogram tepeleri sayısı	Ayrık
16	NSIFIR	Histogram sıfır sayıları	Ayrık
17	MOD	Histogram modu	Ayrık
18	ORT	Histogram ortalaması	Ayrık
19	MED	Histogram medyanı	Ayrık
20	VAR	Histogram varyansı	Ayrık
21	EĞL	Histogram eğilimi	Kategorik

Çizelge 3.1’de UCI-KTG veri setini oluşturan özellikler tanımlanmıştır. Veriler fetüsün içinde bulunduğu durumu göstermek üzere 3 farklı sınıf ya da FKH örüntüsüne göre 10 farklı sınıfa ayrılacak şekilde etiketlenmiştir.

### 3.1.2. CTU-UHB Veri Tabanı

KTG 1960’lı yılların sonlarından günümüze kliniksel olarak rutin bir şekilde kullanılmasına rağmen, açık erişilebilir KTG veri tabanlarının dağıtımı pek yaygın değildir. Bir istisna olarak, CTU-UHB isimli veri tabanı 552 ham KTG kaydından oluşmaktadır [123]. Kayıtlar, 2010 Nisan ve 2012 Ağustos tarih aralığında Brno Üniversite Hastanesinde (Çek Cumhuriyeti) toplanmıştır. EFM cihazı ile elde edilen

kayıtlar OB TraceVue® sistemi üzerinde çevrimiçi olarak saklanmıştır. Veri tabanını oluşturan kayıtların büyük çoğunluğu 90 dakika uzunluğundadır.



Şekil 3.1 CTU-UHB kayıtlarının etiketlenmesi

Veri tabanını oluşturan her bir kayıt, Şekil 3.1’de gösterildiği gibi, dört parçaya ayrılarak sistematik bir şekilde 9 farklı uzman tarafından değerlendirilmiştir. Kayıtların birinci ve ikinci parçası doğumun birinci aşamasını (aktif itmenin öncesindeki süreci) temsil ederken, üçüncü parçası doğumun ikinci aşamasını (aktif itmenin başladığı süreci) temsil etmektedir. Dördüncü parça ise doğum sonuçlarından elde edilen ölçümlere göre uzmanların görüşlerini içermektedir. İlk üç parça, dokuz uzman tarafından -1, 1, 2 ve 3 olarak etiketlenmiştir. Burada -1 yorumlanamayan, 1 normal, 2 şüpheli ve 3 patolojik örüntü türünü temsil etmektedir. Dördüncü aşamada, -1 yorumlanamayan, 1 hipoksi olmayan durumu, 2 hafif hipoksi durumunu ve 3 şiddetli hipoksi durumunu temsil etmek için kullanılmıştır.

Çizelge 3.2 CTU-UHB veri tabanı için hasta ve doğum sonuçları ait veriler

	<b>ORT</b>	<b>MIN</b>	<b>MAK</b>
<b>Anne yaşı</b>	29,8	18	46
<b>Gebelik</b>	1,43 (1)	1	11
<b>Gebelik yaşı</b>	40	37	43
<b>pH</b>	7,23	6,85	7,47
<b>BE</b>	-6,36	-26,8	-0,2
<b>BDecf</b>	4,60	-3,40	
<b>Apgar 1</b>	8,26 (8)	1	10
<b>Apgar 5</b>	9,06(10)	4	10
<b>Yenidoğan ağırlığı</b>	3408	1970	4750

Kayıtlar toplanırken hem kliniksel açıdan önem arz eden parametreler hem de teknik açıdan işaretin işlenmesi için gerekli olan standartlar dikkate alınmıştır. Çizelge 3.2’de CTU-UHB veri tabanı için hasta ve doğum sonuçlarına ilişkin istatistiksel veriler gösterilmiştir. Dolayısıyla toplamda 14,492 adet kayıt belirlenen kliniksel ve teknik kriterlere bağlı olarak değerlendirilip neticede 552 KTG kaydı seçilmiştir. Veri tabanı Physionet altında açık erişimli olarak araştırmacıların istifadesine sunulmuş durumdadır. Veri tabanı hakkında daha fazla bilgi almak için [123] incelenebilir.

### 3.2. Önişleme

Bu tez çalışmasında, FKH işaretlerinin daha çok harici olarak bir Doppler ultrason ile kayıt edildiği vurgulansa da, FKH işaretleri daha önce belirtildiği gibi dahili olarak kafa derisi elektrotu ile de ölçülebilir [2]. Harici olarak kaydedilen fetal kalp atış hızı, dahili olarak kaydedilenlerden daha düşük sinyal/gürültü oranına sahiptir ancak bu iki yaklaşım arasında klinik bir fark yoktur [93].

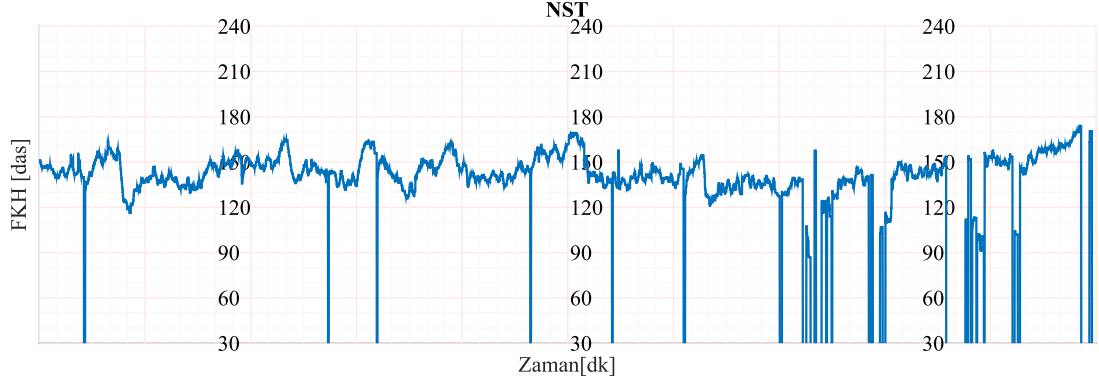
İşaretlerden çıkartılan özelliklerin değerleri ve dahası sınıflandırma, işaretin önişleme kalitesine büyük ölçüde bağlıdır. Önişleme adımları, verileri çarpıtabilir ve doğrusal olmayan yöntemlerin kullanılması uygun olmayan stokastik bileşenleri ekleyebilir [124].

Çalışmamızda, önişleme üç ana aşamadan oluşur:

- 1) Uygun bölümlerin seçilmesi
- 2) Kayıp atımların enterpolasyonu
- 3) Gürültülerden arındırma

Uygun bölümlerin seçilmesi, analizin hangi dönem için yapıldığına bağlı olarak değişmektedir. Örneğin doğum periyodu için bir analiz yapılıyorsa, doğuma mümkün olduğunca yakın örnekler üzerinde işlem yapılmalıdır, çünkü son dakika içinde fetal durumda büyük değişiklikler meydana gelebilir [34]. Doğumun birinci veya ikinci aşaması üzerinde bir analiz gerçekleştiriliyorsa, uygun olan bölümlerin analiz edilecek dönemin taşıdığı özellikler dikkate alınarak seçilmesi gerekir. Şekil 3.2’de ham bir KTG kayıt örneğine yer verilmiştir ve şekilde görüldüğü gibi kayıt pek çok istenmeyen girişim ve gürültü içermektedir.





Şekil 3.2 Ham bir FKH işaret örneği

Gerçekleştirilen analizlerde, işaretin ilgilendiği döneme bağlı olarak, 30 dakika uzunluğuna sahip bölümler seçilmiştir. İşaretler 4 Hz'lik örnekleme frekansını kullandığı için 7200 örnek üzerinde işlem yapılmıştır.

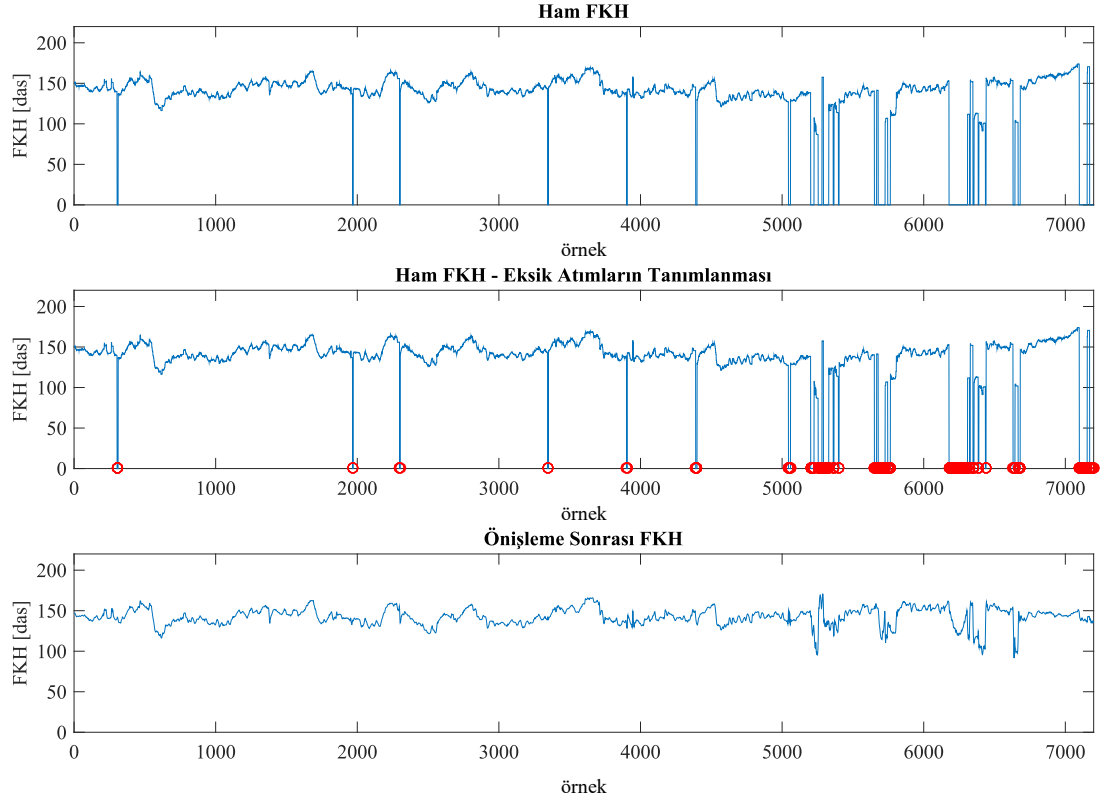
FKH işareti, anne ve cenin hareketlerinden veya dönüştürücülerin yerinden çıkartılmalarından dolayı çok sayıda girişim ve kayıp atımlar içerir. Genel olarak, gürültüler veya eksik değerler olarak değerlendirilen veri miktarı, tüm verilerin %20 ile %40'ı arasında bulunur [12].

Çalışmada, gürültü probleminin giderilmesi için Bernades [38] ve Ayres-de-Campos [120] tarafından önerilen algoritmalar dikkate alınmıştır. Aralarında dakikadaki atım sayısı 10'dan düşük bulunan ardışık beş atım, kararlı bir bölüm olarak kabul edilir. Daha sonra, bitişik atımlar arasındaki fark 25'den daha yüksek ise, ilgili bölüm, bir önceki vuruş ile yeni sabit bölüm arasında doğrusal enterpolasyon tekniğinin kullanılması ile değiştirilir. Böylece, FKH işaretindeki ani değişiklikler kaldırılır.

Eksik veriyi değiştirmek için MATLAB® tarafından sağlanan “*Kübik Hermite Spline Enterpolasyon (KHSE)*” tekniği kullanılmıştır [125]. KHSE, eşit aralıklı frekans spektrumu tahmin edildiğinde, hatalara en az yatkın olduğu için, eşit uzaklıktaki 4 Hz'lik verinin yeniden sentezlenmesinde kullanılmıştır [87]. Enterpolasyon doğrusal olmama durumunu ortaya çıkarır; ancak doğrusal olmama miktarı normal ve patolojik veriler için sağlıklı bir analiz sağlamak üzere aynı olmalıdır.

Doğrusal olmayan yöntemlerin kullanımı için sinyallerin ilginç eğilimlerinin, ikinci mertebe polinomu kullanılarak, işaretin taşıdığı dinamikler korunacak şekilde,

ortadan kaldırılması sağlanmıştır. Ayrıca sinyaller, sıfır ortalama ve birim varyansa göre normalize edilmiştir. Şekil 3.3’de önişleme öncesi ve sonrası örnek bir FKH işaretine yer verilmiştir.



Şekil 3.3 Önişleme öncesi ve sonrası örnek bir FKH işareti

### 3.3. Morfolojik Özellikler

TKH, hızlanma ve yavaşlama örüntülerinin sayısı ile değişkenlik temel morfolojik özellikler olarak tanımlanırlar. Morfolojik özellikler, özellikle kliniksel olarak fetal durumunun iyi olup olmadığını anlamak üzere temel göstergeler olarak kullanılırlar [18]. Hızlanma örüntüleri ve değişkenlik parasempatik sinir sisteminin gelişmişliğini gösterir ve fetüsün aktif olduğuna dair sağlam göstergeler olarak kabul edilirler [14]. Aksine, yavaşlama örüntüleri ise FKH'nin geçici olarak yavaşlaması anlamına gelir ve kordon sıkışması gibi çeşitli nedenlere bağlı olarak fetüsün strese olduğunu gösterir [7].

#### 3.3.1. Temel Kalp Hızı

TKH tahmini KTG işaretlerinin hem nümerik hem de görsel analizinde önem arz eden temel göstergelerden biridir; ancak taban çizgisi gerçekte hayali bir çizgidir [126]. Buna rağmen, TKH'nin nihai olarak tekrarlanabilir şekilde belirlenmesi,

objektif bir yorumun yapılabilmesi açısından son derece önemlidir [36]. FIGO TKH'yi "en yatay ve en az FKH salınımının ortalaması" şeklinde ifade etmektedir. Bir başka ifadeyle TKH, fetüsün dinlenme durumunda olduğu, hızlanma ve yavaşlama örüntülerinin olmadığı zamandaki ortalama kalp hızı olarak ifade edilir. TKH 10 dakikalık zaman periyotları şeklinde tahmin edilir ve das ile ifade edilir.

Stabil olmayan FKH örneklerinde, daha önceki kesitlerin değerlendirilmesi ve daha uzun zaman sürelerinin dikkate alınması gerekebilir [127]. Bu durum özellikle doğumun ikinci aşamasında, yüksek TKH tahminlerine neden olabilecek aktif uyanıklık durumunu tanımlamak için gerekli olabilir [128].

### **3.3.1.1. Normal Kalp Hızı Aralığı**

Pre-term fetüslerde (gebeliğin başlangıç dönemleri) TKH aralığının üst ucuna doğru; post-term fetüsler (gebeliğin son dönemleri) ise alt uca doğru değerler taşırlar. Bazı uzmanlar, terimdeki normal başlangıç değerlerinin 110 ile 150 das arasında olduğunu düşünmektedir [18].

### **3.3.1.2. Taşikardi**

TKH değerinin, 10 dakika veya daha uzun bir süre dakikada 160 atımın üzerine çıkma durumu olarak tanımlanır. Fetal taşikardinin en sık sebebi annenin ateşlenmesidir. Taşikardi rahmi içi veya dışı enfeksiyonla da ilişkilendirilir [4].

Epidural analjezi annenin sıcaklığının artmasına ve fetal taşikardiye neden olabilir. Akut olmayan bir fetal hipokseminin başlangıç safhalarında, katekolamin salınımı taşikardi de ortaya çıkarabilir [129].


### **3.3.1.3. Bradikardi**

TKH değerinin, 10 dakika veya daha uzun bir süre dakikada 110 atımın altında kalma durumu olarak tanımlanır. 100 ve 110 arasındaki TKH değerleri genellikle şüpheli olarak görülür; ancak normal fetüslerde, özellikle geç gebeliklerde ortaya çıkabilir [20]. Anne hipotermi, beta blokelerin uygulanması ve atriyoventriküler blok gibi fetal aritmiler diğer muhtemel bradikardi nedenlerdir [5].

## **3.3.2. Temel Kalp Hızı Tahmin Algoritması**

TKH tahmini yapılırken, hızlanma ve yavaşlama örüntülerinin olmadığı ve fetüsün genellikle dinleme döneminde bulunduğu periyotta [18], bahsi geçen örüntülerin göz

ardı edilerek, en geniş yatay ve en az dikey salınımın ortalamasının alınması hedeflenir [85]. Bu bağlamda, Şekil 3.4’de gösterilen algoritmadaki işlem adımları izlenerek TKH tahmini yapılır.



Şekil 3.4 TKH tahmin algoritması

FKH işareti önışleme adımından geçtikten sonra işaret analiz edilmeye hazır hale gelir. Bu kapsamda, bir FKH serisi  $x(n)$  ile gösterilmek ve  $n = 1, 2, \dots, N$  olarak tanımlanmak üzere, FKH işaretinin, ortalaması sanal TKH ( $\bar{x}$ ) olarak kabul edilir ve (3.1)’e göre hesaplanır. Daha sonra sırasıyla, standart sapma ( $\mu$ ), hata payı ( $m$ ), güven aralığı ( $GA$ ) ve standart hata ( $SH$ ) hesaplanır [130].

$$\mu = \frac{1}{N} \sum_{i=1}^N x(i) \quad (3.1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x(i) - \mu)^2} \quad (3.2)$$

$$m = 1,96 \frac{\sigma}{\sqrt{N}} \quad (3.3)$$

$$GA = \mu \pm m \quad (3.4)$$

$$SH = \frac{\sigma}{\sqrt{N}} \quad (3.5)$$

Denklem (3.1) ve (3.5) arasındaki istatistiksel işlemler, gerçek TKH hesaplaması için alt ( $a$ ) ve üst ( $u$ ) limitlerin belirlenmesi amacıyla gerçekleştirilir. Bu ifadelere bağlı olarak, gerçek TKH (3.6)'ya göre hesaplanır.

$$TKH = \frac{1}{n} \left[ \int_a^u x dx \right] \quad (3.6)$$

Burada,  $n$  FKH serisinin sahip olduğu örnek sayısını,  $x$  FKH'nin kendisini,  $u$  belirlenen en üst sınırı ve  $a$  ise belirlenen alt sınırı temsil etmektedir. Sırasıyla üst ve alt sınırlar (3.7) ve (3.8) göre hesaplanır.

$$u = TKH + (\sigma + SH) \quad (3.7)$$

$$a = TKH - (\sigma + SH) \quad (3.8)$$

Üst ve alt sınırlar belirlendikten sonra (3.6)'ya göre TKH tahmini yapılır. Hesaplama yapılırken alt ve üst sınırlar arasında kalan değerler işleme alınırken, sınırların dışında kalan atımlar dikkate alınmaz. Şekil 3.5'de şeklin üst kısmında (a) önişleme sürecinden geçirilmiş örnek bir KTG kaydı görülmektedir. Şeklin alt kısmında ise TKH tahmini yapıldıktan sonraki durum (b) görselleştirilmiştir. Şekildeki yeşil noktalar alt ve üst sınır arasında kalan ve işleme alınan FKH değerlerini temsil ederken, gri noktalar ihmal edilen, bir başka ifadeyle sınır dışında kalan noktaları göstermektedir. Kesikli mavi çizgiler ise alt ve üst sınırları temsil etmek üzere çizdirilmiştir. Şekilde ortalama TKH eğrisi ise sürekli siyah çizgi ile gösterilmiştir.

### 3.3.3. Hızlanma Örüntülerinin Tespit Edilmesi

Hızlanma örüntüsü, FKH'nin geçici olarak en az dakikada 15 atım TKH'nin üzerine çıkması ve bu örüntünün en az 15 saniye süreyle devam etmesi ve 10 dakikadan daha fazla sürmemesi şeklinde tanımlanır [18].

Hızlanma örüntülerinin çoğu fetal hareketler ile beraber görülür ve asidoz ya da hipoksiye sahip olmayan, yani nörolojik olarak cevap veren fetüslere işaret eder. Gebelik yaşının 32 haftanın altında olduğu durumlarda 10 saniyenin ve TKH'ye göre dakikada 10 atım genliğinin altında olabilir. Hızlanma örüntüleri, 32. – 34. haftalardan


sonra, fetal davranışsal durumların kurulması ile 50 dakikaya kadar sürebilir derin uyku periyotları boyunca nadiren gözlemlenir [37]. Hızlanma örüntüleri, rahim kasılmaları ile çakışır, bu çakışma özellikle doğumun ikinci aşamasında gerçekleşir. Doğum sırasında annenin kalp atımı hızlanırken, fetüsün kalp atım hızı rahim kasılmalarından dolayı sıklıkla yavaşlar [131].



Şekil 3.5 (a) Örnek bir FKH işareti, (b) FKH için TKH tahmini

Yukarıda ifadelerden anlaşılacağı üzere, hızlanma örüntülerinin tespit edilmesi için işaretin önişleme sürecinden geçirilmiş olması gerekir. Ayrıca, TKH tahminin yapılması ve TKH eğrisinin elde edilmesi ön şartlar arasındadır.


Buna göre hızlanma örüntülerinin tespiti için Şekil 3.6'da belirtilen prosedürler takip edilir.



Şekil 3.6 Hızlanma örüntülerinin tahmini için akış şeması

FKH işareti durağan olmayan bir işarettir. Durağan olmayan işaretlerin istatistiksel özellikleri zamanla değişebilir ve bu işaretlerin stabil bir deseni yoktur [132]. Bu nedenle FKH işareti zaman zaman TKH eğrisinin altına inip; zaman zaman TKH eğrisinin üstüne çıkabilmektedir. Bu değişimin olduğu her bir bölüm geçiş değişikliği olarak ifade edilmiştir. Geliştirilen algoritma, öncelikle bu geçiş değişikliği noktalarını yakalayıp bir örüntü matrisi oluşturur. Örüntü matrisi, her bir geçişin başlangıç

değeri, bitiş değeri, süresi ve TKH'ye göre maksimum genlik değerini vermektedir. Tüm örüntüler elde edildikten sonra, hızlanma örüntüsü şartlarını sağlayan örüntüler örüntü matrisinden seçilir, bir başka ifadeyle hızlanma örüntüsünün karakteristik özelliğini taşımayan, yani zamanda en az 15 saniye sürmeyen ve genlikte en az TKH'ye göre dakikada 15 atımın üzerine çıkmayan, örüntüler örüntü matrisinden elemine edilir. Şekil 3.7'de hızlanma örüntüsü algoritmasının örnek bir kayıt üzerinde çalışması sonucu elde edilen ekran gösterilmektedir. Şekilde, FKH mavi, TKH eğrisi siyah ve hızlanma örüntüleri turuncu renk ile temsil edilmiştir.



Şekil 3.7 Hızlanma örüntülerinin tespit edilmesi

### 3.3.4. Yavaşlama Örüntülerinin Tespit Edilmesi

FIGO'ya göre yavaşlama örüntüleri, FKH'nin taban çizgisinin altında, genlikte dakikada 15 atım azalma ve zamanda 15 saniyeden uzun süren örüntüler olarak ifade edilir [18]. Taşıdığı karakteristik özelliklere göre yavaşlama örüntüleri; erken, değişken, geç ve uzatılmış yavaşlama örüntüleri olarak sınıflandırılmaktadır.

#### 3.3.4.1. Erken Yavaşlama Örüntüleri

Erken yavaşlama örüntüleri, yavaşlama örüntüleri içinde normal değişkenlik ile sığ, kısa süren ve kasılmalarla beraber görülen yavaşlama örüntüleri olarak ifade edilir. Bu örüntülerin, fetüs başının sıkışmasından kaynaklandığı düşünülür ve fetal hipoksi ya da asidoz göstermezler [54].

#### 3.3.4.2. Değişken Yavaşlama Örüntüleri

Literatürde değişken yavaşlama örüntüleri, "V-şekilli" yavaşlama örüntüleri olarak da ifade edilmektedir. Hızlı düşüş gösteren, bir başka ifadeyle 30 saniyeden daha az bir sürede ortaya çıkan yavaşlamalar, yavaşlama içinde iyi değişkenlik, hızlı



toparlanma, deęişen boyut nitelikleri gösterirler ve genellikle rahim kasılmalarıyla ilişkilendirilirler. Deęişken yavaşlama örüntüleri, doğum sırasında yavaşlama örüntülerinin çoğunluęunu oluştururlar. U-şekilli bir bileşen sergilemedikçe, deęişkenlięi azaltmadıkça ve bireysel süreleri 3 dakikayı aşmadıkça, önemli derecede fetal hipoksi ya da asidoz ile ilişkilendirilmezler [133].

#### **3.3.4.3. Geç Yavaşlama Örüntüleri**


Geç yavaşlama örüntülerinin temel karakteristikleri “*U-şekilli*” olmaları ve deęişkenlikteki azalmadır. Yavaşlama kademeli olarak başlar ve yavaşlamanın eni, başlangıç ve bitişi arasında 30 saniyeden daha uzun bir süre TKH’ye geri dönülürken ortaya çıkar. Kasılmalar yeterince izlendiğinde, geç yavaşlama örüntülerinin kasılmanın başlamasından sonra, 20 saniyeden daha uzun bir süre, başladığı görülür. Bu yavaşlama türü fetal hipoksemiye kemoreseptör aracılı bir yanıtın göstergesi olarak kabul edilir [133]. Bir FKH şeridinde, hızlanma örüntüleri yok ise deęişkenlięi azalmış bir kayıt için, geç yavaşlamaların tanımı aynı zamanda dakikada 10 – 15 atımlık genlikleri de kapsamaktadır.

#### **3.3.4.4. Uzatılmış Yavaşlama Örüntüleri**

Uzatılmış yavaşlama örüntüleri 3 dakikadan daha fazla sürmektedir. Bu örüntü türünün, büyük olasılıkla bir kemoreseptör aracılı bileşen içermesi ve böylece hipoksemi göstermesi olasıdır [18]. FKH’nin dakikada 80 atımdan daha düşük tutulduğu ve yavaşlamada deęişkenlięin azaldığı, 5 dakikayı aşan yavaşlamalar sıklıkla akut fetal hipoksi ya da asidoz ile ilişkilidir ve acil müdahale gerektiren bir durumdur.

Yavaşlama örüntüleri, bu tez çalışmasında tespit edilmiş ancak türlerine göre kategorize edilmemiştir. Bu kapsamda, yavaşlama örüntülerinin tespit edilmesini sağlamak üzere FIGO tarafından yapılan tanım ve kabullere göre bir algoritma geliştirilmiştir. Hızlanma ve yavaşlama örüntülerinin tespiti birbirine son derece yakındır. Bu örüntülerin tespit edilmesi için gerekli olan temel şart, TKH eğrisinin ve örüntü matrisinin doğru bir şekilde oluşturulmasıdır. Bu bağlamda, Şekil 3.6’da gösterilen akış şeması takip edilerek, hızlanma örüntülerinin tespiti için izlenen yol izlenmiş, farklı olarak sadece ilgisiz örüntülerin kaldırılması noktasında yavaşlama örüntüleri için FIGO tarafından belirlenen kriterler göz önüne alınmıştır.

Şekil 3.8’de yavaşlama örüntülerinin tespit edilmesi sonucunda elde edilen grafik gösterilmiştir. Grafikte FKH işareti mavi, yavaşlama örüntüleri yeşil, TKH eğrisi siyah çizgi ile gösterilmiştir.



Şekil 3.8 Yavaşlama örüntülerinin tespit edilmesi

### 3.3.5. Değişkenlik

Değişkenlik, işaretin 1 dakikalık bölümlerdeki ortalama bant genişlik genliği (genlikteki bant aralığı) olarak FKH işaretindeki salınımları ifade eder.

Normal değişkenlik değerinin dakikada 5 – 25 atım arasında olması gerektiği belirtilmiştir.

Azalan değişkenlik, genlik aralığının, TKH seviyesinde 50 dakikadan uzun bir süre dakikada 5 atımın altına düşmesi olarak ifade edilir. Azalan değişkenlik merkezi sinir sisteminin hipoksi ya da asidoz durumunda olmasından dolayı meydana gelebilir ve sempatik ve parasempatik sinir sisteminin yavaşlaması ile sonuçlanabilir [18].

Genlikteki bant genişliği, 30 dakikadan daha uzun süre dakikada 25 atımın üstündeyse ise bu durum artan değişkenlik olarak ifade edilir. Bu örüntünün patofizyolojisi henüz tam olarak açıklanamamıştır, ancak bu durumun fetal otonomik istikrarsızlık/hiperaktivite otonom sistemden kaynaklandığı düşünülmektedir [134].

### 3.4. Doğrusal Özellikler

FKH’nin doğrusal özellikleri, işaretlerin her birinin karakterize edilmesini sağlamak üzere pek çok çalışmada geleneksel olarak kullanılmaktadır [68]. Doğrusal özellikler zaman alanından elde edilir ve FKHD’nin analizi için faydalı modellerdir.

Sırasıyla (3.1) ve (3.2)’de FKH’nin ortalaması ve standart sapmasının nasıl hesaplandığı daha önce ifade edilmiştir. Bu özelliklere ek olarak, bir FKH serisi  $x(n)$

ile gösterilmek üzere ve  $x(n)$  için  $n = 1, \dots, N$  olarak tanımlandığında  $UDD$ , delta ( $\Delta$ ),  $KZD$  ve  $AE$  aşağıdaki belirtilen matematiksel formlarla hesaplanabilir.

$$UDD = A \left( \sqrt{x^2(i) + x^2(i+1)} \right) \quad (3.9)$$

$$\Delta = \frac{1}{D} \sum_{i=1}^D \left[ \max_{i \in D} (x(i)) - \min_{i \in D} (x(i)) \right] \quad (3.10)$$

$$KDD = \frac{1}{24D} \sum_{i=1}^{24D} |sm(i+1) - sm(i)| \quad (3.11)$$

$$AE = \frac{KDD}{\sigma(sm(i))} \quad (3.12)$$

Burada,  $A$  fonksiyonu çeyrekler arası aralığı temsil etmektedir ( $i = 1, \dots, N - 1$ ) ve  $D$  FKH serisinin sahip olduğu toplam dakika sayısını gösterir.  $sm(i)$ ,  $x(i)$ 'nin 2,5 saniyelik periyodunu içerir ve bir başka ifadeyle örnekleme frekansı 4 Hz olan FKH işaretinin 2,5 saniyelik periyodu 10 örnekten oluşur ve bu 10 örneğin ortalaması  $x(i)$ 'ye karşılık  $sm(i)$ 'yi oluşturur.  $\sigma$ , standart sapmayı temsil etmek üzere kullanılmıştır.

### 3.5. Doğrusal Olmayan Özellikler

Zaman serilerinin doğrusal olmayan dinamiklerini belirlemek için kaotik, yani doğrusal olmayan analiz yöntemleri EKG, KTG, elektroensefalografi (EEG), KHD, solunum ve uyku gibi pek çok biyofiziksel işaret üzerinde hali hazırda kullanılmış durumdadır [135]. Entropi endeksleri ile karmaşık kortikal sinir sistemi aktivitesi birçok çalışmada ilişkilendirilmiştir [68]. Doğrusal olmayan dinamiklerin hesaplanmasına işaretin uzunluğu, girişimler, boyut sayısı ve zaman gecikmesi gibi parametreler etki etse de [136], özellikle makine öğrenmesinde işaretleri tanımlamak üzere kaotik endekslerin kullanılmasının, sınıflandırma doğruluğunu arttırdığı çeşitli çalışmalarda rapor edilmiştir [55], [76].

Doğrusal olmayan yaklaşım, FKH işaretine dair geleneksel zaman serisi analizinde ortaya çıkartılamayan klinik bilgileri açığa çıkarabilir. Bu kapsamda, fraktal boyut, entropi tahmin edicileri ve karmaşıklık ölçütleri hali hazırda kullanılmaktadır [93]. Doğrusal olmayan yaklaşımlarla, FKH işaretleri analiz edildiğinde başlıca iki

temel husus dikkate alınmalıdır. Birincisi, FKH işaretleri, özellikle harici bir ultrason elektrotu ile toplandığında, harekete ve ölçüm ekipmanlarına bağlı stokastik bileşenler içerir. Bu durum, FKH işaretinin doğasının bozulmasına neden olabilir. İkincisi, doğrusal olmayan yöntemlerin güvenilir değerler üretmesi için kesin bir veri uzunluğuna ihtiyaç duymasındır. Her yöntem için gerekli veri uzunluğu farklılık gösterebilmektedir [137].

Nihai olarak, doğrusal olmayan analiz alanından, yaklaşım entropi (*YaEn*), örnek entropi (*ÖrnEn*) ve Lempel Ziv Karmaşıklığı (*LZK*) incelenmiştir.

### 3.5.1. Yaklaşım Entropi

Entropi, bir sistemin davranışını rastgelelik açısından tanımlar ve altındaki dinamiklerle ilgili bilgileri nicelleştirir [138]. Yaklaşım entropi (*YaEn*), istatistiksel endekslerden oluşan bir ailedir ve doğrudan işaret tahmini ile elde edilen doğrusal olmayan bir ölçüttür [55]. *YaEn* bir işaretin düzensizliğini ve eninde sonunda korelasyonunu ve kalıcılığını ölçer. Bir başka ifadeyle, *YaEn* düşük boyutlu deterministik sistemi, kaotik sistemi, stokastik ve karışık sistemleri ayırt edebilmektedir [139].

Birçok yinelenen ya da tekrarlanan desen içeren bir zaman serisinin nispeten küçük bir *YaEn* değerine; daha az öngörülebilir bir süreci ifade eden bir serinin ise daha yüksek ise bir *YaEn* değerine sahip olması beklenir.

*YaEn* hesaplanırken,  $x_n$  ile temsil edilen bir zaman serisi, bir dizi  $m$  uzunluğunda vektörlere,  $u_m(i)$ , bölünür. Daha sonra,  $u_m(i)$  ve  $u_m(j)$  vektörlerinin sayısı Öklit bağlamında,  $d[u_m(i), u_m(j)] \leq r$ ,  $n_i^m(r)$  sayısı ile açıklanır. Bu sayı, vektörlerin göreceli olarak, (3.13)'de belirtilen şekilde yakınlık ihtimalini hesaplamak için kullanılır.

$$C_i^m(r) = \frac{n_i^m}{(N - m + 1)} \quad (3.13)$$

İşlev (3.14)'de gibi genişletilir.

$$\Phi^m(r) = \frac{1}{(N - m + 1)} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (3.14)$$

Sonuç olarak  $YaEn$  aşağıdaki gibi tanımlanır.

$$YaEn(m, r) = \lim_{N \rightarrow \infty} [\Phi^m(r) - \Phi^{m+1}(r)] \quad (3.15)$$

$$\begin{aligned} YaEn(m, r) &= \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} \ln(C_r^m(i)) \\ &\quad - \frac{1}{N - m} \sum_{i=1}^{N-m} \ln(C_r^{m+1}(i)) \\ &= \text{ortalama}_i \left[ \ln \frac{C_r^{m+1}(i)}{C_r^m(i)} \right] \end{aligned} \quad (3.16)$$

Burada  $r$  tolerans değerini, yani filtreleme seviyesini ya da bir başka ifadeyle sinyal çıktılarıyla alakalı tolerans düzeyini gösterir. İki vektör arasındaki farklar  $r$  değerinden küçük olmalıdır.  $m$  ise gömülü boyutu, yani karşılaştırılan vektörlerin uzunluğunu tanımlar.  $m$  değeri arttırıldıkça işaret analizi için detay derecesi de artar. Genellikle standart olarak  $r(0,10; 0,15; 0,20)$  ve  $m = 2$  olarak kullanılmaktadır [82].  $YaEn$  genellikle uzunluğu,  $N > 100$  olan bir veri serisi için uygulanabilir [139]. Bununla birlikte, bu geniş bir uygulama yelpazesi için önerilmiştir ve gürültüyle bozulmuş zaman serilerine karşı sağlam sonuçlar üretebilmektedir.  $m = 1, 2$  iken  $r$  giriş sinyalinin standart sapmasının 0,1 ve 0,25 katı arasında ( $r(0,10; 0,15; 0,20)$ ) kullanılması  $YaEn(m, r, N)$  için hem kliniksel uygulama hem de teorik hesaplama için iyi bir istatistiksel geçerlilik sağlamaktadır [140].

### 3.5.2. Örnek Entropi

Örnek entropi ( $ÖrnEn$ ), yaklaşım entropinin biraz daha güçlü bir versiyonu olarak kabul edilir [141].  $ÖrnEn$ , sinyal karmaşıklığını (veya düzensizliği) kısa kesimlerle, sağlam bir şekilde ölçebilen doğrudan sinyal tahmini ile elde edilen ve doğrusal olmayan bir yaklaşımdır [135]. Bu tahmin edici,  $YaEn$ 'e kıyasla önyargıya sebep olan öz-eşleşmeleri elemine edebildiğinden  $YaEn$ 'nin eksikliklerini giderir [68]. Şartlı

olasılıklar, şablon tabanlı bir yaklaşımla tahmin edilmez.  $\text{ÖrnEn}$  yalnızca bir şablonun  $m + 1$  uzunluğunda bir eşleşme bulmasını ister ve (3.17)'deki gibi hesaplanır.

$$\text{ÖrnEn}(m, r) = \lim_{N \rightarrow \infty} -\ln \frac{C^{m+1}(r)}{C^m(r)} \quad (3.17)$$

$m$  ve  $r$  parametresi  $\text{YaEn}$  ile aynıdır. Ayrıca, veri gereksinimleri de benzerdir.

### 3.5.3. Lempel Ziv Karmaşıklığı

Lempel Ziv karmaşıklığı ( $LZK$ ), zaman serisinde zamana bakmaksızın, yinelenen kalıpları duyarlı bir şekilde tahmin eder [142].

$LZK$  hesaplanırken öncelikle diziyi oluşturan semboller kümesi olan bir alfabe ( $A=\{0,1\}$ ) tanımı yapılır. FKH analizi için geliştirilen algorithmada alfabe, 0 ve 1'leri içeren ikili dizgelerden oluşturulmuştur.  $x$  bir FKH serisini temsil etmek üzere  $x(1), x(2), \dots, x(n)$  olarak tanımlanmış bir seri,  $x(i+1) > x(i)$  olduğu durumlarda 1 ve  $x(i+1) \leq x(i)$  olduğu durumlarda 0 ile yeni sonlu-uzunluğa sahip bir  $S$  dizisi oluşturmak için kodlanır.  $S$ 'nin her bir elemanı,  $S = s_1, s_2, \dots, s_n$  olarak tanımlanır ve  $\forall s_i \in A$  şartını sağlar.  $S$  dizinin sözcük dağılımı  $v(S)$  ile tanımlanır ve  $S$ 'nin tüm alt dizgilerinin kümesini kapsar. Örneğin  $S = 101$  olarak tanımlandığında  $v(S) = \{1,0,10,01,101\}$  olarak tanımlanır.

Alfabe tanımı yapılarak,  $S$  dizisi oluşturulduktan sonra algoritma,  $S$ 'deki farklı desenleri sayar ve her yeni desen için  $c(n)$  karmaşıklığı 1 artırılır. Geleneksel olarak  $S$ 'nin son elemanına erişildiğinde,  $c(n)$  karmaşası yine 1 artırılır.  $c(n)$  orijinal dizinin uzunluğunu temsil eden  $n$  değerine bağlıdır. Veri noktalarının sayısına bağlı olan bu bağımlılığı önlemek için normalleştirme formu kullanılmaktadır [93]. Normalizasyon formu (3.18)'de belirtildiği gibi uygulanır.

$$C(n) = c(n) \frac{\log_2(n)}{n} \quad (3.18)$$

İkili kodlama, sonuçların ölçüm kriterleri ve normalizasyon prosedürleri üzerindeki bağımlılığını engellemek için kullanılır. İkili kodlanmış veriler için gerekli veri uzunluğu 1000 örnek olarak belirtilmiştir [143].

### 3.6. Zaman-Frekans Özellikleri

#### 3.6.1. Zaman-Frekans Analizi

Bir biyofiziksel işaretin gösterimi için başlıca belirteçlerden biri olan “*zaman*”, işaretin doğasını anlamada oldukça faydalıdır. Zamana ilaveten “*frekans*” en önemli niceliklerden birini temsil etmektedir. Zaman-frekans analizinin temel amacı, zaman ve frekans ekseninde işaretin analiz edilebilmesi için iyi bir çözünürlükle birlikte, işareti oluşturan frekans bileşenlerinin dağılımını gösteren bir spektrum elde edebilmektir [132]. Zaman-frekans analiz yöntemleri, doğrusal frekans dağılımları (Fourier dönüşümü, dalgacık dönüşümü) ve karesel frekans dağılımları (spektrogram, skalogram, Wigner dağılımı, Cohen sınıfı zaman-frekans dağılımları) olarak başlıca iki grup altında incelenmektedir.

#### 3.6.2. Kısa Zamanlı Fourier Dönüşümü ve Spektrogram

Fourier dönüşümü, farklı genlik ve frekanslardan oluşan işaretlerin doğrusal bileşenler ile ifade edilmesini sağlayan bir tekniktir. Genel olarak, salınım ve titreşim hareketleri gibi periyodik olayları incelemek üzere kullanılmaktadır. Fourier analizi, işareti oluşturan frekans bileşenlerini verebilmesine rağmen, frekans dağılımını oluşturan bileşenlerin hangi  $t$  anında ortaya çıktığı bilgisi verememektedir [144]. Bu nedenle durağan olmayan işaret, zaman ekseninde kayan küçük pencerelere bölünüp, bir başka ifadeyle küçük durağan parçalara bölünüp, her bir pencerenin Fourier analizi ayrı ayrı hesaplanır ve parçaların bir araya getirilmesi, işaretin zaman içinde frekans dağılımının nasıl gerçekleştiği bilgisini vermektedir [145]. Bu yöntem, KZFD olarak ifade edilir ve matematiksel olarak (3.19)’daki gibi modellenir.

$$X(n, \omega) = \sum_{m=-\infty}^{\infty} x[m]w[n-m]e^{-j\omega n} \quad (3.19)$$

Burada,  $x[m]w[n-m]$  giriş sinyalini temsil eden  $x[m]$ ’in  $n$  anında seçilen parçasını ifade etmektedir. Benzer şekilde, KZFD (3.20)’deki gibi de tanımlanabilir.


$$X(n, k) = X(n, \omega)|_{\omega=\frac{2\pi}{N}k} \quad (3.20)$$

KZFD aynı zamanda işaretin zaman-frekans bilgisini görsel olarak veren spektrogramların elde edilmesine de imkan vermektedir. Spektrogram log ölçeğinde

ayrık kısa zamanlı dönüşüm büyüklüğünün görsel sunumu olarak da tanımlanabilir ve (3.21)'de gösterildiği gibi hesaplanır.

$$S(n, k) = \log|X(n, k)|^2 \quad (3.21)$$

Şekil 3.9'da normal ve hipoksik FKH örnekleri hemen altlarında ise KZFD yardımıyla elde edilmiş spektrogramları gösterilmiştir. Spektrogram grafiklerinden anlaşılacağı üzere işaretler [0,1] bandında normalize edilmiştir.



Şekil 3.9 (a) Normal ve (b) Hipoksik FKH işaretleri ve spektrogramları

### 3.6.3. Güç Spektrum Yoğunluğu

GSY fonksiyonu, frekansın bir fonksiyonu olarak değişimlerin (enerji) gücünü gösterir. Başka bir deyişle, hangi frekanslarda enerjinin güçlü; hangi frekanslarda enerjinin zayıf olduğu GSY ile anlaşılabilir [146]. GSY'nin birimi, frekans başına (bir frekans aralığında) enerjidir. GSY hangi frekans aralıklarının enerjisinin güçlü olduğunu bildirdiğinden, zaman serisindeki salınım işaretlerinin genliği ve frekansları bilinmek istendiğinde ve daha ileri analizler için çok kullanışlı bir araç olabilir [147].

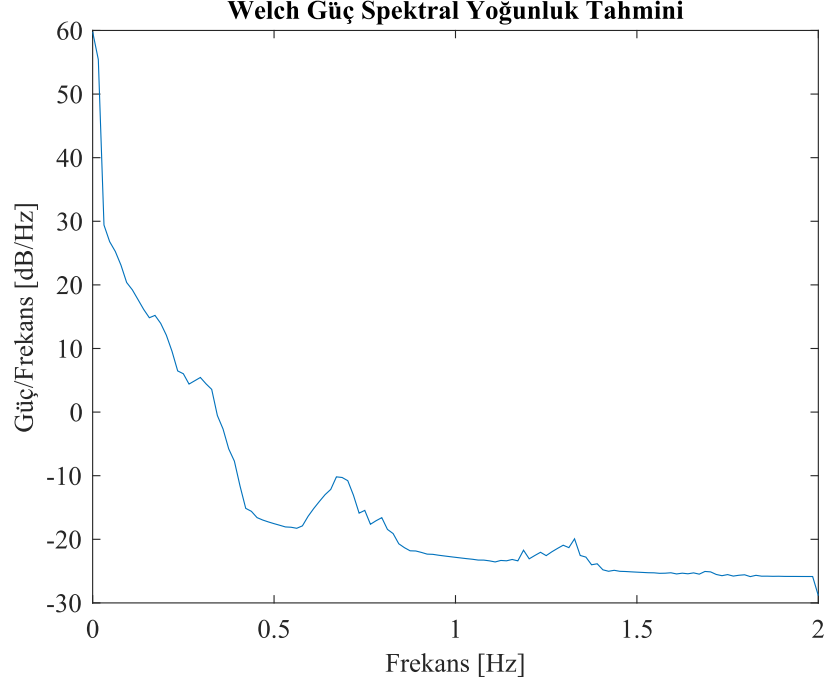


FKH'ı açısından bakıldığında GSY analizi, kalp atışlarının fizyolojik değişkenliğini kontrol eden FOSS tarafından gerçekleştirilen aktivitenin niceliksel ölçümünü sağlar [55]. Frekans alanı doğrusal yöntemleri, frekans bileşenlerinde FKH sinyalinin ayrışmasına izin verir [73]. Bu tez çalışmasında, frekans alanı doğrusal yöntemleri dikkate alınarak, non-parametrik spektral tahmin metodu olan Welch yöntemi kullanılmıştır [147]. Welch metodu, 256 uzunluğundaki Hanning pencere ve %62,5 örtüşme oranı ile uygulanmıştır.

Çizelge 3.3. Deneysel frekans aralıkları

Frekans Bantları	Aralıklar
ÇDF	0 – 0.03 Hz
DF	0.03 – 0.15 Hz
OF	0.15 – 0.50 Hz
YF	0.50 – 1 Hz

Çizelge 3.3'de FKH işareti için yaygın olarak kullanılan frekans bant genişlikleri ve bant aralıkları ifade edilmiştir. Yetişkin bir kişinin GSY'sinde gözlenenlerden farklı olarak, FKH spektrumunda dört farklı kanala odaklanılmaktadır. ÇDF (0 – 0.03 Hz) uzun periyot ve doğrusal olmayan girişimlerle alakalıdır ve termoregülasyon süreçlerini ve renin-anjiyotensin sistemi gibi periferik damarların yavaş düzenleyici sistemlerini yansıttığından yorumlanması oldukça zordur [68]. Bu bant propranolol ile azaltılabilir [38] ve sinüs kalp hızı örüntülerinde olduğu gibi otonom faaliyet güçlü bir şekilde bastırıldığında belirgin olarak görünür [148]. Düşük frekans (DF, 0.03 – 0.15 Hz) esas olarak otonom sinir sistemin bir parçası olan sinirsel sempatik aktivite ile ilişkilidir [76]. Orta frekans (OF, 0.15 – 0.50 Hz) fetal hareketlere ve anne solunumuna bağlıdır ve FKH spektrumunda tipiktir. Son olarak, yüksek frekans (YF, 0.50 – 1 Hz) fetal solunum varlığına işaret etmektedir. Kullanılan bu dört farklı frekans aralığının ötesinde, tüm spektrum alanını ifade eden toplam güç ( $TG$ ) ve  $DF/(OF + YF)$  olarak tanımlanan, ayrıca sempatik ve parasempatik sinir sistemi dengesini işaret eden SVD endeksi işaretleri tanımlamak üzere kullanılmaktadır.




Şekil 3.10 Güç spektral yoğunluk tahmini


Bu kapsamda, FKH işaretinin  $TG$ ,  $\mathcal{CDF}$ ,  $DF$ ,  $OF$  ve  $YF$  frekans aralıklarının bant gücünün ve SVD endeksinin hesaplanması sağlanabilmektedir. Şekil 3.10'da Welch GSY tahmin fonksiyonu, yukarıda ifade edilen parametrelere bağlı olarak hesaplanmış ve elde edilen grafik gösterilmiştir. Çizelge 3.3'de belirtilen frekans aralıklarının 2 ile çarpılması ilgili deneysel aralıklar için bant gücünün hesaplanabilmesini sağlamaktadır.

### 3.7. İmge Tabanlı Zaman-Frekans Özellikleri


İmge-tabanlı zaman frekans (İTZF) özellikleri KTG işaretlerini daha doğru bir şekilde tanımlamak üzere, KZFD tarafından üretilen spektral imgelerin, 8 bitlik gri-seviyeli imgelere dönüştürülüp, farklı frekans bantlarında odaklanarak, bu frekans bantlarından işareti tanımlayacak istatistiksel özelliklerin çıkartılması mantığına dayanmaktadır. Gri ölçekli spektral imgeler, analizin gerçekleştirilmesi için temel veri kaynağını oluşturmaktadır.



Şekil 3.11 Normal bir FKH işareti için spektral bant aralıkları ve gri imgeler



Şekil 3.12 Hipoksik bir FKH işareti için spektral bant aralıkları ve gri imgeler



Şekil 3.13 Normal ve hipoksik FKH işaretine ait spektrogramlar

Şekil 3.11’de normal bir FKH işaretine ait spektrogram imgeleri deneysel frekans aralıklarına bağlı olarak gösterilmiş ve hemen her spektrogram imgesinin yanına spektrograma ait gri ölçekli imge yerleştirilmiştir. Benzer şekilde, Şekil 3.12’de aynı işlem hipoksik bir FKH işareti için gerçekleştirilmiştir. Şekil 3.13’de normal ve hipoksik örnekler için FKH işaretinin spektrogram imgeleri karşılaştırılma amacıyla yine belirlenen deneysel frekans aralıklarında ayrı ayrı gösterilmiştir.

Doku tanımlayıcıları yüksek karmaşıklığa ve düzensizliğe sahip imgelerin karakteristik özelliklerinin ortaya çıkartılmasını sağlamak üzere kullanılan efektif ve değerli araçlar olarak düşünülebilir [149]. Doku tanımlayıcılar tarafından sağlanan istatistiksel özellikler, biyomedikal imge analizi, uzaktan algılama, endüstriyel yüzey taraması gibi potansiyel pek çok uygulamada kabul görmüş durumdadır [150]–[152].


İTZF analizi ile gri ölçekli spektral imgeleri birbirinden ayırmaya olanak tanıyacak, bir başka ifadeyle hipoksik FKH örneklerini, normal FKH örneklerinden ayıracak, çeşitli istatistiksel özelliklerin çıkartılması hedeflenmiştir. Bu kapsamda gri seviyeli eş oluşum matrisi (GSEM), yerel ikili desen (YİD) ve bölme esaslı fraktal doku ayrışımı (BFDA) yöntemlerinin ilk kez KTG işaretlerinin analizi için kullanılması önerilmiştir.

### 3.7.1. Gri Seviyeli Eş Oluşum Matrisi

Gri ölçekli imgelerden çeşitli istatistiksel özelliklerin çıkartılmasına imkân tanıyan GSEM, M. Haralick tarafından önerilmiştir. Temel olarak, iki komşu piksel arasındaki ilişkinin tanımlanmasını sağlamak üzere kullanılmaktadır. Bu piksellerden biri referans; diğeri ise komşu piksel olarak ifade edilir [149], [153]. GSEM gri ölçekli imgeler için, komşu pikseller arasındaki spesifik bir uzaklık ( $\delta$ ) ve açı ( $\theta$ ) olmak üzere iki parametreye bağlı olarak yönlü bir örüntü sayacı gibi düşünülebilir. Bu durum Şekil 3.14’de gösterilmiştir. Sayısal bir görünüm ile  $\delta = 1$  ve  $\theta = 0$  için GSEM (3.22)’deki gibi tanımlanır.


$$M_{\delta,\theta=0}(p, q) = \sum_{n=1}^N \sum_{m=1}^K \begin{cases} 1 & \text{Eğer } I(n, m) = p \text{ ve } I(n, m + \delta) = q \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.22)$$

Burada  $p, q = 0, 1, \dots, L - 1$ ; olarak tanımlanır ve  $L$  gri ölçekleri ifade eder.  $N$  ve  $K$  imgenin boyutlarıdır. GSEM matrisinin normalize edilmesinden sonra kontrast, enerji, korelasyon ve homojenlik gibi pek çok farklı özellik elde edilebilmektedir.



Şekil 3.14 Açısal en yakın komşular

Pikseller arası uzaklıklar ile birlikte, piksel çiftlerinin yönleri Şekil 3.14'de gösterildiği gibi genellikle  $\theta = 0, 45, 90, 135$  olarak kullanılmaktadır. Seçilen açısal değerlere ve gri seviye limitine bağlı olarak üretilen GSEM matrisinin boyutu değişkenlik gösterir.  $\delta = 1, \theta = 0$  ve gri seviye sayısı 8 olmak üzere Şekil 3.15'de  $4 \times 5$  boyutunda bir imgeden, bir eş-oluşum matrisinin elde edilmesi gösterilmiştir. Şekilde gösterildiği gibi imgedeki (1,1) çifti imge içerisinde sadece 1 defa tekrar ettiği için GSEM matrisindeki (1,1) numaralı hücreye 1 yazılmıştır. Benzer şekilde, (1,2) piksel çifti imgede 2 defa tekrar ettiği için GSEM matrisindeki (1,2) hücresine 2 değeri yazılmıştır. Neticede, bu işlem diğer piksel çiftleri içinde uygulanır ve Şekil 3.15'de gösterilen eş-oluşum matrisi elde edilir [154].



Şekil 3.15 GSEM algoritması

GSEM oluşturulduktan sonra bir takım özellikler bu matrisin normalize edilmesinden hemen sonra ortaya çıkartılabilmektedir. GSEM matrisinden genellikle doku karakteristiğini ortaya koyan kontrast, korelasyon, enerji ve homojenlik nitelikleri birer özellik olarak elde edilir.  $p(i, j)$  olasılık yoğunluk fonksiyonunu göstermek üzere, GSEM'in satır ve sütunlarına ilişkin ortalama ve standart sapma değerleri aşağıdaki gibi tanımlanmaktadır.

$$\mu_x = \sum_i \sum_j i p(i, j) \quad (3.23)$$

$$\mu_y = \sum_i \sum_j j p(i, j) \quad (3.24)$$

$$\sigma_x = \sum_{i,j} (i - \mu_x^2) p(i, j) \quad (3.25)$$

$$\sigma_y = \sum_{i,j} (j - \mu_y^2) p(i, j) \quad (3.26)$$

Kontrast tanımlayıcısı, yerel yoğunluk varyasyonlarının miktarını tanımlamak için kullanılır ve (3.27)'deki gibi tanımlanır.

$$Kontrast = \sum_{p,q} |p - q|^2 \bar{G}_{\delta,\theta}(p, q) \quad (3.27)$$

Korelasyon, imgedeki gri seviye doğrusal bağımlılıkları açıklar ve (3.28)'deki gibi tanımlanır. Burada  $\bar{G}_{\delta,\theta}(p, q)$  marjinal dağılımı göstermektedir.

$$Korelasyon = \sum_{p,q} \frac{(p - \mu_x)(q - \mu_y) \bar{G}_{\delta,\theta}(p, q)}{\sigma_x \sigma_y} \quad (3.28)$$

Enerji miktarı, görüntünün tekdüzeliğini tanımlar ve (3.29)'deki gibi tanımlanır.

$$Enerji = \sum_{p,q} ((\bar{G}_{\delta,\theta}(p, q))^2) \quad (3.29)$$

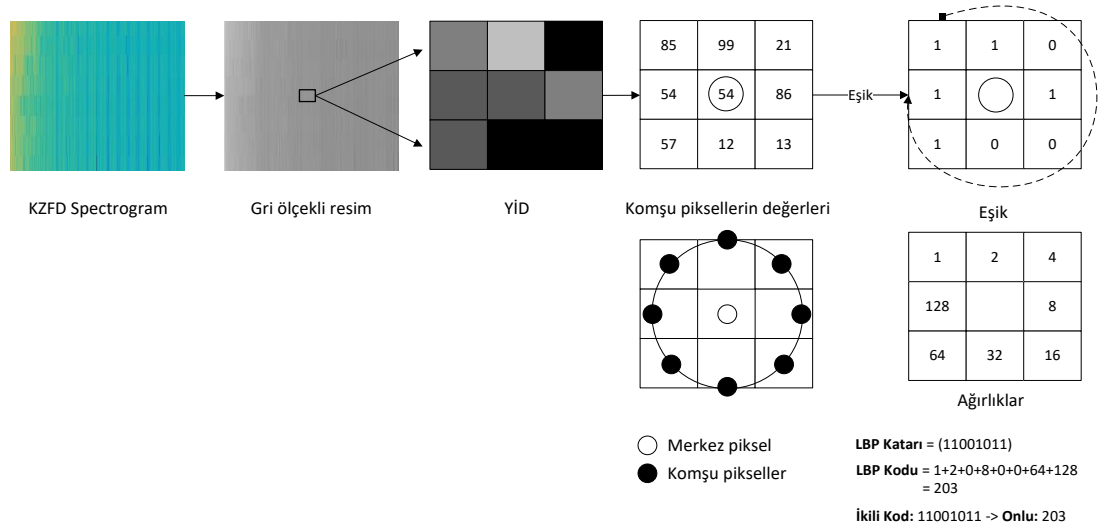
Homojenlik, eş-oluşum matrisindeki elemanların diyagonal olarak eş-oluşum matrisine dağılımının yakınlığını gösterir ve (3.30)'daki gibi tanımlanır.



$$Homojenlik = \sum_{p,q} \frac{1}{1 + |p - q|} \bar{G}_{\delta,\theta}(p, q) \quad (3.30)$$

### 3.7.2. Yerel İkili Desen

YİD doku tanımlaması için mükemmel bir araçtır ve verimliliği Ojala ve diğerleri tarafından ispatlanmıştır. YİD operatörü, Şekil 3.16'da gösterildiği gibi 3x3'lük bir komşu piksel alanı ile merkez pikseli eşikleyerek 8 bitlik ikili numaralar üretir. 8 bitlik bu numara YİD katarı olarak ifade edilir. Operatör daha sonra, farklı büyüklükteki komşuluk alanlarını tutacak şekilde bir dairesel komşuluk alanı ve ikili doğrusal enterpolasyon tekniği ile genişletilmiştir [155].



Şekil 3.16 Yerel ikili desenin hesaplanması

Önerilen notasyon böylesi bir tanımlı gerçekleştirmek için  $(P, R)$  ile tanımlanan bir komşuluk alanı tanımlamaktadır. Burada  $P$  dairedeki örnek noktaların sayısını ve  $R$  dairenin yarıçapını göstermektedir. Bu tanımlara bağlı olarak, YİD (3.31)'de belirtildiği gibi tanımlanmaktadır. Burada,  $g_c$  merkez pikselin yerini,  $g_i$  yarıçapı  $R$  ile tanımlanmış  $P$  aralıklarla eşit olarak bölünmüş  $i$ 'nci pikselin değerini göstermektedir.  $s(\cdot)$  operatörü, (3.31)'de tanımlanan şekliyle ilgili ikili desen için  $2^n$  ayrıık değerlerin sonucunu göstermektedir.

$$YID_{P,R}(x, y) = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i, s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.31)$$

### 3.7.3. Bölme Esaslı Fraktal Doku Analizi

Dokular, karakterize etme amacıyla karmaşık imgesel modellerden istatistiksel kümelerin elde edilebileceği örüntüler olarak görülebilir [152]. Doku analizi, hesaplama maliyeti yüksek olan ve özellikle gri seviyeli imgeler için semantik boşluk problemini gidermek üzere kullanılan gelişmiş metotları ifade etmektedir. Temel amaç imgeden çıkarılan özellikler ile imgelerin ayrışımını sağlayabilmektir [156]. Bu kapsamda BFDA, hesaplama maliyetlerini düşüren ve aynı zamanda verimli özellikler sağlayan bir özellik çıkarma algoritması olarak değerlendirilebilir.

BFDA'ya verilen imge, iki-eşik ikili ayrışım (İEİA) algoritması yardımıyla bir dizi ikili imgeye dönüştürülür. İEİA algoritması  $I(x, y)$  ile gösterilen bir imgeyi giriş olarak alır. İlk adımda  $T$  olarak ifade edilen bir dizi eşik değerlerini hesaplar. Eşik değer setleri, eşit aralıklı gri seviye değerleri seçilerek elde edilir. Bu noktada algoritma, eşik kümesini hesaplamak için girdi imgesinin gri seviyeli dağıtım bilgisini kullanan farklı bir strateji benimser. Çok-seviyeli Otsu algoritması giriş imgesi sınıf-ıçi varyansı en aza indiren eşiği bulur. Daha sonra Otsu algoritması, istenilen sayıda eşik sayısı ( $n_t$ ) elde edilinceye kadar her görüntü bölgesine uygulanır, burada  $n_t$  kullanıcı tarafından verilen parametredir. Bir sonraki adımda, (3.32)'ye göre bir dizi ikili imge elde edilir.

$$I_b(x, y) = \begin{cases} 1 & \text{eğer } t_l < I(x, y) \leq t_u \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.32)$$

Burada  $t_l$  ve  $t_u$  sırasıyla alt ve üst eşik değerleri göstermektedir. İkili imgeler dizisi, İEİA algoritması yardımıyla, iki-eşikli bölütlemenin giriş imgesine uygulanmasıyla elde edilir.

İEİA algoritmasının gri seviye imgeye uygulanmasından sonra, BFDA özellik seti ikili imgelerin boyutu, ortalama gri seviye ve fraktal boyutun sınırlarının sonucu olarak oluşturulur. Fraktal ölçümler girdi görüntüsünde bölünmüş cisimlerin ve yapıların sınır karmaşıklığını tanımlamak için kullanılır. Bir ikili imgenin sınır bölgeleri  $I_b(x, y)$ ,  $\Delta(x, y)$  ile gösterilen çerçeve imge ile temsil edilir ve aşağıdaki gibi hesaplanır.

$$\Delta(x, y) = \begin{cases} 1 & \exists (x', y') \in N_8[(x, y)] : I_b(x', y') = 0 \wedge I_b(x, y) = 1 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.33)$$

Burada  $N_8[(x, y)]$   $(x, y)$ 'ye 8-bağlantı içeren piksel setidir.  $\Delta(x, y)$ , eğer  $(x, y)$  pozisyonundaki piksele karşılık ikili imgedeki  $I_b(x, y)$  pozisyonunda yer alan pikselin değeri 1 ve en az 0 değerine sahip bir komşu pikseli var ise 1 değerini alır; aksi durumda 0 değerini alır. Bu nedenle, ortaya çıkan kenarların 1 piksel genişliğinde olduğu fark edilebilir. Fraktal boyut  $D$ , kutu sayma algoritması olarak kullanılan her kenar görüntüsünden hesaplanmıştır.

### 3.8. Dalgacık Dönüşüm Özellikleri

Pek çok biyofiziksel işaret gibi, FKH de durağan olmayan bir işarettir, özellikle temel kalp hızı, hızlanma ve yavaşlama örüntüleri durağan olmamayı sağlayan temel olaydır. Bu nedenle, FKH işareti yeterli uzunlukta kısa bölümlerle sınırlanmadıkça geleneksel Fourier analizi bu özel işaret türü için uygun değildir. Öte yandan dalgacıklar, pek çok biyofiziksel işaretin analiz edilmesini sağlamak üzere nispeten güçlü matematiksel araçlardır [66].


Bir zaman serisinin dalgacık dönüşümü, işaretin zaman ve frekans alanına yerleştirilmiş ve ana dalgacık ( $\psi$ ) olarak ifade edilen tek bir fonksiyondan üretilen bir dalgacık ailesiyle dönüştürülmesi ve genişletilmesidir.

Dalgacık dönüşümünün, farklı çözünürlük ve ölçeklerde durağan olmayan işaretlerin analizi için son derece kullanışlı bir yöntem olduğu kanıtlanmış durumdadır [52]. Dalgacık dönüşümü matematiksel formda (3.34)'de gösterildiği gibi tanımlanmaktadır [66]. Dalgacık dönüşümü işarete çeşitli spektral bileşenler görüldüğünde, zaman periyodu hakkında ek bilgilerin elde edilmesini sağlamaktadır [27].

$$W[m, n] = 2^{-m/2} \sum_{i=0}^{M-1} FKH[i] \psi(2^{-m}i - n) \quad (3.34)$$

Burada  $m$  ölçek ve  $n$  geçiş parametrelerini gösteren ve negatif olmayan tam sayılardır.  $FKH(i)$  fetal kalp hızı serisi için ardışık indis değerini göstermektedir.  $\psi$  ana dalgacık fonksiyonunu gösterir ve  $M$  analiz edilen toplam atım sayısını temsil eder.

Dalgacık dönüşümü işareti alt bantlarına ayırma, veri sıkıştırma, gürültü giderme ya da işareti yumuşatma amaçlarıyla da kullanılabilir. Dalgacık dönüşümü işaretin uygun dalgacık aileleriyle sentezlenmesini ve analiz edilmesini sağlayan bir ağaç filtre bankasıyla uygulanır. Şekil 3.17 ölçekleme faktörü 2 olan iki kanallı bir filtre bankasıyla dalgacık ayrışımının üç ayrışım aşamasını göstermektedir.



Şekil 3.17 Dalgacık dönüşümünün alt-bant ayrışması

Burada  $h[n]$  ve  $g[n]$  sırasıyla yüksek geçiren ve alçak geçiren filtreleri temsil etmektedir.


Ayrışımındaki temel fikir, aritmetik bir kurala göre sinyalin alçak frekans ( $A$ , yaklaşım) ve yüksek frekans bileşenlerine ( $D$ , detay) ayrıştırmaktır. Bu durum, Şekil 3.18'de gösterilmiştir.

$$S = A1 + D1 \quad (3.35)$$

$$S = A2 + D2 + D1 \quad (3.36)$$

$$S = A3 + D3 + D2 + D1 \quad (3.37)$$

$S$  bir zaman serisini işaret etmek üzere her ayrışım aşamasında işareti temsil eden ayrışım ve detay bileşenlerinin elde edilmesini sağlayan dalgacık katsayıları ( $c$ ) elde edilir. Bu ayrışım tek bir değere ulaşıncaya kadar devam ettirilebilir. Burada  $S$  işareti dalgacık katsayılarının toplamına eşittir.



Şekil 3.18 Dalgacık ayrışımı

FKH analizi için çok seviyeli tek-boyutlu analiz, dalgacık ayrışımı yardımıyla spesifik dalgacık aileleri kullanılarak uygulanabilir. Bu doktora çalışması kapsamında, alanda en fazla kullanılan Haar (haar), Daubechies (db5) ve Symlets (sym5) ana dalgacık aileleri dikkate alınmıştır. Dalgacık ayrışımı ile her bileşenden ortalama mutlak sapma (OMS), medyan mutlak sapma (MMS) ve bir takım ek istatistiksel parametrelerle birlikte  $p$ -normu, Frobenius norm, sonsuzluk ve negatif sonsuzluk normları elde edilmiştir. Ayrıca,  $p$ -normu için 3 değerleri de kullanılmıştır. Sonuç olarak işareti farklı frekans bantlarında tanımlamak üzere her bir bileşenden çok sayıda istatistiksel özellik elde edilmiştir. Her bir dalgacık bileşeni  $1 \times n$  boyutundaki bir sembolik  $V$  vektörü ile gösterilmek ve  $i = 1, 2, \dots, n$  olarak tanımlanmak üzere, vektörün  $p$ -normu, ( $p = 2$ , Frobenius normu), sonsuzluk ve negatif sonsuzluk normları sırasıyla aşağıdaki gibi tanımlanır.

$$\|V\|_p = \left( \sum_{i=1}^n |V_i|^p \right)^{\frac{1}{p}} \quad (3.38)$$

$$\|V\|_F = \sqrt{\sum_{i=1}^n |V_i|^2} \quad (3.39)$$

$$\|V\|_{\infty} = \max(|V_i|) \quad (3.40)$$

$$\|V\|_{-\infty} = \min(|V_i|) \quad (3.41)$$

### 3.9. Özellik Seçimi

Özellik seçimi, sınıflandırma prosedürlerinde ve öğrenme algoritmalarında sınıflandırma doğruluğunu arttırmak ve hesaplama maliyetlerini düşürmek amacıyla önemli bir yer tutmaktadır [157]. Özellik seçimi yöntemlerinin temel amacı, probleme ilişkin özelliklerin en baskın olanlarını ortaya çıkarmaktır. Özellik çıkarma prosedürleri başlıca istatistiğe dayalı (filtreleme) ya da sınıflandırmaya dayalı (sarmal) olarak gerçekleştirilmektedir [158]. Bu yöntemler, özellik setini ifade edecek daha alt özellik setleri oluşturarak sınıflandırma doğruluğunu arttırmaya çalışmaktadır. İstatistiğe dayalı yöntemler sınıflandırmadan bağımsız olarak alt özellik kümesini inşa etmeye çalışırken; sınıflandırmaya dayalı yöntemler faydasız özelliklerin tespiti ve atılması üzerinde çalışırlar.

Özellik seçimi için TBA,  $t$ -testi, doğrusal ayrışım analizi (DAA) gibi yöntemler sıklıkla tercih edilmektedir. Bu yöntemler, sınıf-içi farklılığı en az, sınıflar arası farklılığı ise en fazla tutma prensibine göre çalışmaktadır. Probleme yeni verilerin eklenmesi durumunda yeniden hesaplanma gerekliliği ve çok büyük boyutlu veri setlerine uygulanamama bu yaklaşımların temel eksikleri olarak ifade edilmiştir [157].

Tez çalışması kapsamında özellik seçimi için  $t$ -testi, geriye doğru özellik seçimi (GDÖS) ve TBA kullanılmıştır.

#### 3.9.1. $t$ -Testi

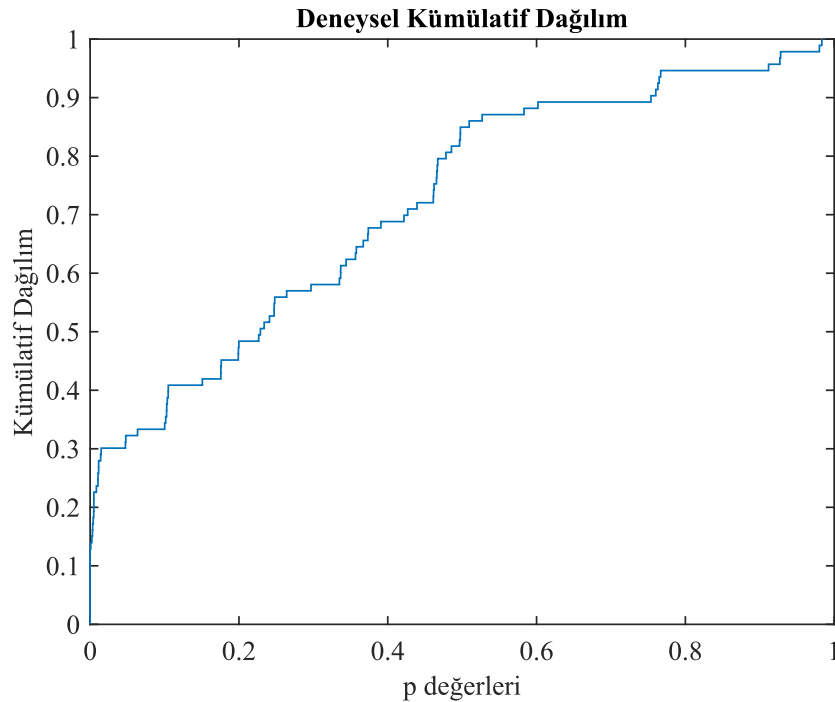
İstatistiksel hipotez, karar verme amacıyla ilgilenilen yığınla ilgili tahmin yapma noktasında yararlı olan bir yaklaşımdır.  $t$ -testi hipotez testlerinden biridir ve yaygın şekilde kullanılmaktadır. Bu test, iki grubun ortalamalarını karşılaştırarak aradaki farkın rastlantısal mı yoksa istatistiksel olarak anlamlı olup olmadığı karar vermek üzere kullanılabilir [159].

$$t = \frac{\bar{X} - \mu}{s} \sqrt{N - 1} = \frac{\bar{X} - \mu}{\frac{s}{\sqrt{N}}} \quad (3.42)$$

$$z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{N}}} \quad (3.43)$$

(3.43)'de ortalaması  $\mu$  olan normal bir yığından çekilmiş  $N$  hacimlik örnekler göz önüne alınır ve her bir örnek için örnek ortalaması  $\bar{X}$  ve örnek standart sapması  $s$  kullanılarak  $t$  hesaplanırsa,  $t$ 'ye ilişkin örnekleme dağılımı elde edilebilir.

$t$ -testi makine öğrenmesinde özellik seçimi prosedürü açısından özellik filtreleme adımı gibi düşünülebilir. Seçilen özelliklerin sınıflandırma başarısı ya da sınıflandırıcıyla bir ilgisi yoktur. En büyük avantajı hızlı ve basit olmasıdır. Bu yaklaşım her değişken üzerinde ayrı ayrı tek değişkenli bir ölçüt sağlamaktadır. İki grubun nasıl ayrıldığını anlamak için deneysel kümülatif dağılım fonksiyonu  $p$  değerlerine bağlı olarak çizdirilmektedir. Şekil 3.19'da örnek bir deneysel kümülatif dağılım grafiğine yer verilmiştir. Ancak, sınıflandırma doğruluğunun maksimum olmasını sağlayacak en iyi özellik setini için en az kaç özelliğin seçilmesi gerektiğini doğrudan bu yaklaşım ile anlamak oldukça güçtür.



Şekil 3.19 Deneysel kümülatif dağılım grafiği

Bu doktora tezi kapsamında  $t$ -testi, normal ve hipoksik örneklerden oluşan özellik setinde  $p < 0.01$  ve  $p < 0.05$  değerlerine bağlı olarak iki grubu tanımlamak üzere

kullanılan her bir özelliğin, gruplar arasında anlamlı bir farklılığa sahip olup olmadığını ve önem derecelerini tespit etmek üzere kullanılmıştır.

### 3.9.2. Geriye Doğru Özellik Seçimi

GDÖS algoritması iç içe sarmal işlemlerden oluşan bir prosedürdür ve çalışması sonucunda bir performans vektörü üretmektedir. Bu algoritma tüm özellik seti ile çalışmaya başlar ve her döngüde alakasız özelliklerin veri setinden atılmasını sağlar. Bu işlem  $k$ -katlı çapraz bir doğrulama döngüsü içerisinde gerçekleştirilir [160].

### 3.9.3. Temel Bileşenler Analizi

Gerçek dünyadaki işaretlerin büyük çoğunluğu, özellikle biyofiziksel işaretler çok yüksek boyutlara sahip olduklarından dolayı bir takım niteliklerle belirtmek durumundadırlar. Bu nitelikler, özellik setini oluştururlar. Daha verimli ve sağlam bir öğrenmenin gerçekleştirilebilmesi için özellik setinin boyutunun azaltılmasına ihtiyaç duyulur [161]. Bu nedenle özellik seçimini ya da özellik dönüşümü yaklaşımları tercih edilir. Bu bağlamda TBA, özellikle boyut indirgeme ve veri sıkıştırma amacıyla yaygın olarak kullanılan doğrusal bir özellik dönüşüm yöntemidir. Boyut indirgeme prosedürü, verinin sahip olduğu uzaydan bir başka uzaya taşınıp bir alt uzayda temsil edilmesidir [162].

$(x_i, y_i)_{i=1}^N$ ,  $x_i \in \mathbb{R}^p$  ve  $y_i \in \{1, 2, \dots, c\}$  şeklinde tanımlanan  $N$  elemanlı bir veri kümesinde  $x_i$ ,  $p$  özelliğe sahip örnekleri ve  $y_i$  ise sınıf bilgisini gösterme koşuluyla temel alt uzaya ait eksenler evrensel ortak-değişinti matrisi olan  $S$ 'den türetilirler [119].

$$S = \frac{1}{N} \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu)(x_i^j - \mu)^T \quad (3.44)$$

Burada  $\mu$  tüm örneklerin ortalama değerini,  $x_i^j$   $j$ 'nci sınıfta olan  $i$ 'nci örneği,  $N_j$   $j$ 'nci sınıfa ait örnek sayısını ve  $c$  ise sınıf sayısını göstermektedir.  $m$  adet temel eksen  $K_1, \dots, K_m$ ,  $S$ 'nin ilk  $m$  en değerli özvektörü bulunarak elde edilir.

$$SK_i = \lambda_i K_i, i = \{1, 2, \dots, m\}, m < p \quad (3.45)$$

Burada  $\lambda_i$ ,  $S$ 'nin  $i$ 'nci en büyük özdeğeridir. Veri kümesi herhangi bir  $x_i$  örneğinin temel bileşenleri (3.46)'e göre elde edilir.



$$\bar{x}_i = K^T x_i, i = \{1, 2, \dots, N\} \quad (3.46)$$

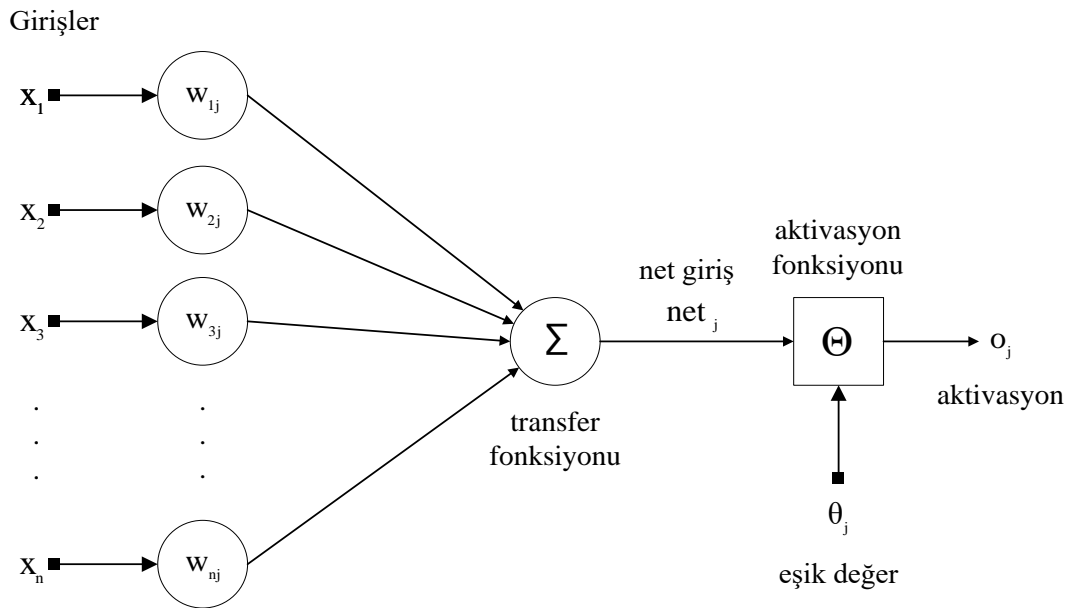
Burada  $x_i \in \mathcal{R}^m$  ve  $K = [K_1, K_2, \dots, K_m]$  şeklinde tanımlanmaktadır [163].

### 3.10. Sınıflandırıcılar

Makine öğrenmesi açısından sınıflandırıcılar, denetimli öğrenmenin bir örneği olarak düşünülebilir. Denetimli öğrenme terimi ise gözlemlerin erişilebilir olduğu bir dizi eğitim serisinin sınıflandırıcılar tarafından öğrenilmesi esasına dayanmaktadır [164]. Bu doktora tez çalışması kapsamında, FKH işaretlerini sınıflandırmak üzere YSA, AÖM, DVM, k-EK, radyal tabanlı fonksiyon ağı (RTFA) ve RO sınıflandırıcıları kullanılmıştır.

#### 3.10.1. Yapay Sinir Ağları

YSA insan beyninin öğrenme ve genelleme özelliklerinden ilham alınarak geliştirilmiş hesaplamalı bir modeldir. Örüntü tanıma, tahmin yapma, optimizasyon, ilişki bellemek ve kontrol gibi gerçek dünya problemlerini çözmek üzere yaygın bir şekilde kullanılmaktadır [165].



Şekil 3.20 Yapay sinir ağı modeli

Şekil 3.20’da klasik bir YSA’nın yapısı gösterilmektedir. Klasik bir YSA, örnekleri temsil eden giriş katmanı, giriş katmanı ile net fonksiyonu arasındaki ağırlıkların çarpılmasıyla elde edilen giriş net fonksiyonu, giriş değerlerinin belirli aralıklara çekildiği aktivasyon fonksiyonu ve çıkış katmanından oluşmaktadır. Buna

göre YSA'nın herhangi bir katmanının çıkışı ( $a^i$ ) matematiksel olarak (3.47)'deki gibi modellenir.

$$a^i = \sigma \left( \sum_{j=1}^N w_{ij} x_j + b^i \right) \quad (3.47)$$

Burada  $\sigma$  aktivasyon fonksiyonunu,  $N$  giriş nöronlarının sayısını,  $w_{ij}$  ağırlıkları,  $x_j$  giriş değerlerini ve  $b$  gizli katman için sapma değerini gösterir.

Bir yapay sinir ağı oluşturulduktan sonra, yapılandırılmalı ve daha sonra eğitilmelidir. Yapılandırma, ağı düzenlenmesini içerir ve böylelikle ağ, çözülmek istenen problemle, örnek veriler kullanılarak uyumlu hale getirilir.

Ağ yapılandırıldıktan sonra, ayarlanabilir parametrelerin (ağırlıklar ve sapmalar) gözden geçirilmesi gerekir, böylelikle ağ optimize edilir. Bu ayarlanma süreci ağı eğitilmesi olarak ifade edilir. Ağı eğitilmesi için örnek veri setine ihtiyaç vardır. Ağ eğitimi de kabaca ikiye ayrılmaktadır. Bunlar artan eğitim ve toplu eğitimidir.

Bir sinir ağı tasarlanırken aşağıdaki adımlar sırayla takip edilmelidir:

- (1) Verilerin toplanması
- (2) Ağı oluşturulması
- (3) Ağı yapılandırılması
- (4) Ağırlık ve sapmanın (bias) ayarlanması
- (5) Ağı eğitilmesi
- (6) Ağı doğrulanması
- (7) Ağı kullanılması

Ağ eğitilmeden önce bir dizi işlem adımının takip edilmesi gerekir. Bunların verinin seçilmesi, verinin önışlemeden geçirilmesi ve ağ türü (çok katmanlı, rekabetçi, dinamik vs.) ile ağ mimarisinin (katman sayısı, nöron sayısı) seçilmesi olarak ifade edilebilir. Ancak giriş uzayını oluşturan veri setinin yeterli olduğundan emin olmak

zordur. Pek çok problemin çözümünde giriş veri kümesinin oldukça geniş olarak tutulması gerekir [166].

Çizelge 3.4 Yapay sinir ağı eğitim algoritmaları

Fonksiyon	Algoritma
<i>trainlm</i>	Levenberg-Marquardt
<i>trainbr</i>	Bayesian Regularization
<i>trainbfg</i>	BFGS Quasi-Newton
<i>trainrp</i>	Resilient Backpropagation
<i>trainscg</i>	Scaled Conjugate Gradient
<i>traincgb</i>	Conjugate Gradient with Powell/Beale Restarts
<i>traincgf</i>	Fletcher-Powell Conjugate Gradient
<i>traincgp</i>	Polak-Ribière Conjugate Gradient
<i>trainoss</i>	One Step Secant
<i>traingdx</i>	Variable Learning Rate Gradient Descent
<i>traingdm</i>	Gradient Descent with Momentum
<i>traingd</i>	Gradient Descent

Bu doktora tez çalışması kapsamında YSA yapılandırılırken çok geniş ölçekli deneysel çalışmalar yürütülmüştür. Özellikle, ağ topolojisi ve eğitim fonksiyonları ve ayarlanabilir parametreler geniş bir ölçekte değerlendirilmiştir. Çizelge 3.4’de YSA için kullanılan eğitim algoritmaları verilmiştir.

### 3.10.2. Aşırı Öğrenme Makineleri

Eğim-tabanlı öğrenme algoritmaları reel hayat problemine çözüm üretirken bu öğrenme algoritmalarını kullanan ağların ihtiyaç duyulan hızdan çok uzakta olduğu görülmüştür. Ayrıca ağın yapılandırılması noktasında pek çok parametrenin elle ayarlanması gereklidir. AÖM, bu bağlamda standart tek-katmanlı ileri beslemeli ağlar (TKİBA) için hızlı bir öğrenme ve daha iyi bir genelleştirme performansı sunmaktadır [167].

$(x_i, t_i)$  ile temsil edilen  $N$  adet keyfi, ayrık ve farklı örnekler için  $x_i = [x_{i1}, x_{i2}, \dots, x_{iD}]^T \in R^D$  ve  $t_i = [t_{i1}, t_{i2}, \dots, t_{iK}]^T \in R^K$  olmak üzere, TKİBA, gizli düğüm sayısını gösteren  $L$  ve aktivasyonu fonksiyonu gösteren  $h(x)$  ile (3.48)’deki gibi tanımlanır [167].

$$\sum_{i=1}^L \beta_i h_i(x_j) = \sum_{i=1}^L \beta_i h_i(\omega_i x_j + b_i) = c_j \quad (3.48)$$

$j = 1, 2, \dots, N$  dir. Burada, ağırlık vektörü  $\omega_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{iD}]^T$ ,  $i$ . gizli düğüm ile giriş düğümleri birbirine bağlarken,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iK}]^T$  olarak tanımlanmış ağırlık vektörü  $i$ . gizli düğüm ile çıkış düğümlerini birbirine bağlamaktadır.  $i$ . düğüm için sapma değeri  $b_i$  ile gösterilmiştir.  $L$  gizli düğüm ve  $h(x)$  aktivasyon fonksiyonu ile bir AÖM kompakt formda aşağıdaki gibi yazılır.

$$H\beta = Y \quad (3.49)$$

$$H = \begin{bmatrix} h_1(\omega_1 x_1 + b_1) & \cdots & h_L(\omega_L x_1 + b_L) \\ \vdots & \ddots & \vdots \\ h_1(\omega_1 x_N + b_1) & \cdots & h_L(\omega_L x_N + b_L) \end{bmatrix} \quad (3.50)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix} \quad (3.51)$$

TKİBA'nin geleneksel çözümlerinden farklı olarak AÖM, fonksiyonu (3.52)'deki gibi çözer.

$$\beta = H^\dagger Y \quad (3.52)$$

$H^\dagger$  burada,  $H$  matrisinin genelleştirilmiş tersi Moore-Penrose temsil etmektedir.  $H^\dagger$  aşağıdaki gibi açıklanabilir.

$$H^\dagger = \begin{cases} (H^T H)^{-1} H^T & H^T H \text{ tekil matris değilse} \\ H^T (H H^T)^{-1} & H H^T \text{ tekil değilse} \end{cases} \quad (3.53)$$

Burada  $H^T$ ,  $H$  matrisini transpozunu ifade etmektedir. AÖM'nin kararlılığı ve genelleştirme performansı  $H^T H$  veya  $H H^T$ 'nin diyagonal değerlerine (3.54)'de belirtilen şekilde bir pozitif ekleme yapılarak geliştirilebilir [168].

$$\hat{\beta} = \left( H^T H + \frac{I}{\lambda} \right)^{-1} H^T Y \quad (3.54)$$

Burada  $\lambda$  düzenlilik parametresidir. Verilen matematiksel formlara bağlı olarak AÖM aşağıdaki gibi özetlenebilir [169].

Giriş =  $\{x, y\}$  eğitim örnekleri,  $N$  gizli düğüm sayısı ve  $\lambda$  düzenlilik parametresi olmak üzere:

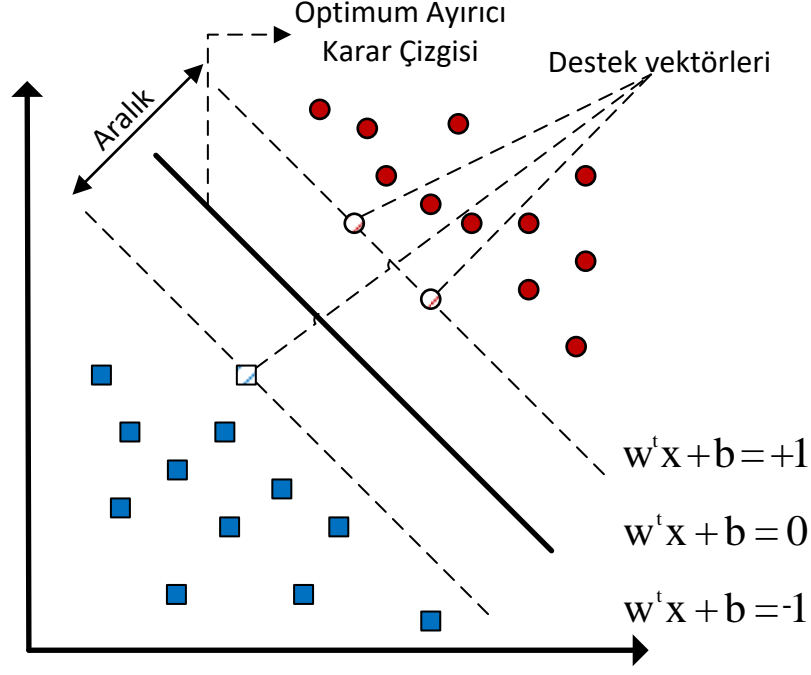
- (1) Giriş ağırlıklarının ( $w$ ) ve gizli katman sapma değerlerinin ( $b$ ) rastgele oluşturulması
- (2) Gizli katman çıkışı  $H$  matrisinin (3.49) göre hesaplanması
- (3)  $\hat{\beta}$ 'nin (3.52) veya (3.54) göre hesaplanması

$H^\dagger$ 'nin eşsizliğinin sonucu olarak, özel çözüm  $\hat{\beta}$  benzersizdir. Bu kapsamda, AÖM eğim-tabanlı öğrenme algoritmalarına göre daha iyi bir genelleştirme performansı sağlayabilir.

### 3.10.3. Destek Vektör Makineleri

DVM sınıflandırma, tahmin, kümeleme gibi problemler için global çözümler sunan ve diğer makine öğrenmesi algoritmalarının aksine, deneysel risk minimizasyonu değil yapısal risk minimizasyonunu kullanan bir algoritmadır [170].

Giriş vektörleri  $x_i \in \mathfrak{R}^n$  ile ifade edilmek ve  $y_i \in \{-1, 1\}$  giriş vektörünün ait olduğu sınıfı göstermek üzere  $D = \{x_i, y_i\}_{i=1}^N$  şeklinde tanımlanan bir veri setinde, veri kümesindeki kayıt sayısı  $N$  ile gösterilmiştir. Verilerin dağılımı Şekil 3.21'de gösterildiği gibi gerçekleşmiştir. Buna göre, giriş kümesindeki kayıtların doğrusal olarak ayırt edilebildiği varsayıldığında bu verileri ayıran karar çizgisi  $w^T x + b = 0$  şekilde ifade edilir. Bu sınır çizgisine paralel olan çizgilerin denklemleri ise sırasıyla  $w^T x + b = 1$  ve  $w^T x + b = -1$  olarak tanımlanır [57]. DVM'deki temel prensip bu iki paralel çizgi arasındaki mesafeyi  $m = \frac{2}{\|w\|^2}$  şeklinde maksimum yapmaktır. Bu aynı zamanda  $\frac{1}{2} \|w\|^2$  en küçük yapmakla aynı amacı ifade etmektedir [171]. Dolayısıyla en büyük aralığa sahip sınıflandırıcı denklemi aşağıdaki gibi tanımlanır.



Şekil 3.21 DVM için verilerin dağılımı ve en büyük aralıklı sınıflandırıcı

$$\max_{w,b} \frac{2}{\|w\|} = \min_{w,b} \frac{1}{2} w^T w \quad (3.55)$$

$$\text{Kısıt: } y_i(w^T x_i + b) \geq 1, i = 1, \dots, N$$

Problem bir kısıta sahip olduğundan, bu problemin her zaman bir çözümünü bulmak kolay değildir. Problem Lagrange çarpanı prensibine göre (3.56) gibi ifade edilebilir.

$$\min_{\alpha} L(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i^T x_j - \sum_{i=1}^N \alpha_i \quad (3.56)$$

$$\text{Kısıt: } \sum_{i=1}^N \alpha_i y_i = 0$$

Yukarıdaki denkleme göre bazıları sıfır olan Lagrange çarpanları elde edilir.  $\alpha_i > 0$  şeklinde Lagrange çarpanına sahip olan  $x_i$  vektörlerine “destek vektörleri” denir. Bu vektörler  $y_i(w^T x_i + b) = 1$  koşuluna uyar ve sınır çizgisi dahilindedirler. Birincil uzaydaki  $\hat{y} = w^T x + b$  olan sınıflandırıcı ikinci uzayda aşağıdaki ifade edilen eşitliğe dönüşür.

$$\hat{y}(x) = \sum_{i=1}^N \alpha_i y_i x_i^T x + b \quad (3.57)$$

Sınıflandırmaya katkısı olan giriş verileri sadece destek vektörleridir.  $\mathcal{S}$  destek vektörlerinin kümesini ifade etmek üzere (3.57)'deki model (3.58)'deki gibi ifade edilebilir.

$$\hat{y}(x) = \sum_{i \in \mathcal{S}} \alpha_i y_i x_i^T x + b \quad (3.58)$$

Yukarıdaki denklem destek vektör modeli olarak ifade edilir.

Bazen verileri doğrusal olarak ayırmak mümkün olmayabilir. Böyle bir durumda doğruluktan bir parça ödün verilerek veriler yine iki ayrı eksene aralarındaki mesafe maksimum olacak şekilde ayrılabilir. Bu durumda hataya belli oranda izin veren sınıflandırıcı modeli (3.59)'daki gibi ifade edilebilir. Burada  $\zeta$  hata miktarını ifade etmektedir.

$$\min_{w,b} \frac{1}{2} w^T w + C \sum_{i=1}^N \zeta_i$$

$$Kısıt: y_i(w^T x_i + b) \geq 1 - \zeta, i = 1, \dots, N \quad (3.59)$$

$$\zeta_i \geq 0 \quad i = 1, \dots, N$$

Yukarıdaki denklemin Lagrange formu aşağıdaki gibi yazılır. Burada  $C$  hataları cezalandıran bir ceza parametresidir.

$$\min_{\alpha} L(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x_i^T x_j - \sum_{i=1}^N \alpha_i$$

$$Kısıt: \sum_{i=1}^N \alpha_i y_i = 0 \quad (3.60)$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, N$$

Esnek aralıklı sınıflandırıcı modeli de tıpkı en büyük aralıklı sınıflandırıcı gibi  $\hat{y}(x) = \sum_{i \in \mathcal{S}}^N \alpha_i y_i x_i^T x + b$  şeklindedir. Yalnız Lagrange katsayılarında  $0 \leq \alpha_i \leq C$  şeklinde bir sınırlandırma vardır.

Verinin yapısına bağlı olarak bazen giriş veri setini doğrusal olarak ayırmak mümkün olmayabilir. Bu durumda, veriler  $\Phi(\cdot)$  ile gösterilen bir dönüşüm fonksiyonu ile daha yüksek boyutlara çekilirler. Böylelikle  $x_i^T x_j$  iç çarpımı yerine  $\Phi^T(\cdot)\Phi(\cdot)$  iç çarpımı kullanılır. Aşağıda yaygın olarak kullanılan polinom kernel fonksiyonu, sigmoid kernel fonksiyonu ve gauss kernel fonksiyonu sırasıyla matematiksel formlarıyla birlikte verilmiştir.

$$K(x_i, x_j) = (x_i^T x_j + c)^d \quad (3.61)$$

Burada  $c$  negatif olmayan sabit bir sayıdır ve genellikle 1 olarak kullanılır,  $d$  ise polinom derecesidir ve parametre formunda kullanılır.

$$K(x_i, x_j) = (kx_i^T x_j + \theta) \quad (3.62)$$

Burada  $k$  ve  $\theta$  ifadenin Mercer koşullarını sağlamak için kullanılan parametreleri temsil etmektedir.

$$K(x_i, x_j) = e^{-\frac{\|x_i^T - x_j\|}{2\sigma^2}} \quad (3.63)$$

Bu durumda Kernel fonksiyonunun DVM model eşitliğine entegre edilmesi durumunda (3.64) ve (3.65)'deki eşitlikler elde edilir [172].

$$\min_{\alpha} L(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \quad (3.64)$$

$$\text{Kısıt: } \sum_{i=1}^N \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, N$$



$$\hat{y}(x) = \sum_{i \in S}^N \alpha_i y_i K(x_i, x_j) \quad (3.65)$$

### 3.10.4. k-EK Yakın Komşu Sınıflandırıcısı

k-EK parametrelerin bağımsız olduğu, uygulanması basit ve birçok reel problem üzerinde tatmin edici sonuçların elde edildiği bir sınıflandırma metodudur [106].

k-EK algoritması  $S, k, t$  olmak üzere üç kavram tarafından tanımlanmaktadır. Burada  $S$ ,  $N$ -boyutlu bir uzayda gerçek ya da tam sayılardan oluşan bir veri çiftini bağlayan benzerlik ölçüsünü temsil eder.  $k$  sınıflandırmayı gerçekleştirmek üzere eğitilen en yakın verilerin sayısını gösterir.  $t$  sınıflandırıcıya uygulanan  $M$  adet eğitim verisinin vektörüne karşılık gerçek sınıf değerlerini içeren parametredir.

$t$ , sınıflandırıcının uygulandığı ve  $k$  en yakın komşularının ortaya çıktığı bir veri örneği ise bu  $t$  için bir komşuluğun oluştuğu anlamına gelir. Kullanılan metot veri örneğini sınıflandırmak için  $t$  komşuluk alanını göz önüne alırken, mesafeyi dikkate alır ya da almaz. Hiç şüphesiz,  $k$  için doğru değer seçimi oldukça kritiktir, çünkü bu seçim sınıflandırma başarısıyla doğrudan ilişki içerisindedir. k-EK yöntemi saptırılmış  $k$  değeri nedeniyle sınıflandırma noktasında başarısız olabilir. Elbette  $k$  değerinin seçmenin pek çok farklı yolu vardır. Bunlardan biri, deneysel olarak  $k$  değerini sürekli değiştirip sınıflandırma doğruluğunu en yüksek veren  $k$  değerini seçmektir. Bu kapsamda, k-EK yönteminin  $k$  seçimi üzerindeki bağımlılığını azaltmak amacıyla tek bir  $k$  değerini seçilmesi yerine, en yakın komşuların setlerini içeren bir kontrolün yapılması önerilmiştir [173].

$$d_E = \sum_{i=1}^N \sqrt{(x_i - y_i)^2} \quad (3.66)$$


Denklem (3.66)'da belirtildiği üzere k-EK sınıflandırıcısı genellikle Öklid uzaklık bağıntısını örnekler arasındaki mesafeyi bulmak üzere kullanmaktadır [174]. Bunun dışında algoritma, Manhattan, Minkowski gibi farklı mesafe ölçütlerini de kullanabilmektedir.

k-EK örnek tabanlı bir sınıflandırıcı özelliği sergilediğinden sınıflandırıcı sistem parametreleri olarak örneklerin birbirine olan uzaklığını kullanır. Algoritma tüm giriş

veri setini  $d$  boyutlu bir uzaydaki noktalar olarak kabul eder. Sınıf bilgisi bilinmeyen yeni bir örnek test edildiği zaman  $k$  değerine bağlı olarak karar verilir. Test aşamasında önceden sınıf bilgisi bilinen örnekler ile bir karşılaştırma yapılmaktadır, bir başka ifadeyle bu kıyaslama dışında ayrıca bir eğitim aşaması yoktur. Bu nedenle, pek çok durumda yüksek bir genelleme sağlamaktadır. Ancak çok büyük veri setlerinde test işleminin tüm eğitim kümesiyle kıyaslanması zaman alacağından, bu durumda dezavantajlı olabilir. Artık verilerin olması ve veri setinin büyüklüğü  $k$ -EK'nın başarısı için sorun teşkil eden diğer önemli iki husus olarak rapor edilmiştir [106].

### 3.10.5. Radyal Tabanlı Fonksiyon Ağı

RTFA bir giriş katmanı, bir gizli katman ve bir çıkış katmanından oluşan ve ileri beslemeli YSA'nın özel bir türü olarak değerlendirilen bir ağıdır. Temelde, tek gizli katman bulundurması ve gizli katmandaki nöronların aktivasyon fonksiyonu olarak RTF'ler kullanılması karakteristik özellikleridir [175].



Şekil 3.22 Tipik bir radyal tabanlı fonksiyon ağı

Şekil 3.22’de tipik bir RTFA yapısına yer verilmiştir. YSA’da gizli katmanlarda sigmoid ve S-türü fonksiyonların kullanıldığı bilinmektedir. RTFA gizli katmanda bu fonksiyonların yerine çekirdek fonksiyonları kullandığından, çok katmanlı YSA ağlarına kıyasla çok daha hızlı öğrenebilmektedir [176].

Bu ağ türünde, girdi katmanındaki verilerin gizli katmana değiştirilmeden aktarıldığını, bir başka ifadeyle giriş katmanı ve gizli katman arasındaki tüm ağırlıkların 1 olarak değerlendirildiğine dikkat etmek gerekir. Giriş katmanından alınan bilgi RTF fonksiyonları aracılığıyla işlenir ve ilgili ağırlık değerleriyle çarpıldıktan sonra çıkış katmanına gönderilir. Bu akışta, gizli katmandaki nöron sayısı  $P$ , herhangi bir  $p$ ’nci nöronla ilişkili RTF  $h_p$  ile sembolize edilmek üzere, bir girdi  $x$  karşılık RTFA çıkışı (3.67)’deki gibi modellenir.

$$f(x, w) = \sum_{p=1}^P w_p h_p(x) \quad (3.67)$$

Burada ağın çıktısı  $f(x, w)$  gösterilmiştir. Denklem (3.67)’deki ifade tipik bir doğrusal modele indirgenerek (3.68)’deki gibi yazılabilir.

$$y = Hw \quad (3.68)$$

Eğitim veri kümesi içerisindeki gözlem sayısı  $N$ , gizli katmandaki nöron sayısı  $P$  olmak üzere,  $y$ ,  $N \times 1$  boyutunda tahmin vektörünü,  $w$ ,  $P \times 1$  boyutunda ağırlık vektörünü ve  $H$  (3.69)’da gösterildiği gibi  $K \times p$  boyutunda tasarım matrisini ifade etmektedir.

$$H = \begin{bmatrix} h_1(x_1) & \dots & h_p(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_K) & \dots & h_p(x_K) \end{bmatrix} \quad (3.69)$$

RTFA ağlarında başarımlı ağın modellenen de anlaşılacağı üzere gizli katmandaki nöron sayısı ve kullanılacak RTF türü ile doğrudan ilişki içerisindedir. Bir RTF merkez ( $c$ ) ve yarıçap ( $r$  ve  $r > 0$ ) olmak üzere iki parametre ile birlikte tanımlanır. Geleneksel olarak kullanılan bir RTF fonksiyonunu yapısı (3.70)’de gösterilmiştir.

$$h = e^{\left(\frac{(x-c)^2}{r^2}\right)} \quad (3.70)$$

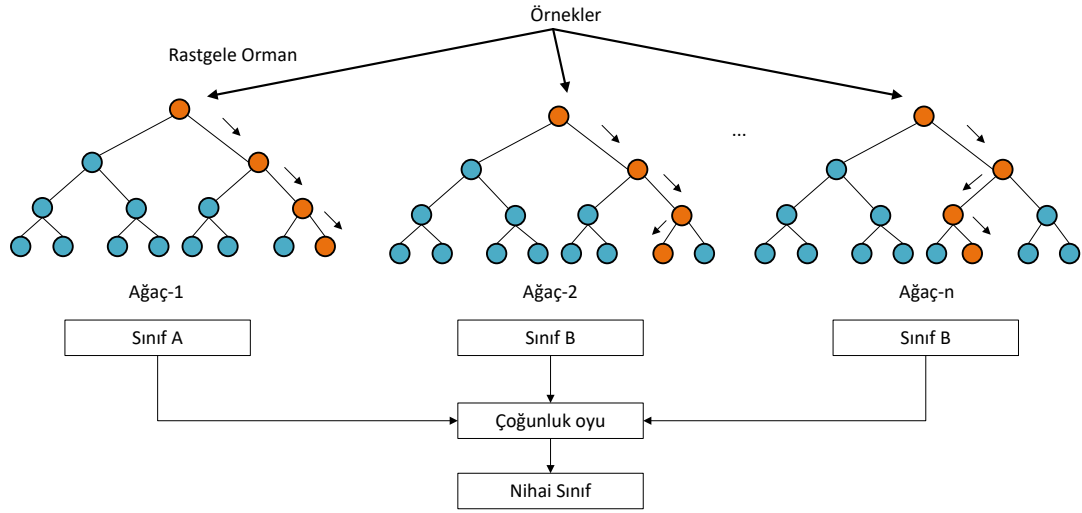
RTFA'da öğrenme iki aşamada gerçekleşmektedir. İlk aşama, biraz daha denetimsiz öğrenmeye benzeyen gizli katmanda yer alan RTF'lerin merkez ve yarıçap değerlerinin belirlenmesi aşamasıdır. Bu aşamada sınıf etiketleri kullanılmadığı için biraz daha denetimsiz öğrenme yaklaşımına benzediği savunulabilir. İkinci aşamada ise, gizli katman ile çıkış katmanı arasındaki ağırlık değerlerinin güncellenmesi yapılır [106].

### 3.10.6. Rastgele Orman

RO, sınıflandırma doğruluğunun bir sentezini sunan algoritmadır. RO'da keyfi örneklendirme ve grup oluşturma yolu daha iyi bir genellemenin yanında güvenilir öngörüğü yakalamak için bir şans vermektedir [106]. 2001 yılında Breiman torbalama metodunu önererek RO algoritmasını öne sürmüştür. RO, farklı alt eğitim kümelerinin elde edilmesini sağlamak üzere önyükleme tekniğini kullanırken; ağaçların geliştirilmesi aşamasında rastgele özellik seçimi tekniğinden faydalanır [177]. Önyükleme tekniği, istatistiksel çıkarım yapmak amacıyla orijinal veriden alt veri setlerinin türetilmesini sağlamaktadır. Rastgele özellik seçimi ise torbalama yönteminden farklı olarak tüm değişkenleri kullanmak yerine her düğümde rastgele seçilen değişkenler arasından en iyisinin seçilmesidir. RO'da ağaç geliştirme işlemi CART algoritmasına göre yapılır; tek fark budalama işleminin yapılmamasıdır [178]. Dolayısıyla, RO genelleştirme performansı yüksek, çok hızlı, aşırı uyuma karşı dayanıklı ve arzu edilen sayıda ağaçla çalışabilme özelliklerine sahip bir sınıflandırıcı olarak değerlendirilmektedir.

Bir RO çalışırken, eğitim veri setinin 2/3 önyükleme için kullanılır. Geriye kalan 1/3'lük kısım ise genelleştirilmiş hata verisi olarak adlandırılır ve hataları test etmek üzere kullanılır. RO yapılandırma aşamasında, düğümlerde kullanılacak değişken sayısı ( $m$ ) ve ağaç sayısını belirtmek üzere ( $N$ ) iki parametrenin tanımlanmasını gerekli kılar.  $m$  parametresinin ayarlanması hatalara bağlı olarak gerçekleştirilir. Korelasyon ve güç  $m$  değerinin artırılıp azalmasıyla orantılı olarak değişmektedir. Bu parametrenin ayarı genelleştirilmiş hataya göre ayarlanır.  $m$  parametresinin düzgün bir şekilde ayarlanması neticesinde sınıflandırma duyarlılığı da artar ve hata azalır. Hem

yeterli öngörünün sağlanması hem de yeterli miktarda düşük korelasyon sağlayan değişken sayısının seçimi, kritik bir konudur [179].



Şekil 3.23 Rastgele orman algoritması

### 3.11. Performans Ölçütleri

Sınıflandırıcıların performanslarını değerlendirmek amacıyla karmaşıklık matrisi ve AİK yöntemlerinden sıklıkla faydalanılmaktadır. Bu bölümde her iki yöntem kısaca açıklanmıştır.

#### 3.11.1. Karmaşıklık Matrisi

Makine öğrenmesi ve istatistiksel öğrenme alanlarında karışıklık matrisi, bir başka ifadeyle hata matrisi ya da ikili ihtimal tablosu özel bir tablodur. Bu tablo, genellikle bir algoritmanın başarısını ölçmek üzere kullanılmaktadır. Karmaşıklık matrisi, her bir satırında algoritmanın doğru ve yanlış şekilde tahmin ettiği örneklerle birlikte gerçek değerlerin eşleşmesi doğrultusunda elde edilen dört farklı sayısal endekslerden oluşur. Doğru pozitif (DP) ve doğru negatif (DN) sırasıyla doğru şekilde tahmin edilmiş normal ve hipoksik örneklerin sayısını temsil ederken; yanlış pozitif (YP) ve yanlış negatif (YN) sırasıyla yanlış şekilde tanımlanmış normal ve hipoksik örneklerin sayısını temsil etmektedir. Hata matrisinin kullanımı, özellikle medikal uygulamalarda oldukça yaygın bir şekilde gözlemlenmektedir.

Şekil 3.24’de örnek bir hata matrisine yer verilmiştir. DP, DN, YP ve YN indislerinin temsil ettiği sayılar sırasıyla  $A$ ,  $B$ ,  $C$  ve  $D$  değerleri ile gösterilmiştir. Benzer şekilde, gerçek pozitif (gp) ve gerçek negatif (gn) ile pozitif tahmin (pt) ve

negatif tahmin (nt) değeri satır ve sütunların toplamlarından oluşacak şekilde  $A + C$ ,  $B + D$  ve  $A + B$ ,  $C + D$  değerleriyle gösterilmiştir [180].

		+R	-R			+R	-R		
Çıkış sınıfı	+P	DP	YP	pt		A	B	A+B	
	-P	YN	DN	nt		C	D	C+D	
		gp	gn			A+C	B+D		
		Hedef Sınıf				Hedef Sınıf			

Şekil 3.24 Hata matrisi

Hata matrisi sağladığı indisler sayesinde sınıflandırıcı karakteristiğini temsil eden çeşitli başarımların elde edilmesini sağlamaktadır. Bu kapsamda en sık kullanılan başarımların ölçütleri matematiksel formları ile birlikte tanımlanmıştır.

Doğruluk (DĞR), sistemin tüm örnekler üzerindeki başarımlarını göstermektedir ve (3.71)'deki gibi tanımlanmaktadır.

$$D\check{G}R = \frac{DP + DN}{DP + YP + YN + DN} = \frac{A + D}{A + B + C + D} \quad (3.71)$$

Duyarlılık (DUY), sistemin pozitif örnekler üzerindeki başarımlarını ölçmek üzere kullanılır ve (3.72)'deki gibi tanımlanır.

$$DUY = \frac{DP}{DP + YN} = \frac{A}{A + C} \quad (3.72)$$

Özgüllük (ÖZG), sistemin negatif örnekler üzerindeki başarımlarını ölçmek üzere kullanılır ve (3.73)'deki gibi tanımlanır.

$$\check{O}ZG = \frac{DN}{DN + YP} = \frac{D}{D + B} \quad (3.73)$$

Hassasiyet ya da pozitif tahmin değeri (PTD) sistemin pozitif örnekleri tahmin etme değerini verir ve (3.74)'deki gibi tanımlanır.

$$PTD = \frac{DP}{YP + DP} = \frac{A}{B + A} \quad (3.74)$$

Negatif tahmin değeri (NTD), PTD'ye benzer şekilde sistemi negatif örnekleri doğru bir şekilde tahmin etme değerini verir ve (3.75)'de gibi tanımlanır.

$$NTD = \frac{DN}{YN + DN} = \frac{D}{C + D} \quad (3.75)$$

Yanlış pozitif oran (YPO) (3.76)'daki gibi tanımlanır.

$$YPO = \frac{YP}{YP + DN} = \frac{B}{B + D} = 1 - \text{ÖZG} \quad (3.76)$$

Yanlış negatif oran (YNO) (3.77)'deki gibi tanımlanır.

$$YNO = \frac{YN}{DP + YN} = \frac{C}{A + C} \quad (3.77)$$

F-ölçütü (F1) hassasiyet ve özgüllük değerinin harmonik ortalaması olarak ifade edilir ve (3.78)'deki gibi tanımlanır.  $\beta$  genellikle 1 olarak kullanılır ve duyarlılığa karşı hassasiyet önemini ifade eden bir katsayıdır.

$$F1 = \frac{(1 + \beta)^2 DUY \times PTD}{\beta^2 \times DUY + PTD} = \frac{2DP}{2DP + YP + YN} = \frac{2A}{2A + B + C} \quad (3.78)$$

Kalite endeksi (KE), özgüllük ve duyarlılık değerlerinin geometrik ortalaması olarak ifade edilir. KE özellikle verilerin sınıflar üzerinde dengesiz dağılım gösterdiği durumlarda sıklıkla kullanılır ve (3.79)'daki gibi tanımlanır.

$$KE = \sqrt{\left(\frac{A}{A + C}\right) \times \left(\frac{D}{D + B}\right)} \quad (3.79)$$

Doğruluk ile birlikte hata oranı (HO) geleneksel olarak kullanılan bir metriktir ve (3.80)'deki gibi tanımlanır.

$$HO = 1 - D\check{G}R \quad (3.80)$$

Yukarıdaki performans ölçütlerinin verilerin sınıflar üzerinde dengeli dağıldığı durumlarda kullanılması uygun olacaktır. Bazı durumlarda, veri setinde sınıflandırılması gereken kayıtlar sınıflar üzerine eşit bir şekilde dağılmayabilir. Örneğin 316 normal ve 44 hipoksik fetüs örneğinden oluşan bir veri setinde kayıtlar sınıflar üzerinde dengesiz bir şekilde dağılmıştır. Verilerin sınıflar üzerinde dengesiz bir şekilde dağıldığı durumlarda sınıflandırıcılar, çoğunluğu oluşturan sınıfı ayırt etme konusunda yanlı davranabilir. Bu durumda, veri setinde azınlığı oluşturan sınıfın ayırt edilmesi, çoğunluğa göre daha zayıf kalabilir [181]. Dolayısıyla çoğunluğu oluşturan sınıfa bağlı olarak, çok yüksek duyarlılık değeriyle birlikte düşük özgüllük ya da çok düşük özgüllük değeriyle birlikte yüksek duyarlılık değerlerinin elde edilmesi olasıdır. Bu nedenle, AİK eğrisi, hassasiyet-duyarlılık eğrisi ve kalite endeksi gibi daha bilgilendirici performans metriklerinin kullanılması tavsiye edilmektedir.

Sezgisel olarak, hassasiyet (pozitif tahmin değeri) kesinliğin bir ölçütüdür, bir başka ifadeyle pozitif olarak etiketlenmiş örneklerin kaç tanesinin doğru olarak etiketlendiği hakkında bilgi veren bir ölçüttür. Duyarlılık eksiksizliğin bir ölçütüdür ve pozitif sınıfın kaç örneğinin doğru olarak etiketlendiği bilgisini vermektedir. Bu iki metrik arasında, aynen doğruluk ve hata oranı gibi, ters bir orantı görülmektedir; ancak doğruluk ve hata oranında olduğu gibi bu iki metrik, veri dağılımının değişimine karşı bir hassasiyet taşımamaktadır. Pozitif tahmin değeri veri dağılımına karşı duyarlı iken, duyarlılık ölçütü bu konuda herhangi bir hassasiyete sahip değildir. Ayrıca, duyarlılık kaç pozitif örneğin yanlış olarak etiketlendiği hakkında herhangi bir fikir vermez. Bu ölçütlerin aksine F-ölçütü doğruluğa göre daha anlamlı bir performans ölçütü olarak değerlendirilebilir ancak yine de veri dağılımına karşı duyarlı kalmaktadır. Bir başka metrik, geometrik ortalamadır (kalite endeksi) ve tümevarımsal yanlılığın derecesini pozitif ve negatif doğruluk oranı açısından değerlendirir.

Yukarıdaki ifadelerden de anlaşılacağı üzere bir veri setinde, verilerin sınıflar üzerinde dengesiz bir şekilde dağılmasından dolayı performans metrikleri bazen yanıltıcı, bazen de uygun olmayan sonuçlara üretebilmektedir. Bu durumu engellemek üzere çoğunlukla farklı ve daha bilgilendirici performans ölçütlerinin kullanıldığı görülmüştür. Verilerin sınıflar üzerinde dengesiz bir şekilde dağılması durumunda performans ölçütlerinin olası yanıltıcılığını engellemek üzere ağırlıklı performans ölçütü hesaplaması dikkate alınabilir. Bu durumda, hesaplama yapılırken verilerin



sınıflar üzerindeki dağılımı, yani her bir sınıfa düşen toplam örnek sayısı da dikkate alınır. Buna göre, duyarlılık, özgülük, yanlış negatif oran ve F-ölçütü gibi ağırlıklı performans metrikleri sırasıyla aşağıdaki gibi tanımlanabilir.

$$DUY_{ağ} = \frac{\left(\left(\frac{A}{A+C}\right)(A+B)\right) + \left(\left(\frac{D}{B+D}\right)(C+D)\right)}{N} \quad (3.81)$$

$$ÖZG_{ağ} = \frac{\left(\left(\frac{D}{B+D}\right)(A+B)\right) + \left(\left(\frac{A}{A+C}\right)(C+D)\right)}{N} \quad (3.82)$$

$$YNO_{ağ} = \frac{\left(\left(\frac{C}{C+D}\right)(A+B)\right) + \left(\left(\frac{B}{A+B}\right)(C+D)\right)}{N} \quad (3.83)$$

$$F1_{ağ} = \frac{\left(\left(\frac{2A}{2A+B+C}\right)(A+B)\right) + \left(\left(\frac{2D}{2D+B+C}\right)(C+D)\right)}{N} \quad (3.84)$$

### 3.11.2. Çok-Sınıflı Sınıflandırıcılar için Performans Metrikleri

Bölüm 3.11.1’de belirtilen performans metrikleri iki sınıflandırmayı sağlamak üzere kullanılmaktadır. Buna göre sınıf sayısının  $M$  olarak ifade edildiği çok sınıflı bir sınıflandırıcı için performans metrikleri aşağıdaki gibi tanımlanır.

$$DUY_M = \frac{\sum_{i=1}^M \frac{DP_i}{DP_i+YP_i}}{M} \quad (3.85)$$

$$ÖZG_M = \frac{\sum_{i=1}^M \frac{DN_i}{DN_i+YP_i}}{M} \quad (3.86)$$

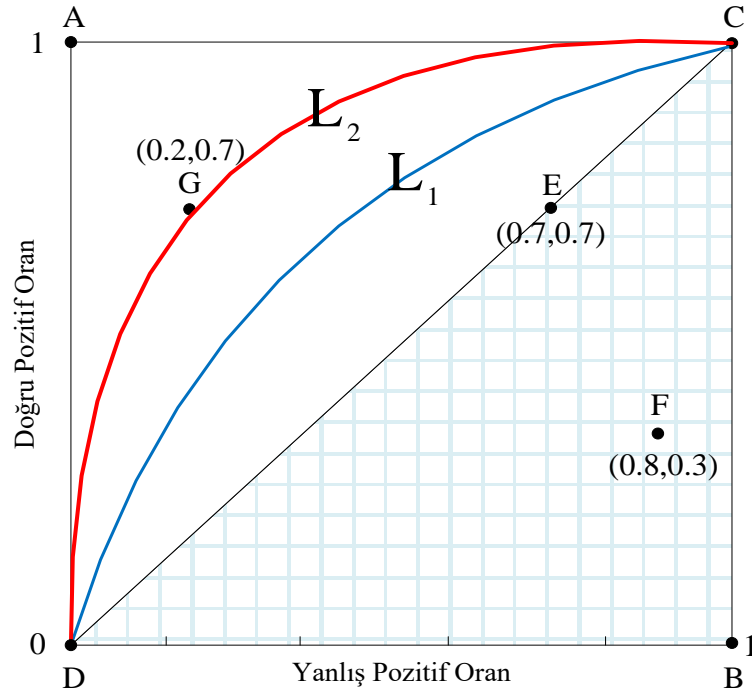
$$GO_M = \sqrt{DUY_M \cdot ÖZG_M} \quad (3.87)$$

### 3.11.3. AİK Eğrisi

AİK sınıflandırıcı performansı ölçmek üzere yaygın olarak kullanılan metotlardan biridir. Bir AİK grafiği, dikey ekseninde DP oranı ve yatay ekseninde DP’ye karşılık gelen YP oranlarına bağlı olarak çizdirilir. DP oranı bu grafikte sınıflandırıcının sağladığı faydaya işaret ederken; YP oranı sınıflandırıcının maliyetine işaret etmektedir [180].

Şekil 3.25 Örnek bir AİK grafiği verilmiştir. Bu AİK grafiğine, grafiği yorumlamak üzere A, B, C, D, E, F ve G olmak üzere toplamda 7 nokta yerleştirilmiştir. Sol üst köşede yer alan A noktası (0,1) mükemmel bir sınıflandırma anlamına gelir. E noktası sınıf etiketlerinin rastgele tahminini sağlayacak bir sınıflandırıcıyı temsil etmektedir. Bu nedenle AİK alanında sağ alt üçgende görünen herhangi bir sınıflandırıcı kötü bir performansa işaret etmektedir. Örneğin F noktası, sınıflandırıcı tahmininin tamamen rastgele yapıldığı anlamına geldiği bir bölgeyi temsil eder. F'nin simetriğinde bulunan G noktasındaki bir sınıflandırıcı bilgilendiricidir; yani sınıflandırıcının üreteceği kararlar kabul edilebilirdir [181].

Şekil 3.25'de  $L_1$  ve  $L_2$  olmak üzere iki eğri görülmektedir.  $L_2$  eğrisi,  $L_1$  eğrisi ile kıyaslandığında daha geniş bir alana sahiptir, yani  $L_2$  eğrisinin AİK-AKA değeri  $L_1$ 'e kıyasla daha büyük olduğu için  $L_2$  sınıflandırıcısının daha iyi bir genelleştirme performansı sağladığı söylenebilir.




Şekil 3.25 Örnek bir AİK grafiği

#### 3.11.4. k-Katlı Çapraz Doğrulama

Çapraz doğrulama, iyi bir model değerlendirme tekniğidir. Modeller değerlendirilirken modelin daha önce görmediği veriler üzerinde bir tahmin yapılması istediğinde, modelin bunu ne kadar iyi yapacağı konusunda herhangi bir bilgi yoktur ve bu bir sorundur [182]. Bu sorunu aşmanın yollarından biri, modeli eğitirken

verilerin tamamının eğitim için kullanılmamasıdır. Bu nedenle, verilerin bir kısmı eğitimden önce veri setinden çıkartılır. Eğitim tamamlandıktan sonra veri setinden çıkartılan örnekler modeli test etmek üzere kullanılır. Çapraz doğrulama denilen model değerlendirme yöntemi tam olarak bu durumu ifade eder.



Şekil 3.26 10-katlı çapraz doğrulama

Hangi verilerin test için dışarıda bırakacağı veya bu verilerin nasıl seçileceği konusunda  $k$ -katlı çapraz doğrulama tekniği kabul görmüş bir yaklaşımdır.  $k$ -katlı çapraz doğrulamada, veri seti  $k$  alt parçaya bölünür ve dışarıda tutma işlemi  $k$  defa gerçekleştirilir. Her seferinde,  $k$  alt kümelerinden biri test kümesi olarak kullanılırken diğer  $k - 1$  alt kümeleri bir eğitim kümesi oluşturmak üzere bir araya getirilir. Daha sonra tüm  $k$  denemelerindeki ortalama hata hesaba katılır. Bu yöntem, verilerin nasıl bölündüğü konusunun daha az önemsenmesini sağlamaktadır. Her veri örneği tam olarak bir kez test kümesine girer ve  $k - 1$  defa eğitim kümesinde yer alır. Sonuç olarak tahmin varyansı,  $k$  değeri arttıkça azaltılır. Bu yöntemin dezavantajı ise eğitim algoritmasının sıfırdan  $k$  defa tekrarlanması gerekliliğidir, yani değerlendirme yapmak için  $k$  defa hesaplama gerektirir. Bu yöntemin bir başka türü, verileri rastgele bir test ve eğitim setine  $k$  farklı zamanlara bölmektir. Bunu yapmanın avantajı, her test kümesinin ne kadar büyük olduğunu ve kaç denemenin bağımsız olduğunu seçilebilmesidir [183].

#### **4. ARAŞTIRMA BULGULARI VE TARTIŞMA**

Günümüzde, biyomedikal alanındaki gelişmeler dikkate alındığında, işaret işleme, örüntü tanıma ve makine öğrenmesi tekniklerini kapsayan bilgisayarlı işaret analizi ile bir hastalığa tanı koyma sürecinin iç içe geçmiş durumda olduğu gözlemlenmektedir. Bunun bir sonucu olarak da, bilgisayarlı KTG analizi, KTG'nin sahip olduğu yeniden üretilmemesi, gözlem-içi ve gözlemciler arası yüksek varyasyon ve anlaşmazlık seviyesi gibi başlıca sorunlara çözüm getirmek üzere en umut verici yöntem olarak görülmektedir.

Bu doğrultuda bilimsel olarak KTG'nin sahip olduğu sorunların çözümüne katkı sunmak amacıyla, bu doktora tezi kapsamında, gelişmiş pek çok işaret işleme, örüntü tanıma ve sınıflandırma teknikleri, KTG analizini gerçekleştirmek üzere, geniş ölçekli deneysel çalışmalar kapsamında kullanılmıştır. Yürütülen deneysel çalışmalar ve bu çalışmalara ait deneysel sonuçlar, literatüre dayalı tartışmalarla birlikte bu bölümde açıklanmıştır.

##### **4.1. Sentetik EKG İşaretleri Üzerinde QT Aralığının Belirlenmesi**


KTG işaretleri Şekil 1.4'de gösterildiği gibi dahili veya harici olarak elde edilebilir. Bir Doppler ultrason yardımıyla harici olarak elde edilen FKH işareti, fetüs EKG işaretinin R-R atımların toplanmasıyla oluşturulur. Diğer taraftan, dahili olarak elde edilen bir FKH işareti Şekil 4.1'de gösterildiği gibi karakteristik EKG özelliklerini taşır.

EKG, kardiyovasküler rahatsızlıklara tanı koyma ve değerlendirme amacıyla yaygın olarak kullanılmaktadır. Kalp hızı, ventriküler aksiyon potansiyelinin en önemli belirleyicisidir. Bu nedenle QT aralığı kalp hızıyla ters orantılı olacak şekilde değişmektedir. QT aralığının hesaplanma ve düzeltme gereği bu durumdan kaynaklanmaktadır [121].

Bu deneysel çalışmada, 3 boyutlu dinamik bir model temel alınarak, karakteristiği bilinen sentetik EKG işaretlerinin üretilmesi sağlanmıştır [184]. Çizelge 4.1'de sentetik EKG üretimi için kullanılan parametrelere yer verilmiştir.

Deneysel çalışmada sentetik EKG işaretleri, bir ön işleme sürecinden geçirilmiş ve bu kapsamda TBA ile sinyal üzerindeki gürültü probleminin giderilmesi sağlanmıştır.

Daha sonra işaretin karakteristik noktaları çıkartılmış ve son olarak QT aralıklarının Bazett yöntemiyle belirlenmesi sağlanmıştır.



Şekil 4.1 Bir elektrokardiyografi işaretinin karakteristik özellikleri

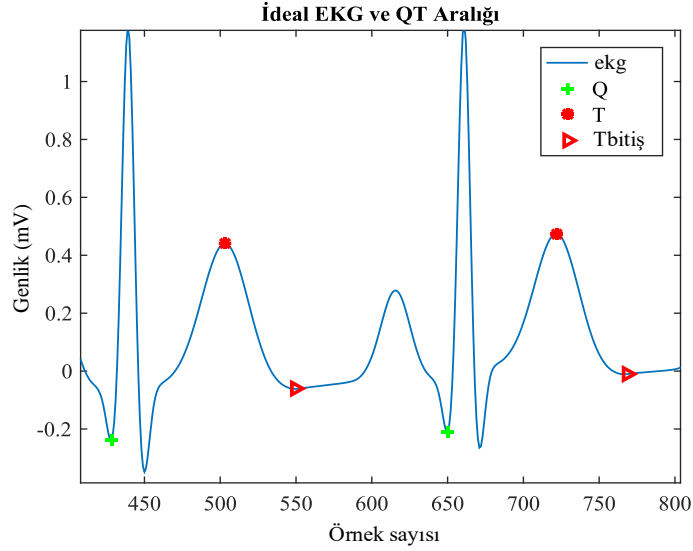
QT aralığı EKG işaretinin analizini gerçekleştirirken morfolojik bir özellik olarak kullanılmaktadır.

Çizelge 4.1 ECGSYN parametreleri ve varsayılan değerleri

<b>SFECG</b>	256	<b>N</b>	256
<b>HR-Std</b>	1	<b>LF/HF</b>	0.5
<b>NOISE</b>	0.02	<b>ti</b>	[-70 -15 0 15 100]
<b>SFINT</b>	256	<b>ai</b>	[1.2 -5 30 -7.5 0.75]
<b>HR-Mean</b>	60	<b>bi</b>	[0.25 0.1 0.1 0.1 0.4]

EKG üzerindeki gürültülerin giderilmesi için alçak-geçiren süzgeçlerin kesim frekansının 15 – 40 Hz arasında olması güvenli olarak kabul edilir. Taban çizgisi dolaşımının giderilmesi için yüksek-geçiren bir süzgecin kesim frekansı ise genellikle 0.05 – 0.5 Hz arasında kullanılmaktadır. Bu kurallara uygun iki süzgecin birleşimi, bu çalışmada bir bant geçiren süzgeç olarak kullanılmıştır. Ventriküler depolarizasyonun başlaması ve ventriküler repolarizasyon sonlanması arasındaki zaman dilimi QT aralığı olarak değerlendirilir. Bir başka ifadeyle QT aralığı QRS kompleksin

başlangıcından T dalgasının sonuna kadar olan uzaklığı kapsar ve kalp hızı ile olan bağımlılığı nedeniyle düzeltilerek bildirilir. Analiz için öncelikle EKG işareti üzerindeki karakteristik noktaların tespit edilmesi sağlanmıştır. Tespit edilen noktalar Şekil 4.2’de gösterilmiştir.



Şekil 4.2 EKG işareti üzerinde Q ve T noktalarının tespit edilmesi

QT aralığının, kalp hızına göre düzeltilmiş ifadesi  $QT_c$  ile gösterilir ve kardiyak repolarizasyonun gecikme ölçümü olarak kullanılabilir.  $QT_c$  kalp hızıyla büyük ölçüde ilişki içerisindedir. Çizelge 4.2’de QT aralığının standart değerlerine yer verilmiştir.

Çizelge 4.2 Standart QT aralığının özellikleri

Özellik	Normal Değer	Nomal Limit
$T_c$ aralığı	400 ms	$\mp 40$ ms
T genliği	0.3 mV	$\mp 0.2$ mV

$$QT_{cBazett} = \frac{QT}{\sqrt{RR}} \quad (4.1)$$


$$QT_{cFridericia} = \frac{QT}{\sqrt[3]{RR}} \quad (4.2)$$

$$QT_{cFramingham} = QT + 0.154 \cdot (1 - RR) \quad (4.3)$$


$$QT_{cHodges} = QT + 1.75(HR - 60) \quad (4.4)$$

Aşağıda düzeltilmiş QT aralığının tahmini için kullanılan yöntemlerin matematiksel formlarına yer verilmiştir.

Bu kapsamda, belirtilen kurallar dahilinde QT aralığının tespit edilmesi sağlanmıştır. Analizin her bir aşamasının görsel olarak kontrol edilebilmesini sağlamak ve parametre değişimlerine bağlı olarak farklı işaretler üzerindeki farklı sonuçları analiz edebilmek için Matlab üzerinde bir kullanıcı arayüzü geliştirilmiştir. Geliştirilen arayüzlere ait ekranlar Şekil 4.3 ve Şekil 4.4 gösterilmiştir.



Şekil 4.3 Sentetik EKG işaretleri üretme ekranı



Şekil 4.4 QT analiz ekranı

## 4.2. Makine Öğrenmesi Tekniklerinin Karşılaştırılması

KTG, doğum öncesi yani gebelik dönemi ve doğum esnasında fetüs durumu hakkında hayati ve önemli bilgilerin elde edilmesini sağlayan bir izleme tekniğidir. Modern obstetrik uygulamalardaki gelişmeler, birçok sağlam ve güvenilir makine öğrenmesi tekniğinin, fetal kalp hızı örüntülerinin sınıflandırılmasına imkan sağlamaktadır. Hastalık teşhisinde makine öğrenme yaklaşımlarının rolü gittikçe zorunlu ve iç içe geçmiş hale gelmektedir. Bu nedenle, bu deneysel çalışmada YSA, DVM, AÖM, RTFA ve RO makine öğrenmesi tekniklerine odaklanılmıştır. Bu deneysel çalışmanın amacı FKH işaretlerinin normal ve patolojik olarak sınıflandırılmasını sağlamak ve bu konuda en verimli makine öğrenmesi tekniğini saptamaktır [185].

Çalışmada açık erişilebilir UCI-KTG veri seti kullanılmıştır. Veri setindeki şüpheli örüntüler ikili sınıflandırmayı sağlamak üzere veri setinden çıkartılmıştır. Toplamda 21 nitelik ve 2 sınıf kullanılmıştır. 1655 normal ve 176 patolojik örüntü çalışma kapsamında dikkate alınmıştır. Tüm özellikler YSA, DVM, AÖM, RTFA ve RO sınıflandırıcılarına 10-katlı çapraz doğrulama yöntemiyle uygulanmıştır.

Sınıflandırıcı performanslarını ölçmek üzere duyarlılık, özgüllük, hassasiyet ve F-ölçüt kriterleri kullanılmıştır. Sınıflandırıcı performanslarına ait sonuçlar Çizelge 4.3’de verilmiştir.

Çizelge 4.3 Makine öğrenmesi tekniklerinin performans sonuçları


<b>Kriterler</b>	<b>YSA</b>	<b>DVM</b>	<b>AÖM</b>	<b>RTFA</b>	<b>RO</b>
Duyarlılık	<b>99.73</b>	91.53	99.34	96.83	99.07
Özgüllük	<b>97.94</b>	20.40	95.30	88.49	93.31
Hassasiyet	<b>99.73</b>	92.26	99.34	96.97	99.06
F-ölçütü	<b>0.997</b>	0.883	0.993	0.969	0.990
Eğitim süresi	2.236	0.720	0.889	<b>0.073</b>	0.332

Çizelge 4.3’de kalın karakterler en yüksek sonuçları vurgulamaktadır. Çizelge 4.3’de de anlaşılacağı üzere en verimli sonuçlara YSA ile erişilmiştir. YSA yapılandırılırken, Levenberg-Marquardt (LM) eğitim algoritması kullanılmıştır. LM öğrenme algoritması Gradient Descend ve Gauss-Newton metotlarının bir kombinasyonundan oluşmaktadır. Bu nedenle LM algoritması pek çok problem için verimli bir çözümü garanti etmektedir [186]. Diğer taraftan, YSA eğitim parametreleriyle özelleştirilebilmektedir. Momentum azalma ve moment artma



faktörleri ve maksimum doğrulama hataları ağ yapılandırılırken sırasıyla 0.15, 12 ve 10 olarak belirlenmiştir. Tanımlanan bu parametrelerle birlikte ağın eğitimi 30 döngünün altında tamamlanmıştır ve eğitim yaklaşık olarak 2,236 saniye sürmüştür. YSA eğitimi diğer makine öğrenmesi tekniklerine göre daha uzun zaman almıştır, bu durum YSA için bir dezavantaj oluşturmaktadır.


DVM yapılandırılırken radyal tabanlı fonksiyon kullanılmış ve maliyet değeri 10000 olarak atanmıştır. Ancak beklenilenin aksine DVM, FKH işaretlerinin sınıflandırılması için YSA kadar başarılı olamamıştır.



Şekil 4.5 AÖM'nin yapılandırılması

Daha önce belirtildiği gibi, AÖM daha iyi genelleştirme performansı, daha düşük hesaplama maliyeti ve özellikle hızlı eğitim yetenekleriyle geleneksel öğrenme algoritmalarının limitlerini aşabilmektedir. Ancak, AÖM bazı dezavantajlara da sahiptir. Örneğin AÖM'nin performansı doğrudan gizli katmandaki düğüm sayısına bağlıdır. Ayrıca, gizli katmandaki düğüm sayısı eğitim kümesinin boyutundan büyük olduğu durumlarda AÖM ezberleme problemiyle karşılaşmaktadır [168]. Bu nedenle bu deneysel çalışma kapsamında AÖM'nin sınıflandırma başarısı ve eğitim süresi

araştırılmıştır. Gizli katmandaki düğüm sayısı kademeli olarak 20’den 1000 kadar artırılmış ve buna bağlı olarak sınıflandırma başarısıyla eğitim süresinin değişimleri gözlemlenmiştir. Şekil 4.5’de AÖM’nin sınıflandırma başarısının gizli katmandaki düğüm sayısının arttırılmasına karşılık nasıl değiştiği gösterilmiştir. Ayrıca şekilden de anlaşılacağı üzere beş farklı aktivasyonun fonksiyonun performansı da değerlendirilmiştir.



Şekil 4.6 AÖM’nin gizli katmandaki düğüm sayısına karşılık performansı

Deneysel sonuçlara göre AÖM’nin gizli katmandaki düğüm sayısı 200’e erişinceye kadar sınıflandırma doğruluğunda genel olarak bir artışın olduğu görülmüştür; ancak bu noktadan sonra sınıflandırma başarısında ciddi bir artış olmamasına karşın eğitim süresinde dikkate değer bir artışın olduğu görülmüştür. Bu nedenle deneysel çalışma için AÖM’nin gizli katmandaki düğüm sayısı 200 olarak ayarlanmıştır. Gizli katmadaki her bir düğüm sayısını arttırılmasından sonra AÖM 50 defa çalıştırılmış. AÖM’nin değerlendirme kriterlerinin ortalama değerleri Çizelge 4.3’de gösterilmiştir. Şekil 4.6’da gizli katmandaki düğüm sayısına karşılık AÖM’nin sınıflandırma doğruluğu ve standart sapma değerlerine bağlı grafiğe yer verilmiştir.

Özetle, deneysel sonuçlara göre kullanılan tüm makine öğrenmesi metotları tahmin edici sonuçlar üretmiştir. Özellikle RTFA ve RO 0,073 ve 0,032 saniye eğitim süresiyle dikkat çekmiştir. Eğitim süresi dışındaki tüm performans metriklerinde YSA üstün gelmiştir. Bu noktada özgüllük değerinin diğer metriklerden daha fazla önem arz ettiğini belirtmek gerekir çünkü özgüllük patolojik örüntülerin tanınma gücüne işaret etmektedir. En yüksek özgüllük değeri ise YSA tarafından sağlanmıştır.

### 4.3. YSA Öğrenme Algoritmalarının Değerlendirilmesi

Pek çok biyofiziksel işaretin sınıflandırılmasında olduğu gibi FKH işaretleri de sınıflandırılırken YSA'nın performansı dikkat çekicidir. Bu nedenle, bu deneysel çalışmada, YSA eğitim algoritmalarının davranışları ve performanslarını karşılaştırmak amacıyla Çizelge 4.4'de gösterilen 12 farklı eğitim algoritması 5 farklı grup altından incelenmiştir. Çalışma kapsamında UCI-KTG veri seti kullanılmıştır ve ikili sınıflandırmayı sağlamak üzere şüpheli örüntüler veri setinden çıkartılmıştır. Sonuç olarak, toplamda 1831 KTG örneği değerlendirilmiştir [187].

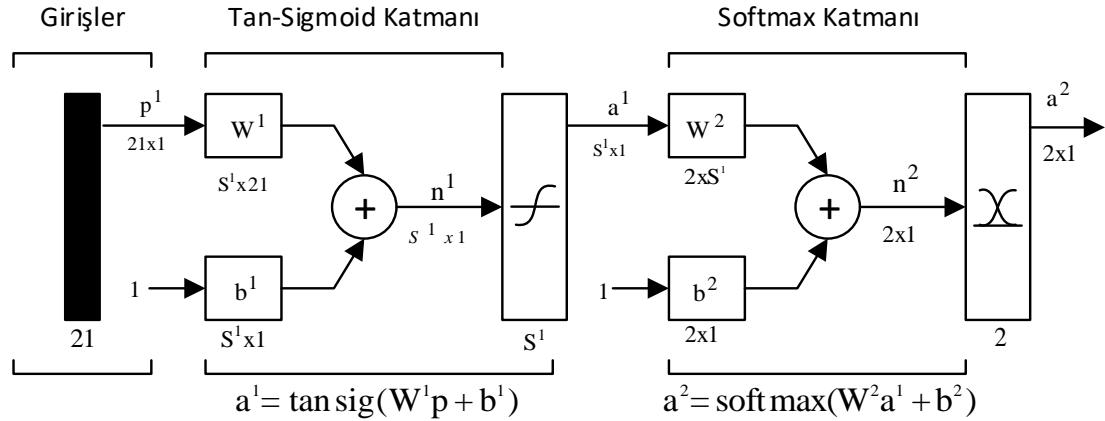
Çizelge 4.4 YSA eğitim algoritmaları

No	Kıs.	Description
1	GD	Gradient descent backpropagation
1	GDA	Gradient descent with adaptive learning rate backpropagation
1	GDM	Gradient descent with momentum backpropagation
1	GDX	Gradient descent with momentum and adaptive learning rate backpropagation
2	RP	Resilient Backpropagation
3	CGF	Conjugate gradient backpropagation with Fletcher-Reeves restarts
3	CGP	Conjugate gradient backpropagation with Polak/Ribière restarts
3	CGB	Conjugate gradient with Powell/Beale restarts
3	SCG	Scaled conjugate gradient backpropagation
4	BFGS	BFGS Quasi-Newton backpropagation
4	OSS	One-step secant backpropagation
5	LM	Levenberg-Marquardt backpropagation

Algoritmaların kısaltması (Kıs) olarak ifade edilmiştir. YSA eğitim algoritmaları 5 farklı grupta toplanmıştır ve bu gruplar sırasıyla (1) Gradient Descent, (2) Resilient Backpropagation, (3) Conjugate Gradient, (4) Quasi-Newton ve (5) Levenberg-Marquardt'dan oluşmaktadır.

Deneysel çalışma sırasında, ağ yapılandırılırken eğitimin 1000 döngü altında ve en geç 5 saniye süreyle gerçekleştirilmesi önkoşul olarak uygulanmıştır. Tüm eğitim algoritmaları için Şekil 4.7'de gösterilen {21, 10, 2} topolojisi uygulanmıştır. Veriler %70 oranında eğitim, %15 oranında doğrulama ve %15 oranında test amacıyla kullanılmıştır. Şekil 4.7'de yapılandırılmış YSA'nın topolojisi gösterilmiştir. Şekilden

de anlaşılacağı üzere giriş katmanının boyutu 21 olarak ayarlanmış ve gizli katmada *tansig* aktivasyon fonksiyonu kullanılmıştır. Gizli katmandaki düğüm sayısı 10 olarak belirlenmiş ve tek bir gizli katman istihdam edilmiştir. Çıkış katmanında pek çok örüntü tanıma ağında kullanıldığı gibi *softmax* aktivasyon fonksiyonu kullanılmıştır. Kayıtlar normal ve patolojik olarak 2 sınıfa ayrılmıştır. Kullanılan eğitim algoritmaları ve grupları Çizelge 4.4’de verilmiştir.



Şekil 4.7 YSA topolojisi

Eğitim algoritmalarının ideal davranışlarını ve ortalama performans değerlerini keşfetmek üzere her bir eğitim algoritması 50 defa çalıştırılmıştır. Algoritmalar genel olarak benzer ve memnun edici sonuçlar üretmiştir. GD ve GDM algoritmalarının her ikisi döngü kısıtlamasına takılmış ve patolojik örüntüleri ayırt etme noktasında herhangi bir varlık gösterememişlerdir. Bu nedenle, bu iki eğitim algoritması deneysel çalışmanın geri kalanında göz ardı edilmiştir. Diğer taraftan, eğitim süresi ve döngü sayısı dikkate alındığında RP algoritmasının hızı dikkat çekmiştir. İyi bir genelleştirme performansının yanında yüksek hızda bir eğitimin gerçekleştirilmesi istendiğinde RP algoritmasının kararlı bir davranış sergileyeceği görülmüştür. Ayrıca, CGA grubundaki algoritmalar oldukça makul sonuçlar üretmiştir. UCI-KTG veri seti üzerinde CGA grubundaki algoritmalar QNA grubundaki algoritmalarla göre daha iyi sonuçlar üretmiştir.

En iyi ve en verimli sonuçlara minimum döngü ve eğitim süresiyle LM eğitim algoritmasıyla ulaşılmıştır. Karşılaştırma eğitim süresi, ortalama kare hata (OKH) ve ağırlık öğrenme eğim karakterlerine göre gerçekleştirilmiştir. En düşük OKH’ya LM ile ulaşılmıştır. Buna karşın, LM algoritmasının ihtiyaç duyduğu bellek gereksiniminin

diğer algoritmalarından fazla olduğu unutulmamalıdır. Bu nedenle, LM algoritması kullanan ağı eğitim süresi, sistem kaynaklarına ve özellik setinin boyutuna bağlı olarak artabilmektedir. Hafıza kullanımıyla alakalı problem oluşturabilecek bir durum varsa öncelikle RP algoritması tercih edilebilir. Daha sonra, CGA grubu ve OSS algoritması kullanılabilir. Deneysel çalışma kapsamında, QNA grubu algoritmalarının en yavaş algoritmalar olduğu gözlemlenmiştir.

Eğitim algoritmalarının performansı değerlendirmek üzere doğruluk, duyarlılık, özgüllük, kalite endeksi ve eğitim süreleri dikkate alınmıştır. Buna bağlı olarak Çizelge 4.5’deki sonuçlar elde edilmiştir.


Şekil 4.8’de 50 farklı eğitim periyodu sonucunda YSA eğitim algoritmalarının başarımı (a), eğitim süresi (b), döngü sayıları (c) ve OKH değerlerinin (d) kutu şeklinde çizdirilmesi sağlanmıştır. Aynı grupta yer alan algoritmalar aynı renkle ile gösterilmiştir. Her bir kutudaki daire simgesi ortanca değeri göstermektedir. Her bir kutunun üst kısmı en yüksek değeri alt kısmı ise en düşük değeri göstermektedir. Şekilde en uzun eğitim süresine karşılık en yüksek başarımın LM algoritmasıyla elde edildiği açıktır.

Şekil 4.9’da ise tüm eğitim algoritmalarının performans değerleri (a) ve eğitim eğrisinin karakteristiği (b) döngü sayılarına bağlı olarak verilmiştir. Aynı grupta yer alan algoritmalar aynı renkle gösterilmiştir. Şekilde görüldüğü gibi LM algoritması en hızlı yakınsamayı göstermiş ve ortalama 23 döngü içerisinde ağ eğitimi tamamlamıştır. Benzer şekilde CGA grubu algoritmalarının da ağ eğitimi için oldukça hızlı bir şekilde yakınsadığı görülmüştür.


Çizelge 4.5 YSA eğitim algoritmaları performans sonuçları

Eğitim Algoritmaları	Eğitim Süresi	Test Süresi	OKH	Döngü	DĞR	DYR	ÖZG	KE
GD	1.3038	0.0087	0.0223	1000	98.58	98.84	NaN	NaN
GDA	1.3126	0.0095	0.0184	1000	98.79	99.11	95.70	97.37
GDM	1.3020	0.0096	0.1060	1000	91.80	91.82	NaN	NaN
GDX	1.3247	0.0095	0.0282	1000	98.76	99.06	95.72	97.37
RP	0.5201	0.0096	0.0721	368.9	98.68	99.08	94.63	96.80
CGF	1.5593	0.0097	0.1037	392.1	<b>98.92</b>	<b>99.21</b>	<b>96.10</b>	<b>97.63</b>
CGP	1.1451	0.0095	0.1273	262.6	98.65	99.05	94.75	96.85
CGB	1.1043	0.0095	0.1236	250.8	98.63	99.10	94.19	96.59
SCG	0.4889	0.0096	0.0793	215.6	98.73	99.15	94.75	96.90
BFGS	3.8062	0.0093	0.2492	285.1	98.30	98.95	91.81	85.29
OSS	4.3929	0.0094	0.0528	1000	98.78	99.08	95.92	97.47
LM	<b>0.4219</b>	0.0101	<b>0.0128</b>	<b>23.86</b>	98.63	99.11	93.70	96.34

Sonuç olarak, tüm YSA algoritmalarının FKH işaretlerinin sınıflandırmak üzere oldukça iyi sonuçlar ürettiği görülmüştür. Ağ eğitimi için geçen süre dikkate alınmadığında en iyi sınıflandırma doğruluğuna CGF algoritmasıyla erişilmiştir. Diğer taraftan, sınıflandırma doğruluğu ve ağ eğitimi için geçen sürenin her ikisi de dikkate alındığında LM algoritmasının daha başarılı olduğu görülmüştür. Bu noktada, küçük veri setlerinin eğitiminde ekstrem bir hıza ve yüksek doğruluğa ihtiyaç duyulması halinde LM algoritmasının uygun bir algoritma tercihi olduğu bir kez daha doğrulanmıştır. Ancak, LM algoritmasının yüksek bellek kapasitesi gerektirdiği unutmamalıdır. Bu durum, yüksek boyutlu veri setlerinde verimsizliğe neden olabilir. Buna karşın CGA grubu ve RP algoritmasının kullanılması bu noktada daha çok fayda getirebilir ve daha verimli olabilir.




Şekil 4.8 YSA eğitim algoritmaları performans sonuçları



Şekil 4.9 Eğitim algoritmalarının performans ve eğim karakteristikleri

Bölüm 3.11.2’de AİK eğrisinin karakteristik özellikleri ifade edilmişti. YSA eğitim algoritmalarından en iyi genelleştirme performansı gösteren LM algoritmasının AİK eğrilerine Şekil 4.10’da yer verilmiştir. Şekilde görüldüğü gibi LM algoritması öncelikle patolojik örüntüleri, daha sonra normal örüntüleri ve son olarak da şüpheli örüntüleri başarılı bir şekilde sınıflandırmıştır. AİK eğrisinin altında kalan alanı büyük olan ya da (0,1) noktasına en fazla yaklaşan sınıflandırıcı daha yüksek genelleştirme performansı sergilemektedir.

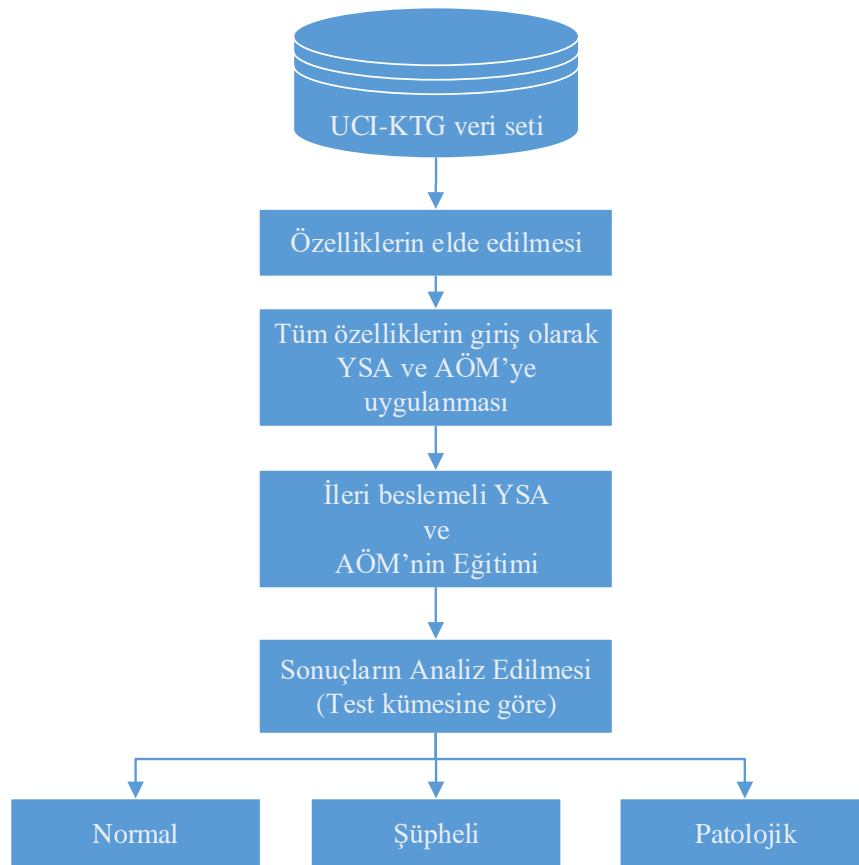


Şekil 4.10 LM algoritması AİK eğrileri

#### 4.4. YSA ve AÖM ile KTG Analizi

Bu deneysel çalışmada, YSA ve AÖM makine öğrenmesi yöntemlerinin KTG işaretlerinin normal, şüpheli ve patolojik olarak sınıflandırılması üzerindeki başarımları değerlendirilmiştir [188]. UCI-KTG veri setindeki 2126 adet KTG örneğinin tamamı çalışma kapsamında kullanılmıştır.

Şekil 4.11’de adım adım analizin aşamaları gösterilmiştir. İşaretler veri setinden okunduktan sonra, yapılandırılmış YSA ve AÖM sınıflandırıcılarına girdi olarak uygulanmıştır ve sınıflandırıcı başarımları doğruluk, duyarlılık ve özgüllük metriklerine bağlı olarak değerlendirilmiştir.



Şekil 4.11 Adım adım ağ eğitimi

Analiz, Intel Xeon CPU E5-2687W v3 3.10 GHz işlemcili ve 32 GB belleği olan bir iş istasyonu üzerinde gerçekleştirilmiştir. Hesaplama ortamı için MATLAB® (2015a) kullanılmıştır.

YSA yapılandırılırken gizli katmandaki düğüm sayısı 10 – 25 arasında kademeli olarak artırılmış ve deneysel çalışmalar neticesinde gizli katmandaki düğüm sayısı 15 olarak ayarlanmıştır. Ağ eğitimi, 100 döngünün altında LM algoritmasıyla



gerçekleştirilmiştir. Bunun dışında RP algoritmasının da çok verimli sonuçlar ürettiği görülmüştür. Bu noktada yüksek sınıflandırma başarısıyla birlikte ağ eğitimi oldukça hızlı bir şekilde gerçekleşmiştir.

AÖM yapılandırılması için YSA'ya benzer şekilde öncelikle gizli katmandaki düğüm sayısına odaklanılmıştır. Gizli katmandaki düğüm sayısı 100 – 1000 arasında kademeli olarak değiştirilmiş ve aynı zamanda 5 farklı aktivasyon fonksiyonunun değerlendirilmesi sağlanmıştır. Gizli katmandaki düğüm sayısı 900'e yaklaştığında AÖM'nin eğitim süresi YSA'nın eğitim süresine yaklaşmıştır; buna karşın sınıflandırma doğruluğunda ciddi bir artışın olduğu görülmemiştir. Bu nedenle sigmoid aktivasyonu fonksiyonu ile birlikte gizli katmandaki düğüm sayısı 200 olarak atanmıştır.

Ağ sonuçları analiz edilirken verilerin %85'i eğitim %5'i doğrulama ve %10'nu test için kullanılmıştır. Elde edilen performans sonuçlarına Çizelge 4.6'da yer verilmiştir. YSA ve AÖM'nin karşılaştırmalı performans sonuçları da Çizelge 4.7'de gösterilmiştir.

AÖM YSA'ya göre ağ eğitim süresi ve performans metrikleri açısından daha iyi sonuçlar üretmiştir.

Çizelge 4.6 YSA ait performans sonuçları

Metrik	Normal (%)	Şüpheli (%)	Patolojik (%)
<b>DĞR</b>	91,31	87,40	96,83
<b>DUY</b>	95,73	78,04	95,00
<b>ÖZG</b>	95,32	81,50	95,17

Çizelge 4.7 YSA ve AÖM sonuçlarının karşılaştırılması

Ağlar	Eğitim Zamanı (s)	Test Zamanı (s)	Doğruluk Eğitim (%)	Doğruluk Test (%)
<b>YSA</b>	7,5482	0,0863	94,14	91,84
<b>AÖM</b>	0,1862	0,0238	97,68	93,42

#### 4.5. Eş Oluşum Matrisi ve YSA'ya Dayalı FKH Analizi


KTG işaretlerini karakterize eden özelliklerin ortaya çıkartılmasını sağlamak üzere morfolojik [18], [54], [126], doğrusal ve doğrusal olmayan [68], [76], [82], [136] ve spektral [91], [100] alanlardan elde edilen pek çok istatistiksel endeks FKH analizi için hali hazırda kullanılmaktadır. Bu deneysel çalışmada, FKH analizi için yaygın olarak kullanılan bu özelliklere ilaveten, frekansın [0-1] Hz aralığında normalize edildiği ve KZFD tarafından sağlanan spektral imgelerin kullanılması önerilmiştir. Bu amaç doğrultusunda spektral imgeler 8 bitlik gri seviyeleri imgelere dönüştürülerek, her bir imgenin popüler doku tanımlayıcılarında biri olan GSEM ile karakterize edilmesi hedeflenmiştir. GSEM gri imgeler için kontrast, korelasyon, enerji ve homojenlik gibi istatistiksel özelliklerin elde edilebilmesini sağlamaktadır [151], [169]. Deneysel çalışmada, ham KTG işaretlerinden oluşan CTU-UHB veri tabanından eksik atımların en az olduğu, bir başka ifadeyle önışleme sürecinden en az etkilenecek 60 normal ve 40 hipoksik olmak üzere toplam 100 KTG örneği rastgele seçilmiştir. Daha sonra seçilen tüm işaretler, literatüre dayalı bir önışleme sürecinden geçirilmiş ve gürültü sorunu giderilmiştir. Böylelikle tüm işaretlerin analize hazır hale getirilmesi sağlanmıştır. Daha sonra, farklı alanlardan elde edilen ve Çizelge 4.8'de belirtilen toplam 18 adet özellik elde edilmiştir.

Çizelge 4.8 GSEM dayalı analiz için elde edilen özellik seti

Özellik Grubu	Özellikler
<b>Morfolojik</b>	(1) Temel kalp hızı (2) Hızlanma örüntülerinin sayısı (3) Yavaşlama örüntülerinin sayısı
<b>İstatistiksel</b>	(4) Medyan (5) Standart sapma (6) Standart hata (7) Maksimum atım (8) Minimum atım (9) Maksimum ve minimum atım aralığı (10) Ortalama mutlak sapma (11) Medyan mutlak sapma (12) Varyans
<b>Spektral</b>	(13) Ortalama frekans (14) Spektral bant gücü
<b>GSEM</b>	(15) Kontrast (16) Korelasyon (17) Enerji (18) Homojenlik

Morfolojik, istatistiksel ve spektral alandan elde edilen özellikler çalışma kapsamında geleneksel özellikler olarak kabul edilmiştir çünkü bu özellikler pek çok çalışmada zaten kullanılmaktadırlar. Sadece 14 adet özelliği kapsayan geleneksel

özellikler, sadece GSEM özellikleri ve geleneksel özelliklere ile birlikte GSEM tarafından sağlanan özelliklerin bir kombinasyonu, yani üç farklı özellik seti YSA sınıflandırıcısına ayrı ayrı uygulanmıştır. Elde edilen tüm özellikleri kapsayan özellik seti iki-boyutlu TBA eksine Şekil 4.12’de görüldüğü gibi yansıtılmıştır.



Şekil 4.12 Veri setinin iki boyutlu TBA eksenine yansıtılması

YSA yapılandırılırken özellik sayısı  $x$  ile gösterilmek üzere  $\{x, [10,5], 2\}$  ağ topolojisi kullanılmıştır. Düşük bellek gereksinimi ve hızlı yakınsama özelliği nedeniyle “*Conjugate gradient with Powell/Beale restarts (traincgb)*” eğitim algoritması 5-katlı çapraz doğrulama ile birlikte kullanılmıştır.

Çizelge 4.9 GSEM ve YSA’ya dayalı performans sonuçları

Özellik seti	DĞR	DUY	ÖZG	KE
Geleneksel	84.0	86.3	81.2	83.8
GSEM	70.0	71.2	67.2	69.2
Geleneksel + GSEM	87.0	88.7	85.1	86.9

YSA başarımını ölçmek üzere doğruluk, duyarlılık, özgüllük ve kalite endeksi metrikleri kullanılmıştır. Çizelge 4.9 GSEM ve YSA'ya dayalı performans sonuçlarına yer verilmiştir. Çizelge 4.9'da görüldüğü gibi geleneksel özellikler sınıflandırıcıya doğrudan uygulandığında oldukça iyi sonuçlar elde edilmiştir, aksine GSEM özellikleri geleneksel olarak kullanılan özelliklere göre nispeten kabul edilebilir sonuçlara erişilmesini sağlamıştır. Ancak geleneksel özellikler ile GSEM özelliklerinin bir kombinasyonunun sınıflandırıcıya uygulanması durumunda en yüksek başarımların elde edilmesi sağlanmıştır [152].

#### **4.6. Doğrusal ve Doğrusal Olmayan Özelliklere Dayalı FKH Analizi**

Doğum, gebelik dönemi ile kıyaslandığında çok daha kısa süren bir süreç olmasına rağmen, fetüs için risk oluşturan pek çok olay bu aşamada ortaya çıkmaktadır. Bu deneysel çalışmada, FKH işaretlerinin doğrusal ve doğrusal olmayan özelliklerine bağlı olarak FKH analizi, doğumun birinci ve ikinci aşaması için ayrı ayrı değerlendirilmiştir [189].

Deneysel çalışmada, CTU-UHB veri tabanında bulunan 552 kaydın tamamı değerlendirilmiştir. Doğumun birinci aşaması toplamda 60 dakikalık kayıtlardan oluşmaktadır, ancak bu aşama, 30 dakikalık kayıtlardan oluşan iki ayrı parça halinde incelenirken, doğumun ikinci aşaması 30 dakikalık kayıtlardan oluşan tek bir parça halinde incelenmiştir. Doğumun ilk aşaması, aktif itmenin henüz başlamadığı bölümü temsil ederken; doğumun ikinci aşaması aktif itmenin olduğu ikinci aşamayı temsil etmektedir.

Veri tabanındaki tüm kayıtlar 9 deneyimli uzman tarafından, her kayıt Şekil 3.1'de gösterildiği gibi 4 parçaya ayrılarak etiketlenmiştir. Kayıtların 1. ve 2. parçası doğumun birinci aşamasını, 3. parçası doğumun ikinci aşamasını ve 4. parçası doğum sonuçlarına göre yapılan etiketlemeleri göstermektedir. Çizelge 4.10'da örnek bir KTG işaretinin uzmanlar tarafından nasıl etiketlendiği gösterilmiştir.

Daha önce belirtildiği gibi KTG işaretlerinin yorumunda gözlemciler arası ve hatta gözlemciler içi yorumlama farklılığı ve anlaşmazlık seviyesi yüksektir [24], [25], [190]. Örneğin, 6 numaralı uzman Çizelge 4.10'da gösterildiği gibi örnek kaydın 1. parçası için hem normal hem de şüpheli demiştir; bu durum gözlemciler içi farklılığa işaret etmektedir. Benzer şekilde, 1, 2, 3, 4, 5, 6 ve 8 numaralı uzmanlar kaydın 1.

parçası için şüpheli etiketi koyarken; 7 numaralı uzman kaydı normal olarak, 9 numaralı uzman ise patolojik olarak değerlendirmiştir. Bu da gözlemciler arası anlaşmazlığı göstermek için uygun bir örnektir. Denetimli öğrenme yaklaşımının gerektirdiği kayıtların etiketlenmesini gerçekleştirmek için uzmanların çoğunluğunun oylaması dikkate alınmıştır. Çizelge 4.10’da verilen örnek kaydın 1. parçası, uzmanlar tarafından çoğunlukla şüpheli olarak etiklendiği için kaydın bu parçası şüpheli olarak etiketlenmiştir.

Çizelge 4.10 Örnek bir kaydın uzmanlar tarafından etiketlenmesi

Doğum öncesi dönemde örnek bir FKH kaydının değerlendirilmesi				Doğum Sonucu
Uzman Id	Parça 1	Parça 2	Parça 3	Parça 4
1	2	3	-1	2
2	2	3	-1	2
3	2	3	-1	-1
4	2	3	-1	-1
4	2	3	-1	-1
4	2	3	-1	-1
5	2	3	-1	2
6	1	3	-1	-1
6	2	3	-1	2
7	1	2	-1	2
8	2	3	-1	-1
9	3	3	-1	2

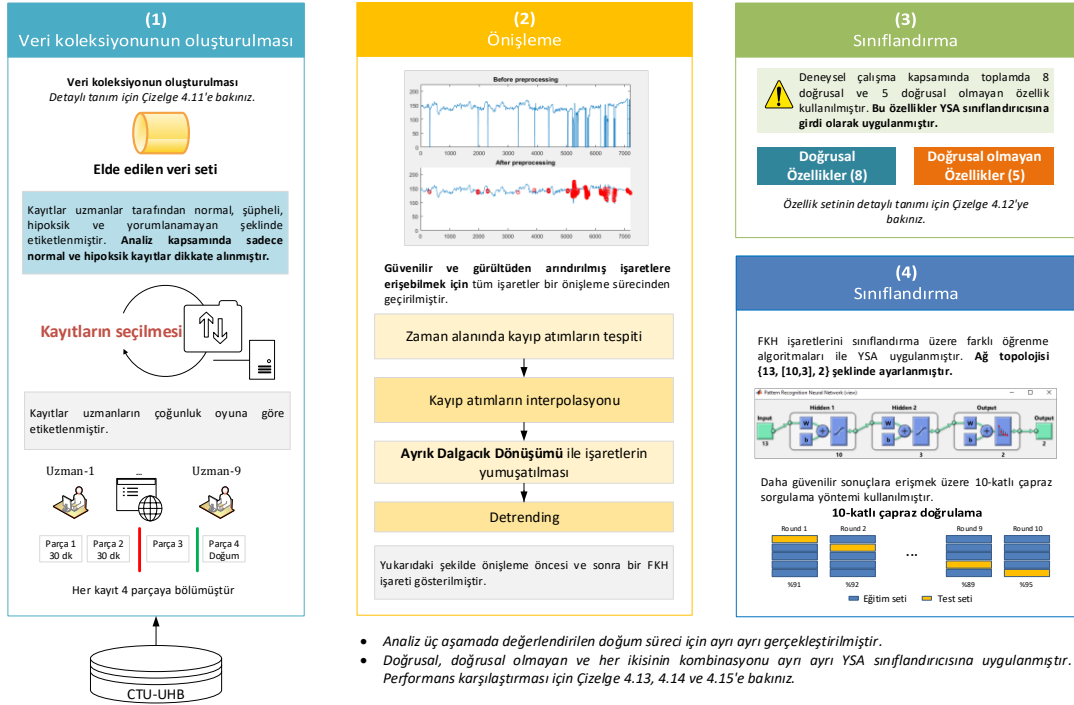
Kayıtların 1 – 3. parçaları arasında 1 normal, 2 şüpheli, 3 patolojik örüntüleri ve -1 ise yorumlanamayan örüntüleri tanımlamak için kullanılmıştır. 4. parçada ise 1 hipoksi durumunun olmadığını, 2 hafif hipoksi durumunu, 3 şiddetli hipoksi durumunu ve -1 yorumlanamama durumunu ifade etmek üzere kullanılmıştır.

Kayıtlar uzmanların çoğunluk oyuna göre yukarıda ifade edilen şekilde etiketlenmiş ve doğum aşaması boyunca kayıtların dağılımı Çizelge 4.11’deki gibi gerçekleşmiştir. Burada kayıtların sayısı etiketlerine göre normal (N), şüpheli (Ş), patolojik (P) ve yorumlanamayan (Y) şeklinde gösterilmiştir.


Çizelge 4.11 Doğum aşamaları boyunca kayıtların dağılımı

Analiz aşamaları	N	Ş	P	Y
<b>I</b>	272	230	44	6
<b>II</b>	195	267	86	4
<b>III</b>	106	160	71	215


Deneyisel çalışma kapsamında, izlenen analiz aşamaları Şekil 4.13’de gösterilmiştir. Doğrusal ve doğrusal olmayan alanlardan elde edilen özellikler ise Çizelge 4.12’de verilmiştir.



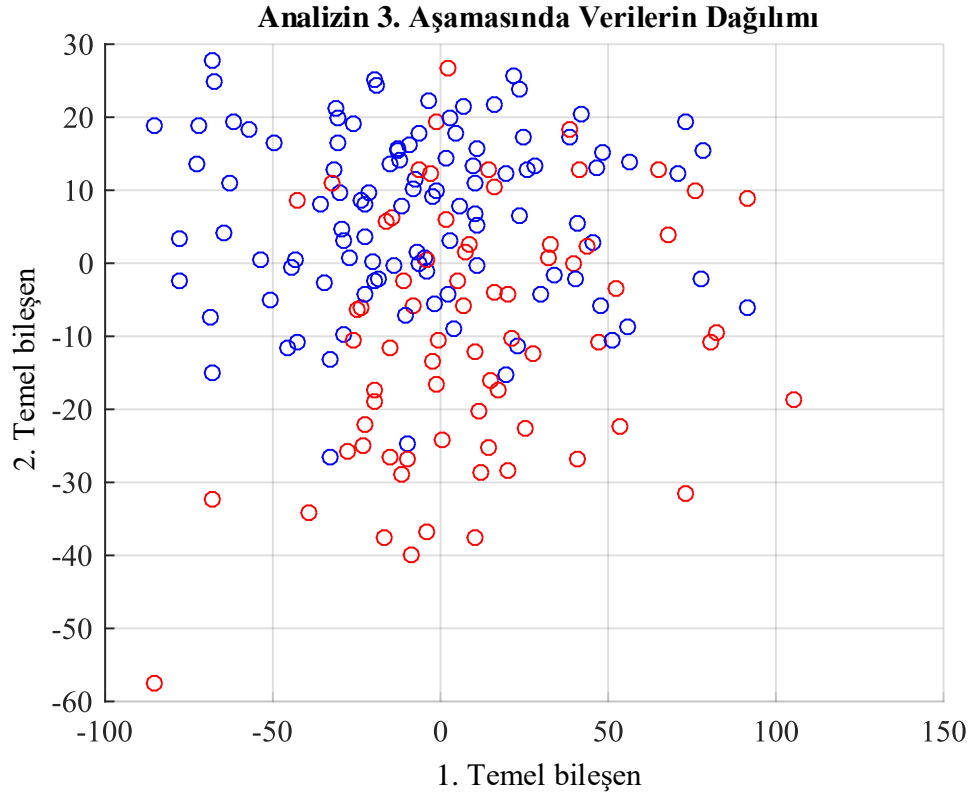
Şekil 4.13 Doğum aşamaları boyunca analizin blok şeması



Şekil 4.14 Doğum aşamaları boyunca verilerin dağılımı, analizin 1. aşaması



Şekil 4.15 Doğum aşamaları boyunca verilerin dağılımı, analizin 2. aşaması



Şekil 4.16 Doğum aşamaları boyunca verilerin dağılımı, analizin 3. aşaması

İkili sınıflandırmayı sağlamak üzere şüpheli ve patolojik örüntülerin tamamı veri setinin dışında bırakılmıştır. Verilerin, analizin üç aşaması boyunca dağılımına sırasıyla Şekil 4.14, Şekil 4.15 ve Şekil 4.16’da yer verilmiştir.

Çizelge 4.12 Doğum aşamaları boyunca kullanılan özellikler

Özellik	Açıklama
$TKH$	Temel kalp hızı
$TKH_{\sigma}$	Temel kalp hızının standart sapması
$UDD$	Uzun dönemli değişkenlik
$\Delta$	Delta
$KZD$	Kısa zamanlı değişkenlik
$AE$	Aralık endeksi
$\frac{ACC}{N}$	Hızlanma örüntülerinin işaret uzunluğuna oranı
$\frac{DCC}{N}$	Yavaşlama örüntülerinin işaret uzunluğuna oranı
$YaEn(2,0.15)$	Yaklaşım entropi
$YaEn(2,0.20)$	Yaklaşım entropi
$ÖrnEn(2,0.15)$	Örnek entropi
$ÖrnEn(2,0.20)$	Örnek entropi
$LZK$	Lempel Ziv karmaşası

YSA yapılandırması için “*Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts (CGF) ve Levenberg-Marquardt backpropagation (LM)*” eğitim algoritmaları, {13, [10,3], 2} topolojisiyle kullanılmıştır.

Çizelge 4.13 Sadece doğrusal özellikler ile elde edilen sonuçlar

Analiz	DĞR	DUY	ÖZG	KE
<b>I</b>	<b>91,73</b>	94,58	71,83	81,14
<b>II</b>	82,56	87,17	72,34	79,10
<b>III</b>	72,91	77,70	69,17	72,65

Doğrusal ve doğrusal olmayan toplam 13 özellikten oluşan veri seti üç farklı şekilde YSA sınıflandırıcısına uygulanmıştır. Özellik seti sadece doğrusal, sadece doğrusal olmayan ve bu ikisinin kombinasyonu şeklinde ayrı ayrı değerlendirilmiştir.



Elde edilen sonuçlar sırasıyla Çizelge 4.13, Çizelge 4.14 ve Çizelge 4.15’de verilmiştir.

Çizelge 4.14 Sadece doğrusal olmayan özellikler ile elde edilen sonuçlar

<b>Analiz</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>KE</b>
<b>I</b>	<b>87,61</b>	92,40	59,68	65,34
<b>II</b>	71,82	79,14	54,06	63,73
<b>III</b>	55,23	62,10	45,65	52,35

Çizelge 4.15 Doğrusal ve doğrusal olmayan özellikler ile elde edilen sonuçlar

<b>Analiz</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>KE</b>
<b>I</b>	<b>92,40</b>	95,89	74,75	83,66
<b>II</b>	83,29	87,06	75,90	80,92
<b>III</b>	79,22	85,87	72,73	77,91

Sınıflandırma performansını ölçmek üzere hata matrisi kullanılmıştır. Hata matrisinden türetilen doğruluk, duyarlılık, özgüllük ve kalite endeksi performans metrikleri olarak kullanılmıştır. Ağın performansında yanlılığı engellemek ve sonuçlar üzerindeki varyasyonu azaltmak amacıyla 10-katlı çapraz doğrulama sınıflandırma aşamasında kullanılmıştır.

Deneysel sonuçlara göre, en yüksek sınıflandırma başarısına tüm özelliklerin kullanılmasıyla erişilmiştir. Bu başarıım değeri sırasıyla analizin 3 aşaması için %92,40, %83,29 ve %79,22 olarak elde edilmiştir.

Doğrusal olmayan özellikler en yüksek değişimi doğumun ikinci aşamasında gösterirler. Bu aşamada FKH örüntülerinin değişimleri ciddi derecede yüksektir. Bu durumun bir sonucu olarak, doğrusal olmayan özelliklerin kullanımı en fazla bu aşamayı etkilemiştir. Sadece doğrusal özellikler kullanılarak elde edilen %72,91 doğruluk oranı, doğumun üçüncü aşamasında doğrusal olmayan özelliklerin kullanımı ile birlikte %79,22’ye yükseltilmiştir.

#### **4.7. BFDA ve AÖM’ye Dayalı FKH Analizi**

Bu deneysel çalışmada, CTU-UHB veri tabanındaki kayıtların ilk 30 dakikalık bölümlerine odaklanılmıştır. İkili sınıflandırmayı sağlamak üzere, toplam 552 kayıttan oluşan veri setinden uzmanlar tarafından “şüpheli (230 adet)” ve “yorumlanamayan (6

adet)” şekilde etiketlenen işaretler veri setinden çıkarılmıştır. Sonuçta, 272 adet normal, 44 adet hipoksik örnekten oluşan bir seti elde edilmiştir. Verilerin dengeli bir şekilde dağılmasını sağlamak üzere normal olarak etiketlenen kayıtlar arasından kayıp atım değerleri en düşük olan 44 kayıt seçilmiş, sonuç olarak analiz 44 normal ve 44 hipoksik örnekten oluşan toplam 88 kayıt üzerinde gerçekleştirilmesi sağlanmıştır.

Her bir FKH işaretini doğru bir şekilde tanımlamak üzere morfolojik, doğrusal, doğrusal olmayan, frekans ve doku alanlarından özellikler seçilmiş ve elde edilen özellikler Çizelge 4.16’da gösterilmiştir.

Çizelge 4.16 BFDA ve AÖM’ye dayalı özellik seti

Özellik Grubu	Açıklama
Morfolojik (I)	(1) TKH, (2) ACC, (3) DCC
Doğrusal (II)	(4) $FKH_{ort}$ , (5) $FKH_{ss}$ , (6) $KDD$ , (7) $\Delta$ , (8) $AE$
Doğrusal Olmayan (III)	(9) LZK
Frekans (IV)	(10) $\mathcal{C}DF$ , (11) $DF$ , (12) $OF$ , (13) $YF$ (14) $DF/YF$ , (15) $DF/(OF+YF)$
BFDA (V)	(16) – (36) istatistiksel özellikler ( $n_t = 4$ )

Sınıflandırıcı performansını ölçmek üzere çalışmada hata matrisi kullanılmıştır. Hata matrisi, sırasıyla doğru bir şekilde tahmin edilen normal ve hipoksik fetüslerin sayılarını temsil eden DP ve DN ile birlikte; yine sırasıyla normal ve hipoksik fetüslerin yanlış bir şekilde tahmin edilme sayılarını temsil eden YP ve YN prognostik endekslerinden oluşmaktadır [189]. Hata matrisi aynı zamanda, sınıflandırıcı için doğruluk (DOĞ), duyarlılık (DUY) ve özgüllük (ÖZG) gibi çeşitli performans kriterlerinin hesaplanmasına da olanak tanımaktadır.

BFDA doku analizini gerçekleştirmek için gri ölçekli bir imgeye ihtiyaç duymaktadır. Bu nedenle KZFD kullanılarak FKH işaretinin spektrogramı elde edilmiş ve daha sonra bu spektrogram 8 bitlik gri resme çevrilmiştir [152]. BFDA kullanılırken, deneysel teşebbüsler neticesinde özellik setinin boyutu 4 olarak belirlenip ( $n_t = 4$ ), BFDA’nın 21 adet özellik üretmesi sağlanmıştır. AÖM yapılandırılırken gizli katmandaki düğüm sayısı, 10 – 60 arasında kademeli olarak değiştirilmiş ve farklı aktivasyon fonksiyonları denenmiştir. Sonuç olarak 35 gizli düğüm ile sigmoid aktivasyon fonksiyonu kullanılarak ağ yapılandırılmıştır.

Sınıflandırıcı performansını ölçmek üzere beş farklı özellik seti kullanılmıştır. Sadece morfolojik özellikler kullanılarak elde edilen özellik seti (I), öncelikle tek başına AÖM sınıflandırıcısına girdi olarak uygulanmıştır. Daha sonra, sırasıyla doğrusal (II), doğrusal olmayan (III), frekans (IV) ve BFDA (V) özellikleri mevcut özellik setlerine eklenerek, özellik setlerinin sistematik bir şekilde genişletilmesi sağlanmıştır.

Frekans alanında ÇDF, DF, OF, YF, DF/LF ve DF/(OF+YF) olarak tanımlanan toplam 6 endeks dikkate alınmıştır. Bu özellikleri elde edebilmek için öncelikle işaretlerin Welch güç spektral yoğunluk tahmini gerçekleştirilmiştir. Welch güç spektral yoğunluk tahmini yapılırken örnekleme frekansı 4, Hamming pencere ve uzunluğu 256, örtüşme oranı 128 ve ayrık Fourier dönüşüm nokta sayısı 256 olarak kullanılmıştır. Sonuç olarak, Çizelge 4.17’de tanımlı endekslerin ortalama ve standart sapma değerleri verilmiştir.

Çizelge 4.17 Frekans alanında elde edilen özellikler

ÇDF	DF	OF	YF	DF/LF	DF/(OF+YF)
19846±4025	0.0029±31.07	0.0003±2.71	0.0000±0.26	0.0152±82.35	0.0011±5.59

\* Bant gücü ortalama değeri ± standart sapma

Çizelge 4.18 AÖM sınıflandırma sonuçları

Özellik Seti	DĞR (%)	DUY (%)	ÖZG (%)
I	68,39±4,89	74,31±4,29	66,49±4,54
II	68,33±4,76	71,97±4,81	69,99±4,72
III	70,42±3,48	72,75±3,61	70,20±3,84
IV	76,43±3,63	79,28±3,44	76,06±3,50
V	79,65±3,18	80,95±3,25	79,92±3,24

\* Başarım değeri ± standart sapma

Her özellik seti ayrı ayrı AÖM sınıflandırıcısına girdi olarak uygulanırken, yanlılığı engellemek ve daha objektif sonuçlar elde etmek için 100 farklı iterasyonun her birinde 5-katlı çapraz doğrulama metodu istihdam edilmiş ve elde edilen sonuçların ortalama değerleri alınarak AÖM için sınıflandırma sonuçları Çizelge 4.18’de gibi elde edilmiştir.

Kliniksel açıdan tanıyı destekleyen temel morfolojik özellikler, spektral alandan dört farklı frekans bandının güçleri ve Lempel Ziv karmaşıklığı FKH işaretlerini tanımlamak için kullanılmıştır. Ayrıca, FKH işaretlerinin daha iyi tanımlanmasını sağlamak üzere BFDA kullanılması önerilmiştir. BFDA tabanlı özelliklerin kullanımı ile sınıflandırma performansında tatmin edici sonuçlar elde edilmiş ve BFDA ile sınıflandırma doğruluğunun arttırılabileceği ispatlanmıştır. Elde edilen özellik seti, 5-katlı çapraz doğrulama yöntemiyle birlikte bir aşırı öğrenme (AÖM) makinasına girdi olarak uygulanmıştır. Deneysel sonuçlara göre, %79,65 doğruluk, %79,92 özgüllük ve %80,95 duyarlılık elde edilmiştir. Sonuç olarak, BFDA'nın normal ve hipoksik fetüsleri ayırmak için kullanışlı özellikler sunduğu ispatlanmıştır.

#### 4.8. Dalgacık Dönüşümüyle KTG İşaretlerinin Sınıflandırılması

Bu deneysel çalışmada, fetüs için hayati bilgiler taşıyan FKH işaretlerinin Haar (*haar*), Daubechies (*db5*) ve Symlets (*sym5*) dalgacık aileleriyle 1. ve 12. seviyeler arasında analiz edilmesi sağlanmıştır. FKH işaretinden hem geleneksel olarak kullanılan morfolojik ve doğrusal özellikler elde edilirken hem de dalgacık bileşenlerinin her birinden  $p$ -normu, Frobenius normu, sonsuzluk ve negatif sonsuzluk normu elde edilip, istatistiksel olarak sınıflandırmayı desteklemek üzere birer özellik olarak kullanılmıştır. Elde edilen özellikler k-EK ve YSA sınıflandırıcılarına normal ve hipoksik fetüsleri ayırt etme amacıyla girdi olarak uygulanmıştır. Sınıflandırıcı performanslarını ölçmek üzere hata matrisi kullanılmıştır. Hata matrisinden doğruluk, duyarlılık, özgüllük, pozitif tahmin oranı ve negatif tahmin oranı başarımlar elde edilmiştir.

Özellik seti sınıflandırıcılara girdi olarak uygulanmadan önce, tüm değerler her bir satırdaki maksimum ve minimum değerlere bağlı olarak  $[-1, +1]$  aralığına çekilmiştir. k-EK sınıflandırıcısı için komşuluk sayısı 7 olarak belirlenmiştir. YSA yapılandırılırken, deneysel çalışmalar neticesinde gizli katmanlar sırasıyla 25, 15 ve 2 nörondan oluşacak şekilde yapılandırılmıştır. Ağın eğitilmesi için “*Conjugate gradient backpropagation with Powell-Beale restarts*” eğitim algoritması sağladığı hız ve verimli bellek kullanımı nedeniyle tercih edilmiştir. Her bir özellik seti için ağın eğitilmesi ve test edilmesi amacıyla 100 farklı iterasyon ayrı ayrı gerçekleştirilmiştir. Veriler her defasında %70 oranında eğitim ve %30 oranında test için kullanılmıştır.

Öneri boyunca çeşitli özellik setleri sınıflandırıcılara girdi olarak uygulanmıştır. Özellik setleri, dalgacık adı, seviyesi ve özellik sayısını belirtmek üzere  $F_{dalgacık\ adı}^{seviye}$  (özellik sayısı) formatında kullanılmıştır. Ayrıca, morfolojik ve doğrusal 9 adet niteliği içeren temel özellik seti  $F_{md}(9)$  ile gösterilmiştir ve dalgacık bileşenleriyle elde edilen tüm özellik setlerine eklenmiştir. k-EK için *haar*, *db5* ve *sym5* aileleri kullanılarak elde edilen sonuçlar sırasıyla Çizelge 4.19, Çizelge 4.20 ve Çizelge 4.21’de gösterilmiş ve en iyi performanslar gri renk ile vurgulanmıştır.

Çizelge 4.19 Haar dalgacık ailesi ve k-EK sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{md}$	90,26	98,68	40,64	90,78	83,30
$F_{haar}^1$	89,46	99,18	31,06	89,68	87,91
$F_{haar}^2$	88,90	98,81	27,59	89,46	78,82
$F_{haar}^3$	89,67	99,15	33,02	89,90	88,06
$F_{haar}^4$	90,43	99,41	33,35	90,51	90,21
$F_{haar}^5$	89,29	99,23	26,35	89,54	84,87
$F_{haar}^6$	88,58	99,20	27,39	88,77	87,29
$F_{haar}^7$	88,04	99,42	20,15	88,14	86,24
$F_{haar}^8$	89,04	99,35	26,78	89,19	87,99
$F_{haar}^9$	88,68	99,35	23,96	88,84	86,97
$F_{haar}^{10}$	88,05	99,51	17,01	88,18	87,22
$F_{haar}^{11}$	87,60	99,62	14,23	87,66	88,29
$F_{haar}^{12}$	87,78	99,43	14,57	88,01	81,39

Çizelge 4.20 db5 dalgacık ailesi ve k-EK sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{db}^1$	89,47	98,97	31,80	89,83	84,94
$F_{db5}^2$	89,31	99,22	30,68	89,52	88,31
$F_{db5}^3$	88,83	99,33	26,85	88,94	88,78
$F_{db5}^4$	89,51	98,95	32,08	89,93	83,59
$F_{db5}^5$	89,49	99,22	28,17	89,73	85,13
$F_{db5}^6$	90,41	98,95	36,72	90,81	85,85
$F_{db5}^7$	88,64	98,91	27,03	89,10	83,02
$F_{db5}^8$	89,43	99,45	28,60	89,48	90,20
$F_{db5}^9$	88,15	99,40	20,09	88,31	86,08
$F_{db5}^{10}$	87,88	99,73	17,13	87,81	93,44
$F_{db5}^{11}$	88,27	99,72	19,40	88,21	92,63
$F_{db5}^{12}$	88,19	99,84	13,11	88,11	95,00

Çizelge 4.21 sym5 dalgacık ailesi ve k-EK sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{sym5}^1$	89,77	99,16	35,40	89,94	87,84
$F_{sym5}^2$	88,95	99,32	25,79	89,14	84,96
$F_{sym5}^3$	89,38	99,33	28,98	89,52	87,32
$F_{sym5}^4$	89,93	99,69	31,37	89,76	94,43
$F_{sym5}^5$	89,19	99,55	26,85	89,15	92,28
$F_{sym5}^6$	90,13	99,59	29,64	90,09	92,19
$F_{sym5}^7$	88,90	99,79	22,82	88,72	95,70
$F_{sym5}^8$	88,14	99,67	19,92	88,08	91,53
$F_{sym5}^9$	88,79	99,30	23,38	88,98	85,56
$F_{sym5}^{10}$	88,22	99,31	17,53	88,52	79,07
$F_{sym5}^{11}$	87,65	99,48	15,47	87,81	84,90
$F_{sym5}^{12}$	87,56	99,34	13,05	87,87	75,91

Deneysel çalışmada kullanılan tüm dalgacık aileleri için 1'den 12'ye kadar olan tüm seviyeler için ayrı ayrı özellik setleri oluşturulmuştur. En iyi sınıflandırma performansları k-EK sınıflandırıcısı ile elde edilmiştir.

YSA için *haar*, *db5* ve *sym5* aileleri kullanılarak elde edilen sonuçlar sırasıyla Çizelge 4.22, Çizelge 4.23 ve Çizelge 4.24'de gösterilmiş ve en iyi performanslar gri renk ile vurgulanmıştır.

Çizelge 4.22 *haar* dalgacık ailesi ve YSA sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{md}$	88,53	93,27	59,66	93,50	58,02
$F_{haar}^1$	89,33	92,24	65,85	95,77	49,36
$F_{haar}^2$	88,27	91,45	65,21	95,39	46,03
$F_{haar}^3$	88,92	92,02	64,72	95,49	47,94
$F_{haar}^4$	89,69	92,90	67,16	95,45	53,09
$F_{haar}^5$	89,24	92,54	65,06	95,33	51,70
$F_{haar}^6$	90,04	93,02	68,72	95,75	53,49
$F_{haar}^7$	89,39	92,96	65,68	95,01	54,28
$F_{haar}^8$	89,39	92,92	65,23	95,10	30,79
$F_{haar}^9$	90,13	93,36	66,58	95,49	56,61
$F_{haar}^{10}$	89,48	92,38	67,56	95,78	51,52
$F_{haar}^{11}$	89,11	92,40	65,86	95,38	50,16
$F_{haar}^{12}$	88,32	91,44	62,15	95,50	44,06

Çizelge 4.23 *db5* dalgacık ailesi ve YSA sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{db5}^1$	88,71	91,77	66,12	95,55	49,27
$F_{db5}^2$	88,79	92,18	62,79	95,39	46,34
$F_{db5}^3$	88,34	91,68	62,50	95,38	44,03
$F_{db5}^4$	89,15	91,97	66,29	95,89	47,90
$F_{db5}^5$	89,31	92,55	66,60	95,36	51,35
$F_{db5}^6$	91,00	94,00	69,89	95,83	59,95
$F_{db5}^7$	89,74	93,13	68,93	95,20	56,81
$F_{db5}^8$	90,81	93,89	71,14	95,70	61,01
$F_{db5}^9$	90,46	93,04	71,62	96,19	55,51
$F_{db5}^{10}$	89,72	92,99	65,88	95,48	53,31
$F_{db5}^{11}$	89,48	92,31	68,85	95,90	51,30

Çizelge 4.24 *sym5* dalgacık ailesi ve YSA sonuçları

<b>F</b>	<b>DĞR</b>	<b>DUY</b>	<b>ÖZG</b>	<b>PTO</b>	<b>NTO</b>
$F_{sym5}^1$	89,07	91,88	68,72	95,92	48,03
$F_{sym5}^2$	88,09	92,06	61,52	94,49	48,90
$F_{sym5}^3$	88,52	92,14	62,55	94,90	48,10
$F_{sym5}^4$	89,34	92,29	66,03	95,72	50,75
$F_{sym5}^5$	89,31	92,16	68,12	95,89	51,54
$F_{sym5}^6$	89,32	92,99	65,17	94,88	53,56
$F_{sym5}^7$	89,62	92,80	65,83	95,49	53,90
$F_{sym5}^8$	89,67	92,60	69,23	95,78	52,05
$F_{sym5}^9$	89,79	92,49	69,01	95,96	51,98
$F_{sym5}^{10}$	89,80	92,51	69,18	96,06	49,94
$F_{sym5}^{11}$	89,26	92,12	66,64	95,83	50,46
$F_{sym5}^{12}$	89,26	91,71	71,59	96,24	49,69

En iyi sınıflandırma performansları k-EK sınıflandırıcısı ile elde edilmiştir. Sadece morfolojik ve doğrusal 9 adet özellik kullanılarak elde edilen %83,30 NTO oranı, 7.seviyede *sym5* ve 65 özellik ile %95,70 kadar çıkartılmıştır. Bu sırada PTO oranı %90,78'den %88,72'ye gerilemiştir; ancak negatif örneklerin doğru bir şekilde tahmin edilmesi, yani patolojik örneklerin yakalanması KTG testinin doğası gereği daha fazla önem arz etmektedir. YSA sınıflandırıcısı çoğunluk sınıfındaki örnekleri ayırt etme konusunda, bir başka ifadeyle normal fetüsleri ayırt etme konusunda, hipoksik fetüslere göre daha fazla başarılı olmuştur. *ds5* dalgacık ailesiyle, 8.seviyede ve 72 özellik kullanarak, sadece geleneksel özellikler kullanılarak elde edilen %59,66 ÖZG başarı değeri, %71,14'e kadar yükseltilebilmiştir. Bu durumda, normal fetüsleri doğru bir şekilde tahmin etme oranı %95,70 olarak elde edilirken, ne yazık ki hipoksik

fetüsleri tahmin etme oranı %61,01’de kalmıştır. Neticede, YSA’nın verilerin sınıflar üzerindeki dengesiz dağılımından dolayı beklenen seviyede başarı sağlayamadığı ve daha çok sayı bakımından baskın olan çoğunluk sınıfı yani normal fetüsleri ayırt etmede başarılı olduğu görülmüştür.

Kullanılan veri setinde 276 normal ve 44 adet hipoksik fetüs örneği bulunmaktadır. Verilerin sınıflar arası dağılımının dengesiz olduğu açıktır. Bu nedenle, sınıflandırıcı performansları ölçülürken PTO ve NTO değerlerinin önemi artarken; DUY ve ÖZG değerlerinin önemi azalmaktadır. Bir başka ifadeyle, verinin bir sınıf üzerinde daha fazla yoğunlaşması, sınıflandırıcıların örnek sayısı açısından yoğun olan (çoğunluğu oluşturan) sınıfa meyilli olması problemini beraberinde getirmektedir [109]. Doğal olarak, bu önerideki veri setinde DUY ölçütünün çok yüksek, buna karşın ÖZG değerinin daha düşük olması beklenen bir sonuçtur. Nitekim YSA’da bu durum net bir şekilde görülmüştür.


Deneysel çalışma, geleneksel özelliklerle birlikte dalgacık ayrışımı yardımıyla elde edilen istatistiksel parametrelerin özellik olarak kullanılmasıyla sınırlandırılmıştır. Rahim aktivitesindeki değişimler dikkate alınmamıştır. Ayrıca, doğrusal olmayan [93], imge tabanlı [152] ve spektral alandan diğer pek çok gösterge de göz ardı edilmiştir. Analiz sırasında, dalgacık ayrışımı çeşitli seviyelerde uygulanırken geniş özellik setleri elde edilmiş ve hangi frekans bantlarındaki özelliklerin işaretleri ayırt etmek hususunda daha fazla önem taşıdığına dair bir analiz gerçekleştirilmemiştir. Özellik setinden gereksiz niteliklerin atılması sınıflandırıcı performansı açısından önemlidir. Bir başka ifadeyle, işareti daha iyi tanımlayan özelliklerin seçilmesi sınıflandırıcı performansını arttıracaktır.

Sonuç olarak, bu deneysel çalışmada FKH’nin morfolojik ve doğrusal özelliklerine ek olarak, literatürde en fazla kullanılan *haar*, *db5* ve *sym5* dalgacık aileleri kullanılarak, 1. ve 12. seviyeler arasındaki bileşenlerden elde edilen OMS, MMS, *p*-norm, Frobenius norm, sonsuzluk ve negatif sonsuzluk normlarının birer özellik olarak kullanılması ve KTG işaretlerinin sınıflandırılması üzerindeki etkisi incelenmiştir. En verimli sonuçlara *sym5* dalgacık ailesiyle, 7. seviyede, 65 özellikle ve k-EK sınıflandırıcısı ile erişilmiştir. k-EK sınıflandırıcısı, YSA’ya göre daha iyi sonuçlar üretmiştir. Dalgacık bileşenlerden elde edilen istatistiksel parametreler sınıflandırma doğruluğunu arttırmıştır.



#### 4.9. FKH Analizi için Yeni Bir Prognostik Model Önerisi

Bu deneysel çalışmada, KTG işaretlerinden hipoksik fetüslerin tespitini sağlamak üzere ayırık dalgacık dönüşümü (ADD) ve İTZF özelliklerine dayalı yeni bir prognostik model önerilmiştir.



Şekil 4.17 Yeni bir prognostik model önerisi

Önerilen prognostik modele ait blok şema Şekil 4.17’de verilmiştir. Deneysel çalışmanın 1. aşamasında, veri koleksiyonu oluşturulmuştur. Bu kapsamda, CTU-

UHB veri tabanında yer alan 552 ham KTG kaydına odaklanılmıştır. Kayıtlarda, doğumun birinci aşamasını temsil eden ve 30 dakika uzunluğundaki birinci bölümler kullanılmıştır. Kayıtların normal ya da hipoksik olacak şekilde iki sınıfa ayrılması istendiğinden şüpheli (230 kayıt) ve yorumlanamayan (6 kayıt) kayıtlar veri setinden çıkartılmıştır. Sonuç olarak, 272 tanesi normal ve geriye kalanı hipoksik olmak üzere toplam 316 KTG örneği dikkate alınmıştır.

Deneysel çalışmanın 2. aşamasında önışleme süreci gerçekleştirilmiştir. Önışleme süreci, hem özellik çıkarma hem de sınıflandırma aşamalarını etkilediği için çok önemlidir. Bu açıdan, FKH doğası gereği, anne ve fetüsün metrik hareketleri, kullanılan ekipmanlar ve doğuma ilişkin stres gibi çeşitli nedenlerden kaynaklanan farklı gürültü türleri içermektedir [12]. Önışleme aşaması; güvenilir bölüm seçimi, aykırılıkların yakalanması ve interpolasyon adımlarından oluşmaktadır. Bernardes ve arkadaşları [38] ve Ayres-de-Campos ve arkadaşları [120] çalışmalarında aykırı atımların tespiti ve gürültü gidermek üzere algoritmalar önermişlerdir. Deneysel çalışma kapsamında, özellikle bu iki çalışmada belirtilen prosedürler takip edilmiştir. Sensör temasının kaybı, çoğu durumda kayıp atımlara neden olmaktadır ve doğrusal enterpolasyon tekniği bu problemin üstesinden gelmek için tercih edilmektedir [89]. Eksik atımların uygun bir şekilde doldurulması için MATLAB® tarafından sağlanan kübik Hermite spline interpolasyon tekniği kullanılmıştır [191] çünkü bu teknik spektral analiz için doğru ve güvenilir sonuçlar üretmektedir [87]. Önışleme adımının son aşamasında, doğrusal olmayan işaret işleme tekniklerinin kullanımından dolayı, FKH işaretleri ikinci dereceden bir polinom ile detrend edilmiştir [93]. Bu noktadan sonra işaretler analize hazır hale gelmiştir.

Deneysel çalışmanın 3. ve 4. aşamalarında geleneksel olarak kullanılan (morfolojik ve zaman alanı özellikleri) özellikler elde edilmiştir. Temel kalp hızı, hızlanma ve yavaşlama örüntülerinin sayısı, deneysel çalışma bağlamında morfolojik özellikler olarak değerlendirilmiştir. Morfolojik özelliklere ilaveten, 6 adet doğrusal zaman alanı özelliği de elde edilmiştir. Bunlar FKH ortalaması, standart sapması, UDD, Delta, KZD ve AE'dir. Sonuç olarak 3 adet morfolojik ve 6 adet doğrusal zaman alanı endeksinden oluşan özellikler, deneysel çalışma kapsamında geleneksel özellikler olarak kabul edilmiştir.


Deneysel çalışmanın 5. aşamasında, İTZF özelliklerinin çıkartılması sağlanmıştır. İTZF özelliklerini elde etmek için, GSEM yöntemi kullanılmıştır. Çizelge 4.25’de belirtilen; ÇDF (0 – 0.03 Hz), DF (0.03 – 0.15 Hz), OF (0.15 – 0.50 Hz) ve YF (0.50 – 1 Hz) aralıklarına ayrı ayrı odaklanılmıştır. GSEM için açı değeri ( $\theta$ )  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$  ve uzaklık ( $\delta$ ) 1 olarak dikkate alındığından her bir açı değeri için kontrast, korelasyon, homojenlik ve enerji olmak üzere 16 özellik elde edilmiştir ve bu işlem dört farklı frekans aralığı için uygulandığından toplamda 64 İTZF özelliği elde edilmiştir. Şekil 4.18’de normal ve hipoksik bir KTG işareti için spektrogram görüntülerine yer verilmiştir.

Çizelge 4.25 Deneysel frekans aralıkları

<b>Frekans Bantları</b>	<b>Frekans Aralıkları</b>
ÇDF	0 – 0.03 Hz
DF	0.30 – 0.15 Hz
MF	0.15 – 0.50 Hz
YF	0.50 – 1 Hz

Deneysel çalışmanın 6. aşamasında, FKH işaretlerinin daha iyi bir şekilde karakterize edilmesini sağlamak üzere 5. dereceden Daubechies (*db5*), 10 dereceden Symmlets ve 4. dereceden Coiflets ana dalgacıları değerlendirilmiştir. Dalgacık ayrışımı, Fourier dönüşümü ile gözlenmeyen, işaretin doğal geçişleriyle ilgili özelliklerin ortaya çıkartılmasını sağlamaktadır. Dalgacık ayrışımı bir işarete uygulandığında, ana dalgacık ailesinin ve seviyesinin seçimi oldukça kritik bir konudur. Deneysel çalışmalar sonucunda *db5* dalgacık ailesinin kullanılmasına karar verilmiştir. Standart sapma, ortalama ve medya mutlak sapma, çarpıklık ve basıklık istatistiksel özellikleri, yakınsama ve D3-D5 bileşenleri için ayrı ayrı hesaplanmıştır. Sonuç olarak, FKH işaretini tanımlamak üzere, her bir işareten toplam 20 adet özellik ADD kullanılarak elde edilmiştir. D1 ve D2 bileşenleri gereksiz bilgi içeriği nedeniyle dikkate alınmamıştır.

Deneysel çalışmanın 7. aşamasında, morfolojik, zaman ve İTZF alanlarından elde edilen özelliklerin tümünden oluşan ve veri tabanındaki işaretlerin tümünü tanımlayan özellik seti elde edilmiştir. Çizelge 4.26’de özellik setinin, özelliklerin kökenine göre gruplanması sağlanmış ve hangi alandan kaç özelliğin elde edildiği açıkça gösterilmiştir.



Şekil 4.18 Deneysel frekans aralıklarına göre spektrogramlar

Çizelge 4.26 Prognostik model için organize edilmiş tüm özellikler

<b>FKH analizi için özelliklerin kökenleri</b>	<b>Özellik Sayısı</b>	<b>Açıklama</b>
Geleneksel olarak kullanılan özellikler	9	Morfolojik ve zaman alanından elde edilen özelliklerdir.
ADD alanından elde edilen özellikleri	20	Yakınsanama ve D3-D5 detay bileşenlerinden elde edilen değerlerdir.
İmge tabanlı zaman-frekans özellikleri	64	Çizelge 4.25’de belirtilen frekans aralıklarından elde edilen özelliklerdir.

Deneysel çalışmanın 8. aşamasında, otomatik özellik seçiminin gerçekleştirilmesi sağlanmıştır. Özellik seçimi algoritmaları veri setindeki en ilgili özelliklerin seçilmesini sağlayarak alakasız özelliklerin atılmasını sağlamaktadır [170]. Çizelge 4.27’de GDÖS algoritmasına göre seçilen özelliklerin endeks numaralarına yer verilmiştir. Sonuç olarak, toplam 93 özellikten oluşan özellik setinin boyutu 30’a indirgenmiştir.


Çizelge 4.27 GDÖS algoritmasına göre seçilen özellikler

<b>Seçilen özellikler</b>
9, 11, 10, 1, 12, 5, 4, 6, 23, 3, 13, 7, 29, 24, 34, 42, 30, 38, 41, 39, 40, 28, 45, 43, 33, 31, 44, 32, 37, 35

Analizin bu aşamasında sonra toplamda 6 farklı özellik seti elde edilmiştir. Elde edilen özellik setleri Çizelge 4.28’de tanımlanmıştır.

Morfolojik ve zaman alından elde edilen geleneksel özellikler, işaretin farklı frekans bantlarını tanımlayan ADD özellikleri ve İTZF özelliklerinden elde edilen toplam 93 adet endeks ile özellik seti açıklanmaktadır. Şekil 4.19 tüm özellikleri temsil eden özellik setinin 2 boyutlu TBA eksenine yansıtılmış halini göstermektedir.

Özellik setleri, Çizelge 4.28’de gösterilen her bir özellik seti için 10 farklı iterasyonda ve iterasyonun her birinde 5-katlı çapraz doğrulama yöntemi kullanılarak YSA, AÖM ve DVM makine öğrenmesi teknikleriyle sınıflandırılmıştır [192]. Elde edilen sınıflandırma sonuçlarına Çizelge 4.29’da yer verilmiştir.



Şekil 4.19 Verilerin 2 boyutlu TBA eksenine dağılımı ve marjinal histogramları

Çizelge 4.28 Prognostik model için elde edilen özellik setleri

Özellik seti	Özellik Sayısı	Açıklama
ÖS-I	9	Geleneksel özellikler (GÖ)
ÖS-II	29	Geleneksel özellikler ve ADD tarafından sağlanan özellikler
ÖS-III	45	Geleneksel, ADD ve ÇDF özellikleri
ÖS-IV	61	Geleneksel, ADD, ÇDF, DF özellikleri
ÖS-V	77	Geleneksel, ADD, ÇDF, DF ve OF özellikleri
ÖS-VI	93	Geleneksel, ADD, ÇDF, DF, OF ve YF özellikleri

ÖS-I sadece morfolojik ve zaman alanından elde edilen 9 adet özellikte oluşmaktadır. Bu özellik seti sınıflandırıcılara uygulandığında, %89,18 en yüksek doğruluk ile AÖM makinesinin üstün geldiği görülmüştür. Ancak, hipoksik örnekleri ayırt etme konusunda DVM %83,81'lik başarı oranı ile hem YSA hem de DVM'yi geride bırakmıştır. Bu nedenle, AÖM ÖS-I'deki özellikler ile özellikle pozitif örnekleri ayırt ederken bir üstünlük göstermiştir.

Çizelge 4.29 Prognostik model ile elde edilen sınıflandırma sonuçları

ÖS	Sınıflandırıcı	DĞR (%)	DUY (%)	ÖZG (%)	YPO (%)	GO (%)	F (%)
ÖS-I	YSA	87.88	88.01	60.37	39.62	71.72	<b>92.97</b>
	AÖM	<b>89.18</b>	<b>93.08</b>	45.51	54.48	65.09	90.58
	DVM	79.58	80.84	<b>83.81</b>	<b>16.18</b>	<b>82.31</b>	76.87
ÖS-II	YSA	<b>90.44</b>	<b>95.33</b>	64.58	35.41	76.65	<b>90.67</b>
	AÖM	89.36	91.13	56.18	43.81	71.55	90.05
	DVM	84.08	83.71	<b>81.97</b>	<b>18.02</b>	<b>82.84</b>	82.40
ÖS-III	YSA	<b>92.65</b>	<b>92.85</b>	74.23	25.76	83.02	92.74
	AÖM	87.52	88.54	55.81	44.18	70.29	<b>87.96</b>
	DVM	86.89	87.01	<b>87.66</b>	<b>12.33</b>	<b>87.34</b>	85.59
ÖS-IV	YSA	<b>93.67</b>	<b>93.94</b>	76.22	23.77	84.94	<b>93.78</b>
	AÖM	86.59	86.90	58.28	41.71	71.16	86.73
	DVM	89.30	89.02	<b>86.55</b>	<b>13.45</b>	<b>87.77</b>	88.48
ÖS-V	YSA	<b>92.40</b>	<b>92.58</b>	73.63	26.36	82.56	<b>92.48</b>
	AÖM	84.48	84.16	56.97	43.02	69.24	84.31
	DVM	88.16	87.90	<b>85.96</b>	<b>14.03</b>	<b>86.92</b>	87.15
ÖS-VI	YSA	<b>93.10</b>	<b>93.45</b>	73.76	26.23	83.02	<b>93.24</b>
	AÖM	83.95	83.40	57.27	42.72	69.11	83.65
	DVM	89.39	88.98	<b>84.79</b>	<b>15.20</b>	<b>86.86</b>	88.65

ADD ile elde edilen 20 adet istatistiksel özelliğin özellik kümesine eklenmesi suretiyle özellik kümesi genişletilmiştir. Bu kapsamda, 9 geleneksel ve 20 ADD özelliği nihai olarak kullanılmıştır. Özellik setinin bu şekilde genişletilmesiyle birlikte tüm sınıflandırıcıların performansında bir artış olmuştur. Pozitif örneklerin yani normal FKH işaretlerinin tanınmasında YSA üstün gelirken, negatif örneklerin yani hipoksik FKH işaretlerinin tanınmasında DVM üstün gelmiştir.

ÖS-III, çok düşük frekans aralığında GSEM için açılı değerinin ( $\theta$ )  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$  ve uzaklık ( $\delta$ ) değerinin 1 olarak dikkate alınması neticesinde elde edilen özelliklerin özellik setine eklenmesi sonucu elde edilmiştir. Genel olarak sınıflandırıcıların performansında bir artış gözlemlenmiştir. Özellikle DVM %87,66'lık özgüllük ve %12,33 YPO ile oldukça verimli bir performans sergilemiştir. YSA'nın %60,37'lik özgüllük değeri %74,23'e kadar yükselmiştir. AÖM'nin ürettiği sonuçlar ise biraz daha vasat kalmıştır.

ÖS-IV, toplam 61 özelliğden oluşmaktadır ve geleneksel, ADD ve İTZF için ÇDF ve DF'den elde edilen özelliklerden oluşmaktadır. ÖS-IV en verimli sonuçların elde edildiği özellik seti olarak belirlenmiştir. Hem pozitif hem de negatif örnekler üzerinde oldukça tatmin edici sonuçlar görülmüştür. DVM ile %87,77, YSA %84,94 ve AÖM ile %71,16'lık geometrik ortalama değerleri elde edilmiştir. Benzer şekilde genel olarak en yüksek özgüllük değerleri sırasıyla YSA, AÖM ve DVM için %76,22, %58,28 ve %86,55 olarak elde edilmiştir.

ÖS-V özellik setinin sınıflandırıcılara uygulanması neticesinde ÖS-IV'e çok yakın ve yine oldukça iyi sonuçlar elde edilmiştir. DVM yine en üstün sınıflandırıcı olmuştur.

ÖS-VI tüm özellik setinin sınıflandırıcıya uygulanması sonucu elde edilen performans sonuçlarına göstermektedir ve aynı zamanda en geniş veri setini de temsil etmektedir. Morfolojik, zaman ve İTZF alanlarından elde edilen tüm özellikleri kapsamaktadır. Sonuçlar oldukça tatmin edicidir. YSA, AÖM ve DVM %93,24, %83,65 ve %88,65'lik F-ölçüt değerlerine bu özellik seti ile erişmişlerdir.

Bu deneysel çalışma kapsamında FKH işaretleri analiz edilirken oldukça geniş bir özellik seti oluşturulmuş ve özellik seti sistematik bir şekilde genişletilerek sınıflandırıcı performansları ölçülmüştür. Çizelge 4.27'de GDÖS algoritması sonucuna bağlı olarak seçilen indisler gösterilmiştir.

Elde edilen özelliklerin önem sıralamasını elde etmek üzere *t*-testi kullanılmıştır.  $p < 0.01$  için toplamda 22 özellik elde edilmiştir. Bu özelliklerden geleneksel özelliklerden 9'uncusunu temsil eden AE 1.2745e-15 değeriyle iki grup arasındaki en farklı (benzersiz) endeks olarak çıkmıştır. Daha sonra dalgacık dönüşümüyle elde edilen ortalama mutlak sapma ve yakınsama bileşenin standart sapması iki grup arasındaki en benzersiz endeksler olmuştur ve *p* değerleri sırasıyla 2.0792e-13 ve 1.6259e-12 olarak bulunmuştur. Bunu sırasıyla temel kalp hızı (3.8716e-12), yakınsama bileşenin medyan mutlaka sapma değeri (1.8116e-11) değerleri izlemiştir.



Çizelge 4.30  $p < 0.01$  ve  $p < 0.05$  için anlamlı İTZF özellikleri

No	İndeks No	Özellik Kökeni	Açıklama	p-değeri
01 <sup>+</sup>	9	GÖ	Aralık endeksi	1.2745e-15
02 <sup>+</sup>	11	ADD	A5 için ortalama mutlak sapma	2.0792e-13
03 <sup>+</sup>	10	ADD	A5 için standart sapması	1.6259e-12
04 <sup>+</sup>	1	GÖ	TKH	3.8716e-12
05 <sup>+</sup>	12	ADD	A5 için medyan mutlak sapma	1.8116e-11
06 <sup>+</sup>	5	GÖ	TKH için standart sapma	7.5523e-11
07 <sup>+</sup>	4	GÖ	TKH için ortalama	4.7342e-10
08 <sup>+</sup>	6	GÖ	Uzun dönemli düzensizlik	4.6041e-09
09 <sup>+</sup>	23	ADD	D4 için çarpıklık	2.4605e-07
10 <sup>+</sup>	3	CF	Yavaşlama örüntülerinin sayısı	1.5573e-05
11 <sup>+</sup>	13	ADD	A5 için çarpıklık	7.0966e-05
12 <sup>+</sup>	7	GÖ	Delta	1.0854e-04
13 <sup>+</sup>	29	ADD	D3 için basıklık	8.2257e-04
14 <sup>+</sup>	24	ADD	D4 için basıklık	0.0023
15 <sup>+</sup>	34	ÇDF	$\delta = 1, \theta = 45^\circ$ , Kontrast	0.0031
16 <sup>+</sup>	42	ÇDF	$\delta = 1, \theta = 135^\circ$ , Kontrast	0.0034
17 <sup>+</sup>	30	ÇDF	$\delta = 1, \theta = 0^\circ$ , Kontrast	0.0042
18 <sup>+</sup>	38	ÇDF	$\delta = 1, \theta = 90^\circ$ , Kontrast	0.0048
19 <sup>+</sup>	41	ÇDF	$\delta = 1, \theta = 90^\circ$ , Homojenlik	0.0050
20 <sup>+</sup>	39	ÇDF	$\delta = 1, \theta = 90^\circ$ , Korelasyon	0.0050
21 <sup>+</sup>	40	ÇDF	$\delta = 1, \theta = 90^\circ$ , Enerji	0.0050
22 <sup>+</sup>	28	ADD	D3 için çarpıklık	0.0084
23 <sup>*</sup>	45	ÇDF	$\delta = 1, \theta = 135^\circ$ , Homojenlik	0.0106
24 <sup>*</sup>	43	ÇDF	$\delta = 1, \theta = 135^\circ$ , Korelasyon	0.0106
25 <sup>*</sup>	33	ÇDF	$\delta = 1, \theta = 0^\circ$ , Homojenlik	0.0114
26 <sup>*</sup>	31	ÇDF	$\delta = 1, \theta = 0^\circ$ , Korelasyon	0.0115
27 <sup>*</sup>	44	ÇDF	$\delta = 1, \theta = 135^\circ$ , Enerji	0.0141
28 <sup>*</sup>	32	ÇDF	$\delta = 1, \theta = 0^\circ$ , Enerji	0.0148
29 <sup>*</sup>	37	ÇDF	$\delta = 1, \theta = 45^\circ$ , Homojenlik	0.0475
30 <sup>*</sup>	35	ÇDF	$\delta = 1, \theta = 45^\circ$ , Korelasyon	0.0480

<sup>+</sup>  $p < 0.01$  için istatistiksel olarak anlamlı

<sup>\*</sup>  $p < 0.05$  için istatistiksel olarak anlamlı

İTZF özelliklerine bakıldığında önem sırasına göre 34, 42, 30, 38, 41, 39 ve 40 numaralı endekslerin belirleyici olduğu görülmüştür. Çizelge 4.30'da  $t$ -testine göre en anlamlı olan özelliklere, kökenlerine, açıklamalarına ve  $p$  değerlerine yer verilmiştir. 30, 34, 38 ve 42 numaralı indisleri sırasıyla  $\theta = 0^\circ, 45^\circ, 90^\circ$  ve  $135^\circ$  için kontrast özelliğini temsil etmektedir. 39, 40 ve 41 numaralı endeksler ise  $\theta = 90^\circ$  için korelasyon, enerji ve homojenlik endeks değerini gösterir. Bu sonuçlara göre ÇDF frekans bandından elde edilen tüm kontrast özelliklerinin ve  $\theta = 90^\circ$  için kontrast, korelasyon, enerji ve homojenlik özelliklerinin normal ve hipoksik fetüsleri ayırmak üzere belirleyici olduğu sonucuna varılmıştır.  $t$ -testi için  $p < 0.05$  değeri kabul

edildiğinde ise önem sırasına göre 45, 43, 33, 31, 44, 32, 37 ve 35 numaralı endeksler özellik setine eklenmiştir ve bu özelliklerde yine GSEM ile ÇDF’den elde edilen İTZF özelliklerini temsil etmektedir.

Önem derecelerine bağlı olarak normal fetüsleri hipoksik fetüslerden ayırt etmek üzere istatistiksel olarak anlamı olan ve sırasıyla 22 ve 30 adet özelliklerde oluşan veri setleri sınıflandırıcılara ayrı ayrı uygulanmış ve Çizelge 4.31’de gösterilen sonuçlara erişilmiştir.

Çizelge 4.31 Boyut indirgemesi sonucu elde edilen performans sonuçları

	Sınıflandırıcı	DĞR (%)	DUY (%)	ÖZG (%)	YPO (%)	GO (%)	F (%)
$p < 0.01$	YSA	<b>89.81</b>	<b>89.75</b>	68.30	31.69	78.30	<b>89.78</b>
	AÖM	90.34	93.42	51.87	48.12	69.61	91.40
	DVM	87.12	86.74	<b>84.19</b>	<b>15.80</b>	<b>85.46</b>	85.97
$p < 0.05$	YSA	90.03	89.88	70.15	29.84	79.40	89.95
	AÖM	90.48	<b>93.54</b>	52.12	47.87	69.82	91.54
	DVM	87.72	87.35	<b>84.66</b>	<b>15.33</b>	<b>85.99</b>	86.67

Özetle, bu deneysel çalışmada öncelikle klinik açıdan vazgeçilmez olan morfolojik özellikler ve geleneksel olarak kullanılan ve zaman alanında elde edilen doğrusal özellikler dikkate alınmıştır. ADD, FKH işaretlerinin zaman ölçeğine bağlı özelliklerin çıkartılması için kullanılmıştır. Ayrıca, spektral alanda, bir İTZF özellik çıkarımı yönteminin kullanılması önerilmiştir. Daha spesifik olarak, spektrogram olarak adlandırılan FKH’nin grafiksel bir sunumu KZFD ile elde edilmiştir. Spektrogram imgeleri 8-bitlik gri imgelere dönüştürülmüş ve İTZF özellikleri GSEM ile ortaya çıkartılmıştır. Analizin son aşamasında, farklı özellik seti grupları YSA, AÖM ve DVM sınıflandırıcılarına en bilgilendirici özellik setini tanımlamak için girdi olarak uygulanmıştır. Bunun dışında, normal ve hipoksik fetüsleri ayırt etmek üzere

istatistiksel olarak anlamlı olan özellikler GDÖS algoritmasına bağlı olarak elde edilmiş, *t*-testi ile önem dereceleri tespit edilmiş ve neticede son derece umut verici sonuçlara erişilmiştir.

Bu deneysel çalışma ile İTZF özelliklerinin sınıflandırma doğruluğunu arttırdığı ispatlanmıştır. İTZF analizinin en anlamlı ve bilgilendirici özellikleri ÇDF ve DF bandından elde ettiği görülmüştür. Özellikle kontrast niteliğinin iyi bir tahmin edici olduğu görülmüştür. Önerilen yöntem, FKH işaretlerinin karakterize etmek üzere hem yeni bir yaklaşım sunmuş hem de umut verici sonuçlar üretmiştir. Deneysel çalışma kapsamında kullanılan YSA, AÖM ve DVM makine öğrenmesi tekniklerinden en üstünün olanın DVM olduğu görülmüştür. YSA'da memnun edici sonuçlar üretmiştir. Ne yazık ki, AÖM'nin sergilediği performans DVM ve YSA ile karşılaştırıldığında daha orta seviyelerde kalmıştır.

#### **4.10. Kardiyotokografi Analiz Yazılımı**

KTG analiz yazılımları, gözlemciler arası ve gözlemciler içi anlaşmazlık seviyesini düşürmek ve KTG değerlendirmesinde yeniden üretilebilirliğini sağlamak amacıyla, KTG analizini sayısallaştırıp, objektif bir değerlendirmenin gerçekleştirilmesini amaçlayan yazılımlardır. Bu kapsamda, gözlemciler ve bilgisayarlar tarafından yapılan analizler arasındaki uyumu ölçen [43], [193], [194], ticarileşmiş [28], [38], [41] ya da akademik amaçlarla kullanılan [31] pek çok yazılımın geliştirildiği görülmüştür [80], [101], [120].


Bu doktora tezi kapsamında, akademik amaçlarla kullanılmak üzere yeni bir KTG analiz yazılımı geliştirilmiştir. Yazılım, MATLAB® kullanıcı ara yüzü ortamı (GUIDE) kullanılarak geliştirilmiştir. Bu ortam, uygulamayı kullanmak için gerekli kod bilgisini elemine ederek, kullanıcıların birkaç tıklama ile özel olarak tanımlanmış görevleri kolayca yerine getirebilmesine imkan tanımaktadır [195].

KTG analiz yazılımı, gelişmiş işaret işleme ve makine öğrenmesi tekniklerini içeren bir yazılımdır. Bu çerçevede KTG analiz yazılımı, veri setine erişim, ön işleme, farklı alanlardan elde edilen özelliklerin çıkarımı, özellik dönüşümü ve özellik seçimi ile sınıflandırma aşamalarını kapsamaktadır.

KTG analiz yazılımı, morfolojik özelliklerin elde edilmesi ve çeşitli parametrelerin değiştirilmesi durumunda işaret üzerindeki değişimin

gözelemlenebilmesini sağlamaktadır. Ayrıca, zaman alanı özelliklerinin çıkartılması, zaman-frekans analizinin gerçekleştirilmesi ve imge tabanlı zaman-frekans özelliklerinin elde edilebilmesi de imkan tanımaktadır. Bu özelliklere ilaveten, son dönemlerde oldukça yaygın olarak kullanılan entropi tahmin edicilerinin de yazılıma eklenmesi sağlanmış ve doğrusal-doğrusal olmayan analiz yöntemlerinin de özellik çıkarımı için kullanılması sağlanmıştır.

Şekil 4.20’de KTG analiz yazılımının ana ekranına yer verilmiştir. Öncelikle, araç kutusu çubuğunda yazılım üzerinde yapılabilen pek çok işlemin tek bir tıklama ile gerçekleştirilebilmesi sağlanmıştır. Bunun dışında hangi işaretin yüklendiği ve işaretin hangi bölümüne odaklanıldığı bilgisi ana ekranın alt kısmında belirtilmiştir. Programın gövdesini ise işaretin grafiksel olarak gösterilmesini sağlayan ve gerçek NST testine göre modellenmiş çizim eksenini oluşturmaktadır.



Şekil 4.20 Kardiyotokografi yazılımı ana ekranı

KTG analiz yazılımında uygulama kapsamında kullanılan tüm fonksiyonların hem komut isteminden hem de grafik ekranından çalıştırılabilecek şekilde tasarlanması sağlanmıştır.

#### 4.10.1. Dosya İşlemleri

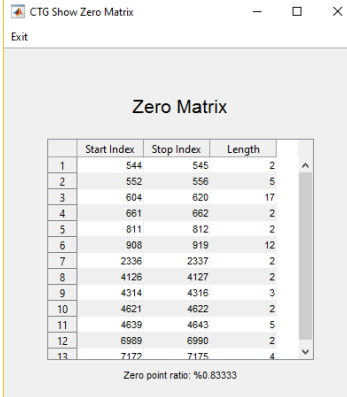
Dosya işlemleri, Şekil 4.20’de gösterildiği üzere kayıtların istenilen bölümlerinin yüklenmesi (Şekil 4.20, A), çeşitli işaret işleme teknikleri kullanıldıktan sonra işaretlerin yeni hallerinin kayıt edilmesi (Şekil 4.20, B) ve programdan çıkma (Şekil 4.20, C) prosedürlerinden oluşmaktadır. KTG analiz yazılımında, KTG işaretlerinin grafiksel kullanıcı arayüzleri ile yüklenmesi sağlanmıştır. Varsayılan olarak işaretlerin ilk parçası yüklenmektedir. İhtiyaç duyulması durumunda, kayıtların ikinci ve üçüncü parçaları ya da tümü de kolaylıkla yüklenebilmektedir.

#### 4.10.2. Temel Araç Kutusu İşlemleri

Temel araç kutusu işlemleri, Şekil 4.20’de gösterildiği üzere ana çizim ekranında çizdirilen şeklinin büyütülmesi (Şekil 4.20, D), küçültülmesi (Şekil 4.20, E), şeklin ele alınması (Şekil 4.20, F), döndürülmesi (Şekil 4.20, G), çizim üzerindeki değerlerin okunması (Şekil 4.20, veri imleci, H) ve göstergenin ayarlanması (Şekil 4.20, I) işlemlerinin yerine getirilmesi sağlamaktadır.

#### 4.10.3. Önişleme İşlemleri

Önişlem işlemleri, Şekil 4.20’de gösterildiği üzere sıfır matrisi (Şekil 4.20, J), önişleme prosedürlerinin tümünün yürütülmesi (Şekil 4.20, K), istatistiksel özelliklerin elde edilmesi (Şekil 4.20, L) ve önişleme öncesi ve sonrası işaretin grafiğini gösteren (Şekil 4.20, M) prosedürlerin bir araya getirilmesinden oluşturulmuştur.




The screenshot shows a window titled 'CTG Show Zero Matrix' with an 'Exit' button. The main content is a table titled 'Zero Matrix' with the following data:

	Start Index	Stop Index	Length
1	544	545	2
2	552	556	5
3	604	620	17
4	661	662	2
5	811	812	2
6	908	919	12
7	2336	2337	2
8	4126	4127	2
9	4314	4316	3
10	4621	4622	2
11	4639	4643	5
12	6989	6990	2
13	7172	7175	4

Zero point ratio: %0.83333

Şekil 4.21 Kayıp atımları gösteren ekran

Analizin ön işleme aşamasında öncelikle kayıp atımların elde edilmesi sağlanmıştır. Bu kapsamda, Şekil 4.21’de sıfır matrisi gösterilmektedir. Sıfır matrisi kayıp atımların indisler değerlerini, yani başlangıç ve bitiş noktalarını ile birlikte uzunluğunu göstermektedir. Ayrıca, kayıp atımların yüzdesi yine bu ekrana yer almaktadır.




Şekil 4.22 Ön işleme öncesi ve sonrası FKH işaretinin grafiksel gösterim ekranı

Ön işleme adımı kapsamında, işaretin güvenilir bölümleri saptanıp, aykırı değerlerin ayıklanması sağlanır ve mevcut gürültü problemleri giderilerek kayıp atımların doldurulması sağlanır. Şekil 4.22’de ön işleme öncesi ve sonrası işaretin grafiksel gösterimine yer verilmiştir. Bu ekranda kırmızı renk ile vurgulanan bölümlerin kayıp atımların doldurulduğu bölümleri temsil etmektedir.

#### 4.10.4. Gelişmiş Analiz İşlemleri

Gelişmiş analiz işlemleri bölümünde, Şekil 4.20’de gösterildiği üzere işaretin hızlanma örüntülerinin saptanması (Şekil 4.20, N), yavaşlama örüntülerinin


saptanması (Şekil 4.20, O), morfolojik özelliklerin elde edilmesi (Şekil 4.20, P), temel kalp hızı analizi (Şekil 4.20, Q), doğrusal-doğrusal olmayan özellik çıkarımı (Şekil 4.20, R) ve İTZF analizi (Şekil 4.20, S) gerçekleştirilmektedir.




Şekil 4.23 Hızlanma ve yavaşlama örüntülerinin saptanması ekranı

Şekil 4.23’de hızlanma ve yavaşlama örüntülerinin elde edilmesini sağlayan analiz ekranı gösterilmiştir. Şekil 4.23’de 1 numaralı panelde, FKH işaretinin çizdirilmesi, hızlanma örüntülerinin turuncu ve yavaşlama örüntülerinin yeşil renk ile vurgulanması sağlanmıştır. 2 numaralı panelde, her bir hızlanma örüntüsüne ait olan başlangıç ve bitiş indisleri, hızlanma örüntüsünün süresi ve maksimum TKH’den yükselme genliğini veren bir tablo yer almaktadır. 3 numaralı panelde ise, hızlanma örüntülerinde gerçekleştirilen işlemler benzer şekilde yavaşlama örüntüleri için de yapılmıştır. 2 ve 3 numaralı ölçütlerin üzerinde yer alan kayan çubuklar ile farklı kılavuzlarda belirtilen değerlere bağlı olarak parametrelerin değiştirilmesi ve hızlanma ve yavaşlama örüntülerinin yeniden hesaplanarak çizdirilmesi sağlanmıştır. 2 ve 3 panellerde yer alan tablo satırlarına tıklandığında ise ilgili örüntünün istatistiksel özelliklerini veren (Şekil 4.24’de bir hızlanma örüntüsünün özellikleri ve Şekil 4.25’de

ise bir yavaşlama örüntüsünün özellikleri verilmiştir) bir ekranın etkileşimli bir şekilde elde edilmesi sağlanmıştır.



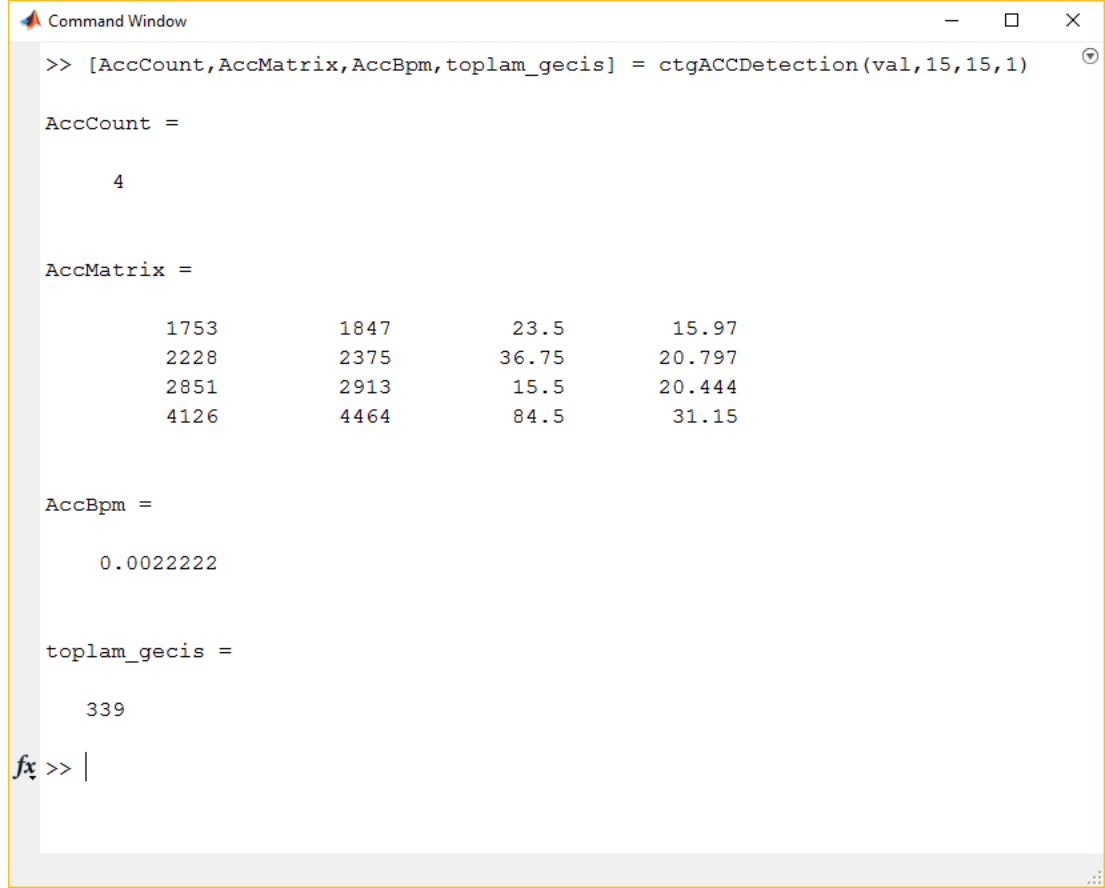
Şekil 4.24 Bir hızlanma örüntüsüne ait istatistiksel özellik ekranı



Şekil 4.25 Bir yavaşlama örüntüsüne ait istatistiksel özellik ekranı



Daha önce ifade edildiği gibi KTG işaretleri için geliştirilen tüm fonksiyonlara hem komut isteminden hem de grafiksel ekranlardan erişim sağlanabilmektedir. Şekil 4.23’de gösterilen FKH işareti örneği için hızlanma örüntülerinin komut isteminden elde edilmesini sağlayan örneğe Şekil 4.26’de yer verilmiştir.



```
>> [AccCount,AccMatrix,AccBpm,toplam_gecis] = ctgACCDetection(val,15,15,1)

AccCount =

     4

AccMatrix =

    1753    1847    23.5    15.97
    2228    2375    36.75   20.797
    2851    2913    15.5    20.444
    4126    4464    84.5    31.15

AccBpm =

    0.0022222

toplam_gecis =


    339

fx >> |
```


Şekil 4.26 Komut isteminde hızlanma örüntülerinin elde edilmesi

Hızlanma ve yavaşlama örüntüleri FIGO’da tanımlandığı şekliyle TKH’ye bağlı olarak tespit edilmektedir. Bölüm 3.3.2’de TKH tahmini yapan algoritmaya yer verilmiştir. Şekil 4.27’de ise TKH’ye tahmin ekranı gösterilmiştir. TKH tahmini Bölüm 3.3.2’de belirtilen parametrelere bağlı olarak, parametre değerleri değiştirilip etkileşimli bir şekilde yeniden hesaplanabilmektedir.

TKH tahmini, hızlanma ve yavaşlama örüntülerinin tespitine ilaveten, Bölüm 3.4’de ve Bölüm 3.5’de belirtilen doğrusal ve doğrusal olmayan endekslerin hesaplanması yine gelişmiş analiz işlemleri bölümünde gerçekleştirilmektedir. Buna göre hesaplanan özellikler Şekil 4.28’de gösterilmiştir.




Şekil 4.27 TKH tahmin ekranı

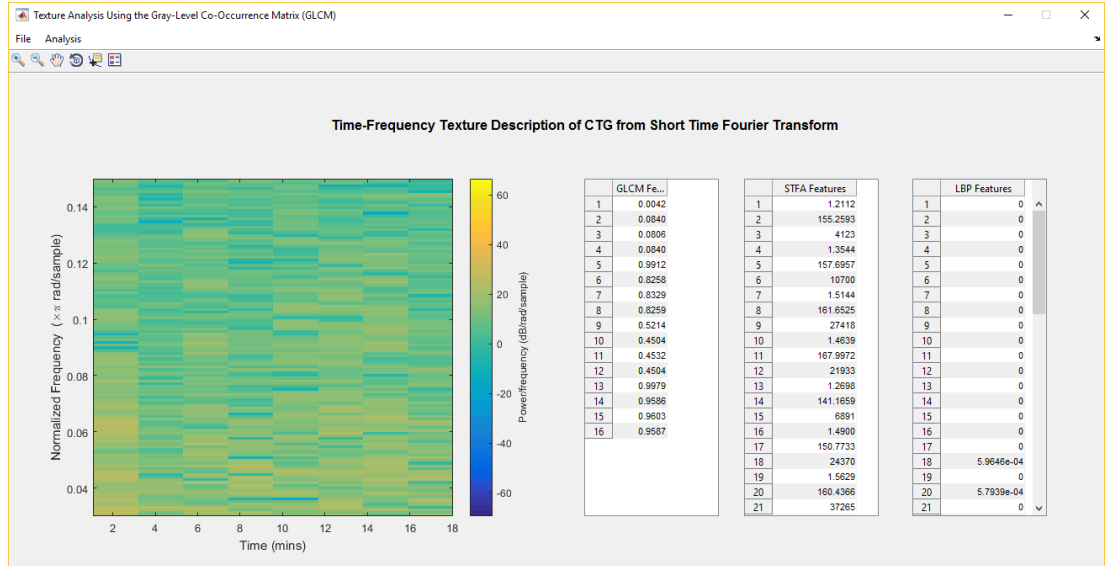


Şekil 4.28 Doğrusal ve doğrusal olmayan özelliklerin hesaplandığı ekran

Bölüm 4.9’da önerilen yeni bir prognostik modelde, İTZF özelliklerinin birer tahmin edici olarak kullanılması önerilmiştir. Bu kapsamda, popüler doku tanımlayıcılarından GSEM, BFDA ve YİD yöntemlerinin kullanılması önerilmiştir. İşaretlere ait bu özelliklerin elde edilmesini sağlayan ekrana ÇDF ve DF için sırasıyla Şekil 4.29 ve Şekil 4.30’da yer verilmiştir.



Şekil 4.29 ÇDF’ye İTZF özellikleri ekranı



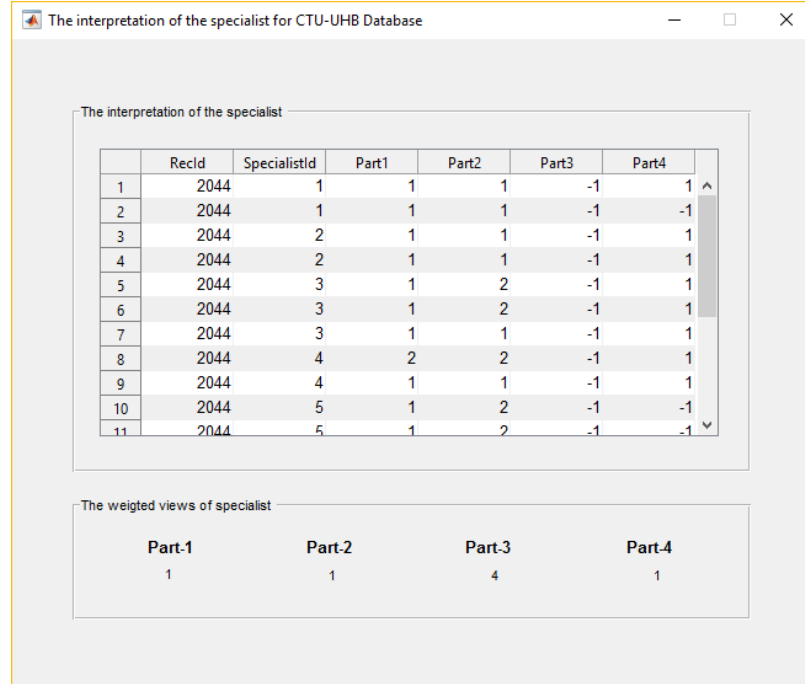
Şekil 4.30 DF’ye İTZF özellikleri ekranı

#### 4.10.5. Çizim İşlemleri

Çizim işlemleri, Şekil 4.20’de gösterildiği üzere sadece FKH işaretinin çizdirilmesi (T), FKH ile birlikte RK işaretinin çizdirilmesi (U) ve FKH işaretinin spektrogramının (V) çizdirilmesi işlemlerinden oluşmaktadır.

#### 4.10.6. Gözlemci Görüşlerinin Değerlendirilmesi

Bir işaretin her bir bölümün normal, şüpheli ya da patolojik olarak değerlendirilmesini sağlamak üzere gözlemci (uzman) görüşlerine (Şekil 4.20,Y) yer verilmiştir. Bu kapsamda, uzmanların çoğunluk oyuna bağlı olarak denetimli öğrenmede kullanılmak üzere işaretler etiketlenmiştir.



	Recid	SpecialistId	Part1	Part2	Part3	Part4
1	2044	1	1	1	-1	1
2	2044	1	1	1	-1	-1
3	2044	2	1	1	-1	1
4	2044	2	1	1	-1	1
5	2044	3	1	2	-1	1
6	2044	3	1	2	-1	1
7	2044	3	1	1	-1	1
8	2044	4	2	2	-1	1
9	2044	4	1	1	-1	1
10	2044	5	1	2	-1	-1
11	2044	5	1	2	-1	-1

Part-1	Part-2	Part-3	Part-4
1	1	4	1


Şekil 4.31 Gözlemci görüşlerinin değerlendirilme ekranı

Şekil 4.31’de örnek bir kayıta ait gözlemci sonuçları gösterilmiştir. Şekilden de anlaşılacağı üzere gözlemciler içi ve gözlemciler arası farklılıkların olduğu açıktır. Gözlemcilerin çoğunluk oyuna bağlı olarak ilgili kayıtın birinci parçası normal (1), ikinci parçası normal (1), üçüncü parçası ise yorumlanamayan (-1) şeklinde etiketlenmiştir. Buna karşın doğum sonucunda arteryal kan parametrelerine bağlı olarak ilgili kayıt gözlemciler tarafından değerlendirildiğinde kaydın normal (1) olduğu ifade edilmiştir.

#### 4.10.7. Sınıflandırma İşlemleri

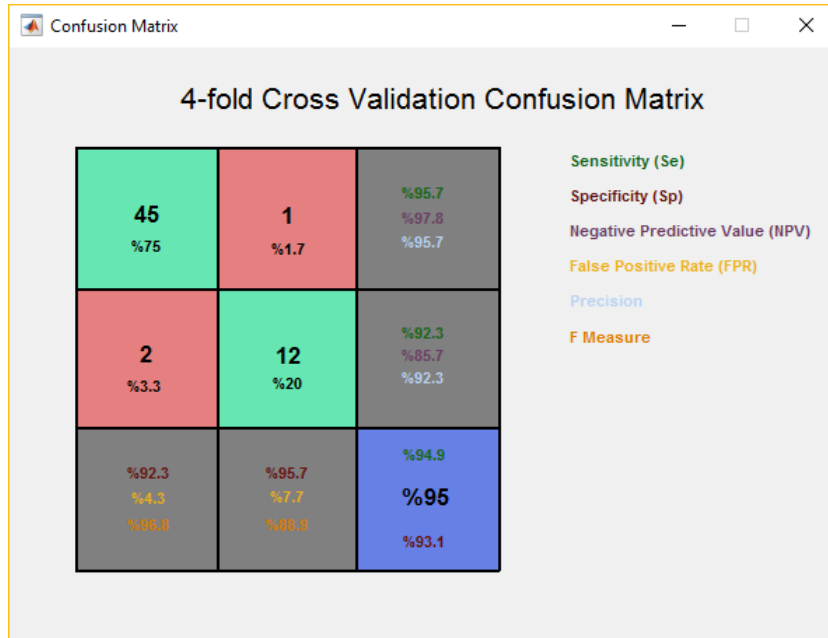
Bu doktora tezi kapsamında, KTG sınıflandırmasını gerçekleştirmek amacıyla YSA, AÖM, DVM, k-EK, RTFA ve RO sınıflandırıcılarının kullanılması sağlanmıştır. Ancak, sadece YSA için bir grafiksel kullanıcı ara yüzü geliştirilmiştir ve geliştirilen ekran Şekil 4.32’de gösterilmiştir. Şekilde 1 numaralı panelde, farklı metotlar kullanılarak elde edilen özellik setlerinin yüklenmesi ve seçime bağlı olarak oluşturan

özellik setinin 4 numaralı panelde TBA ile 2 ya da 3 boyutlu bir eksenle gösterilmesi sağlanmıştır.



Şekil 4.32 YSA sınıflandırma ekranı

2 numaralı panelde ise YSA için eğitim algoritmasının seçilmesi, ağ topolojisinin isteğe bağlı olarak ayarlanması, k-katlı çapraz doğrulamanın gerçekleştirilmesi ve eğitim durumunun izlenmesini sağlayan parametrelerin ayarlanması sağlanmıştır.



Şekil 4.33 YSA için karmaşıklık matrisi ve performans değerlerini gösteren ekran

3 numaralı panelde, YSA eğitimi sonrasında, k-katlı çapraz doğrulamaya bağlı olarak elde edilen performans sonuçları gösterilmiştir. Her bir sonuç sekmesine tıklandığında ise ilgili değerlerin hesaplanmasını sağlayan karmaşıklık matrisinin

gösterilmesi sağlanmıştır. Örneğin Şekil 4.33’de 4. çapraz sorgulama sonucu elde edilen karmaşıklık matrisi gösterilmiştir. En alt satırda ise k-katlı çapraz sorgulama sonucu elde edilen ortalama değerler gösterilmiştir.

#### **4.11. KTG Analizi için Yapılan Diğer Çalışmalar Üzerine Bir Karşılaştırma**

Bilgisayarlı KTG analizi ilk olarak 1960’lı yılların sonlarına doğru duyurulmuştur. Özellikle 1990’lı yılların başlarından itibaren, bu alanda yapılan çalışmalar ciddi oranda arttığı gözlemlenmiştir. Ancak alanda yapılan çalışmalar incelendiğinde, genellikle küçük ve amaca yönelik veri setlerinin kullanıldığı ve açık erişilebilir KTG veri tabanlarının dağıtımının pek de yaygın olmadığı görülmüştür [28], [123]. Çizelge 4.32’de çeşitli çalışmalarda kullanılan veri tabanlarıyla ilgili detaylı bilgilere yer verilmiştir.

KTG analizinde tartışmalı konulardan biri verilerin etiketlenmesidir. Çünkü KTG işaretlerinin normal, şüpheli ya da patolojik olarak sınıflandırılması hususunda genellikle gözlemcilerin değerlendirmelerine başvurulmaktadır [196]. Ancak, gözlemciler arası ve hatta gözlemciler içi değerlendirmede dahi KTG işaretlerinin yorumlanması hususunda yüksek bir değişkenliğin olduğu çeşitli çalışmalarda rapor edilmiştir [63], [190], [197]. Bu nedenle tek bir uzman görüşüne bağlı olarak gerçekleştirilen etiketleme işleminin güvenilirliği şüphe oluşturmaktadır. Ancak unutulmamalıdır ki, denetimli öğrenme yaklaşımında kayıtların kesin olarak etiketlenmesi bir zorunluluktur. Bu nedenle, KTG işaretlerinin etiketlenmesi hususundaki şüpheyi en düşük seviyelere indirmek üzere genellikle birden fazla uzmanın yorumları dikkate alınmakta ve uzmanların çoğunluk oyu ya da ağırlıklı görüşlerine göre işaretlerin etiketlenmesi sağlanmaktadır [80], [189].

Etiketleme işlemi için yaygın olarak kullanılan bir diğer yaklaşım da, doğum sonucunda elde edilen pH, BE, BDecf gibi kan parametrelerine bakılarak işaretin sınıfına karar vermektir. Bu kapsamda, özellikle pH parametresinin yaygın olarak kullanıldığı görülmektedir. Ancak, normal ve patolojik KTG ayrımı yapmak için umbilikal arter pH değeri için uzlaşmış kesin bir değer yoktur. Yenidoğan asidemi tahmini için pH değeri 7,05’in altında olacak şekilde tanımlanmıştır [2]. Ancak farklı çalışmalarda pH ayırım değerinin 7,10 [198] veya 7,15 [58] olması gerektiği tavsiye edilmiştir. Genel kabul, normal bir fetüs için pH değerinin 7,15 altına düşmemesi yönündedir. Bunun dışında, KTG işaretlerinin etiketlenmesini sağlamak üzere

kılavuzlarda tanımlanan kurallara bağlı olarak nöro-bulanık tabanlı yöntemlerin de kullanıldığı görülmüştür [115], [117]. Çizelge 4.33’de çeşitli çalışmaların KTG işaretlerini ayırma kriterleri gösterilmiştir.

Çizelge 4.32 KTG analizi için kullanılan veri setlerine genel bir bakış

Referans	Elde etme	Zaman	Doğum aşaması	Süre	RK	Seçim kriterleri	Klinik bilgi	Örnek sayısı
Nietse ve ark. [193], 1988	X	$\alpha$	I	30	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	50
Chung ve ark. [199], 1995	FEKG	$\alpha$	X	X	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	73
Keith ve ark. [194], 1995	X	$\alpha$	X	>120	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	50
Bernardes ve ark. [33], 1998	US, FEKG	$\gamma$	I,II	-	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	85
Maeda ve ark. [200], 1998	X	$\alpha$	X	50	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	49
Lee ve ark. [201], 1999	FEKG	$\alpha$	X	-	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	53
Chung ve ark. [202], 2001	US	$\gamma$	I,II	X	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	76
Strachan ve ark. [29], 2001	FEKG	$\alpha$	I,II	>30	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	679
Siira ve ark.[203], 2005	FEKG	$\alpha$	I,II	60	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	334
Cao ve ark.[198], 2006	US, FEKG	$\alpha$	X	30	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	146
Salamalekis ve ark. [204], 2006	US	$\alpha$	I,II	X	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	74
Georgoulas ve ark.[69], 2006	FEKG	$\alpha$	I,II	20-60	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	80
Gonçalves ve ark. [68], 2006	US, FEKG	$\alpha$	I,II	32-60	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	68
Costa ve ark. [205], 2009	FEKG	$\alpha$	I,II	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	148
Elliott ve ark. [206], 2010	X	$\alpha$	I,II	>180	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	2192
Warrick ve ark. [171], 2010	US, FEKG	$\alpha$	I,II	>180	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	213
Jezewski ve ark. [207], 2010	US	$\gamma$	X	-	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	749
Helgason ve ark. [208], 2011	FKEG	$\alpha$	I,II	>30	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	47
Chudacek ve ark. [196], 2011	US, FEKG	$\gamma$	I,II	20	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	552
Spilka ve ark. [93], 2012	US, FEKG	$\alpha$	I,II	20	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	217
Georgieva ve ark. [209], 2013	X	$\alpha$	I,II	-	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	124
Czabanski ve ark. [210], 2013	X	$\gamma$	X	60	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	2124

Çizelgede  $\alpha$ , doğum sırasındaki,  $\gamma$  hem doğum sırasındaki hem de doğum öncesindeki dönemi belirtmek üzere kullanılmıştır. X erişilemeyen ya da makalede ifade edilmeyen bilgi anlamına gelmektedir. – ifadesi ise makalede yazarların uzunluk belirtmeden tüm kayıtları kullanıldığı anlamına gelmektedir.  ilgili sütun için pozitif durumu ifade ederken,  ilgili sütun için negatif durumu ifade etmek üzere kullanılmıştır.

Denetimsiz öğrenme yaklaşımında, doğum öncesinde kayıt edilen işaretlerin sahip olduğu örüntü türlerine bakılmaksızın, doğum sonucunda fetüs arteriyel kanındaki pH, BE, BDecf gibi gaz değerine ve bunlara ilaveten Apgar1, Apgar5, Apgar10 ve

yenidoğan ağırlığı gibi parametrelere bağılı olarak bulanık ya da nöro-bulanık yaklaşımlar ile işaretlerin gruplanması sağlanmaktadır [33], [49], [117]. Denetimsiz öğrenme yaklaşımları ile işaretlerin etiketlenmesi sağlandıktan sonra, bu yaklaşıma dayanarak etiketlenen işaretler denetimli öğrenme kapsamında kullanılabilir ve genellikle bu yaklaşımın, sınıflandırma doğruluğunu arttırdığı rapor edilmiştir [115], [118]. Daha önce ifade edildiği gibi, KTG işaretleri harici ya da dahili yolla (Bakınız, Şekil 1.4) elde edilebilir. FKH işaretlerinin harici yolla elde edilmesi için Doppler ultrason (US), dahili yolla elde edilmesi için ise fetal kafa derisi elektrotu kullanılmaktadır. Dahili yolla elde edilen fetal kalp hızı, FEKG işaretinin elde edilmesini sağlamakta ve daha güvenilir bir ölçümle birlikte, yüksek çözünürlüklü bir işaretin de elde edilmesini imkan sağlamaktadır. Dahili yolla elde edilen FKH işareti ise, R-R atımların toplanmasıyla elde edilmektedir. Çeşitli çalışmalarda, US ile elde edilen FKH'nin değişkenlik ve spektral analizi için uygun olmadığı veya yanlış sonuçlar ürettiği ifade edilmiştir [201], [211]. Ancak, Çizelge 4.32'de görüldüğü gibi KTG işaretlerinin analizi için pek çok çalışma, US kullanılarak elde edilen işaretler üzerinde gerçekleştirilmiştir. KTG işaretleri gebeliğin ortalama 28. haftasından itibaren, doğum gerçekleşinceye kadar belirli aralıklarla uygulanmaktadır [13]. Gebelik süresince ve doğum sırasında KTG işaretlerinin karakteristikleri değişkenlik göstermektedir. Doğum öncesi dönemde, KTG işaretleri daha düzenlidir, genellikle yavaşlama örüntüleri bu döneme ait işaretlerde görülmemektedir. RK aktivitesi de daha zayıftır. Bu döneme ait işaretler genellikle, re-aktif ya da non-aktif şeklinde kategorize edilirler ve fetüs için stres oluşturabilecek durumlar bu dönemde daha nadir görülürler. Doğum sırasındaki KTG kayıtları ise daha düzensiz bir karakteristik gösterir, yorumlanması daha güçtür ve benzersiz örüntülerle karşılaşılabılır [197]. RK aktivitesi çok daha yüksektir. Bu nedenle, Çizelge 4.32'de görüldüğü gibi bilgisayarlı KTG analizi çalışmaları genellikle doğum sırasındaki FKH örüntüleri üzerine odaklanmıştır ya da hem doğum sırasındaki hem de doğum öncesindeki döneme ait kayıtlar birlikte değerlendirilmiştir. KTG analizi için bir diğer önemli konu analiz edilen testin süresidir. Kliniksel olarak geçerli bir KTG testinin, gebelik döneminde ortalama 20 – 30 dk arasında sürmesi yeterli görülürken; doğum sırasında ise sürekli bir izleme gerçekleştirilir [9]. Doğum dönemine ait kayıtlar üzerinde makine öğrenmesine dayalı bir analiz gerçekleştirilecek ise öncelikle doğumun hangi aşaması üzerinde analizin yapılacağı ifade edilmelidir. Bununla birlikte analiz edilen tüm



işaretlerin uzunlukları aynı olmalıdır. Çizelge 4.32’de görüldüğü gibi genellikle KTG analizi için işaret uzunluğunun 20 – 30 dk arasında olduğu görülmektedir.

Çizelge 4.33 KTG analizi için kullanılan veri setlerine dair ek bilgiler

Referans	Sınıflar	Sınıflar için bölme kriterleri	Sınıf #	Sınıf Başına Kayıt #
Nietse ve ark. [193], 1988	N, P	Apgar 1 <7 veya pH <7.15 veya BE<-10	2	34;16
Chung ve ark. [199], 1995	N,AN	pH < 7.15	2	65;8
Keith ve ark. [194], 1995	5-aşamalı değ.	17 klinisyen, pH, BDecf, Apgar	5	38;12
Bernardes ve ark. [33], 1998	N, Ş, P	pH, Apgar, Neonatoloji	3	56;22;7
Maeda ve ark. [200], 1998	N, Ş, P	Manuel klinik kurallar	3	12;18;19
Lee ve ark. [201], 1999	N, Decels.	1 klinisyen	2	X
Chung ve ark. [202], 2001	N, S, A	Norm. FKH ve pH>7.15; ve pH<7.15	3	36;26;14
Strachan ve ark. [29], 2001	N, AN	pH≤7.15 ve BDecf>8	2	608;71
Siira ve ark.[203], 2005	N, A	pH<7.05	2	319;15
Cao ve ark.[198], 2006	G+, G-	2 klinisyen	2	102;44
Salamalekis ve ark. [204], 2006	Normal, G-	FIGO, pH<7.20	2	32;42
Georgoulas ve ark.[69], 2006	N, R	pH>7.20; pH<7.10	2	20;60
Gonçalves ve ark. [68], 2006	N, OA, A	pH>7.20; pH>7.10 ve pH<7.20; pH≤7.10	3	48;10;10
Costa ve ark. [205], 2009	Omniview-SisPorto 3.5 uyarıları	pH<7.05	2	7;141
Elliott ve ark. [206], 2010	N, AN	BDecf≥12 & NE	2	60;2132
Warrick ve ark. [171], 2010	N, P	BDecf<8; BDecf≥12	2	187;26
Jezewski ve ark. [207], 2010	N, AN	Apgar X < 7 veya doğum ağırlığı < 10. per. Veya pH<7.2	2	539;210
Helgason ve ark. [208], 2011	FIGO-TN FIGO-FP FIGO-TP	Normal FKH & pH≥7.30; anormal & pH ≥7.30; anormal & pH≤7.05	3	15;17;15
Chudacek ve ark. [196], 2011	N, Ş, P	3 klinisyen	3	139;306; 107
Spilka ve ark. [93], 2012	N, P	pH<7.15	2	123;94
Georgieva ve ark. [209], 2013	N, O-	pH<7.1 ve Neonatoloji	2	62;62
Czabanski ve ark. [210], 2013	N, AN	Apgar 10 < 5	2	X

Tabloda sınıf sütununda kullanılan kısaltmalar: Normal (N), Şüpheli (Ş), Patolojik (P), Anormal (AN), Stresli (S), Asidemik (A), Orta Şiddetli Asidemik (OA), Güven verici (G+), Güven vermeyen (G-), Riskli (R), Olumsuz (O-). X erişilemeyen ya da makalede ifade edilmeyen bilgi anlamına gelmektedir.

KTG analizi yapılırken her ne kadar daha çok FKH karakteristiği üzerinde durulsa da, RK aktivitesi özellikle doğumun başlangıcına karar verme noktasında önemli bilgiler taşımaktadır [111]. Bu kapsamda, RK işaretinin FKH ile ilişkili olduğu ve özellikle yavaşlama örüntülerinin RK ve FKH arasındaki ilişkiye bağlı olarak kategorize edildiği bilinmektedir [109]. Buna rağmen, literatürdeki çalışmalar çoğu zaman RK işaretlerinin analizini göz ardı etmektedir.

Bilgisayarlı KTG analizi kapsamında bir diğer önemli konu veri setini oluştururken seçilen kayıtların seçim ölçütlerinin belirtilmesidir. Veri seti oluşturulurken teknik (işaret uzunluğu, kayıp atım oranı, işaret-gürültü oranı, örnekleme frekansı..) ve klinik (gebelik yaşı, gebelik türü, fetüs cinsiyeti, risk faktörleri, ilaç kullanımı...) ölçütler dikkate alınmalıdır. Çizelge 4.32’de ifade edildiği gibi pek çok çalışmada bu bilgilerin eksikliği görülmektedir.

Makine öğrenmesine dayalı KTG analizini için başlıca dikkat edilmesi gereken konulardan biri de eğitim ve test için kullanılan veri seti sayısı, verilerin kullanım şekli ve verilerin sınıflar arasındaki dağılımıdır. Bu nokta o kadar önemlidir ki, çalışma sonucunda elde edilecek tüm sonuçları da doğrudan etkilemektedir [161]. Çizelge 4.33’de görüldüğü gibi KTG işaretleri normal (N), şüpheli (Ş), patolojik (P), anormal (AN), stresli (S), asidemik (A), güven verici (G+), güven vermeyen (G-), riskli (R) ve olumsuz (O-) gibi sınıflara ayrıldığı görülmektedir. Genel yaklaşım, işaretlerin analizini gerçekleştirirken büyük oranda 2’li ya da bazen de 3’lü sınıf kullanma yönündedir.

Çizelge 4.33 incelendiğinde KTG verilerinin genel olarak sınıflar üzerinde dengesiz dağılım sergilediği görülmektedir, bir başka ifadeyle her sınıfta eşit sayıda kayıt genellikle yoktur. Bu durum makine öğrenmesi açısından doğruluk, duyarlılık ve özgüllük gibi metriklerin yanıltıcı sonuçlar üretmesine neden olabilmektedir [182]. Bu kapsamda, özgüllük ve duyarlılık metriklerinin geometrik ortalamasını ifade eden kalite endeksi ve AİK eğrilerinin kullanılması hatalı yorumların yapılmasını engelleyecektir [181].

Tutarlı bir KTG analizi gerçekleştirmek üzere çeşitli sağlık örgütleri tarafından KTG işaretlerinin şekil ve değişimine dayalı farklı değerlendirme ölçütlerine sahip kılavuzlar hali hazırda yayımlanmış durumdadır [11], [18], [19], [21]–[23]. Öte

tarafından tüm otoriteler tarafından kabul edilmiş tek bir standart hala yoktur. Bu durum bilgisayar destekli çalışmalarda da değişkenliğe sebebiyet vermektedir.

Bilgisayar destekli çalışmalarda, özellikle FKHD analizinde ciddi çatışmaların olduğu rapor edilmiştir [108]. Kalp hızı değişkenliğinin incelenmesinde, GSY analizi bazal kalp hızındaki periyodik değişiklikleri ölçme amacıyla kullanılmaktadır. Yetişkinler için sempatik ve parasempatik sinir sistemleriyle solunum gibi fizyolojik olaylar arasındaki ilişkilerin frekans aralıkları tanımlanmış durumdadır. Fetal kalp hızı analizinde ise fetal solunum aktivitesi, anne solunumu ve fetal hareketlerin spektral aralıkları gebelik yaşıyla ilişkilendirilmiştir ancak bu konuda kesin bir standart hala yoktur [211]. Örneğin spektral alanda GSY'ye bağlı yapılan tahminlerde ÇDF aralığı için bazı çalışmalar 0 – 0.03 Hz aralığını geçerli kabul ederken bazı çalışmalarda bu aralık 0 – 0.04 Hz ya da 0 – 0.05 Hz arasında da değerlendirilmiştir [40], [212], [213]. Benzer şekilde OF için 0.15 – 0.5 veya 0.2 – 0.4 Hz aralığı da kullanılmıştır [55], [75].

Güçlü makine öğrenmesi teknikleri, gelişmiş işaret işleme ve örüntü tanıma yöntemleriyle birlikte KTG işaretlerini analiz etmek üzere sayısız çalışmada kullanılmasına rağmen, bu yaklaşımlardan herhangi biri henüz standart olarak kabul edilmemiştir. Bu problem hala ciddi bir araştırma başlığı olarak literatürdeki yerini korumaktadır. Bilgisayarlı KTG analizi yaklaşımlarında ilk adım genellikle morfolojik özelliklerin tespitine odaklanmaktadır ve genellikle en efektif sonuçlara morfolojik özelliklerin kullanılmasıyla erişilmektedir [47]. Bunun dışında dalgacık dönüşümü (DD) ve DMA gibi çeşitli dönüşüm teknikleri kullanılarak zaman alanında gözlenemeyen niteliklerin ortaya çıkartılmasını sağlamak üzere çeşitli çalışmalar yürütülmüştür. DMA yöntemi, FKH işareti üzerindeki gürültü sorununu gidermek ve özellik çıkarmak amacıyla çeşitli çalışmalarda kullanılmıştır [214]. Çizelge 4.34'de çeşitli gelişmiş metotlar ve makine öğrenmesi teknikleri kullanılarak gerçekleştirilen çalışmalara yer verilmiştir.

Çizelge 4.34'de görüldüğü üzere Magenes ve arkadaşları [49], çok katmanlı algılayıcı ağ ve uyarlanabilir bulanık-sinir çıkarım sistemi tabanlı iki farklı yaklaşım KTG işaretlerini normal ve patolojik olarak sınıflanmışlardır. Çok katmanlı algılayıcı ağ ile %76,1 duyarlılık ve %83,3 özgüllük değeri rapor edilmiştir.

Çizelge 4.34 Makine Öğrenmesi Tekniklerinin Karşılaştırılması

Araştırmacılar ve Yöntemler	Dönem	Kayıt Sayısı	Süre (dk.)	Sınıf Sayısı	Kayıt Sayısı	Erişim?	DĞR (%)	DUY (%)	ÖZG (%)	GO (%)
Magenes ve arkadaşları [49], Morfolojik, zaman, frekans ve YaEn, ÇKA-SA, UBSÇS, t-test, F- test, TBA	a	362	30	2	200 162	<input type="checkbox"/>	-	76,60	59,90	67,7*
Georgoulas ve arkadaşları [66], ADD, DVM	i	80	5	2	60 20	<input type="checkbox"/>	88,7	75,0	93,3	83,6
Georgoulas ve ark.[69], Zaman- Frekans analizi, DVM	i	80	20	2	60 20	<input type="checkbox"/>	81,25	70,00	85,00	77,14
Jezewski ve ark. [207], morfolojik ve zaman alanı endeksleri, YSA	a,i	749	-	2	749 210	<input type="checkbox"/>	72,1	71,3	72,5	71,8*
Krupa ve arkadaşları [86], DMA, DVM, 5-KÇD	a	90	20	2	64 26	<input type="checkbox"/>	87,0	87,0	81,5	81,5
Czabanski ve arkadaşları [33], bulanık sistem, YSA ve LDVM	a	189	60	2	146 43	<input type="checkbox"/>	92,0	82,4	94,8	88,2
Spilka ve ark. [93], doğrusal olmayan özellikler, DVM	i	217	20	2	123 94	<input type="checkbox"/>	-	73,4	76,3	74,8*
Georgieva ve ark. [209], geleneksel ve klinik özellikler, YSA	i	124	-	2	64 64	<input type="checkbox"/>	63,8*	60,3	67,5	63,7*
Jezewski ve arkadaşları [118], c- ortalama bulanık sistem	i	551	-	2	323 228	<input checked="" type="checkbox"/>	70,68	59,61	78,46	68,29

\* Makalenin orijinalinde olmayan ve makalede verilen bilgilere göre hesaplanmış değerleri temsil etmektedir. Doğum sırasındaki (intrapartum) dönemi ifade etmek için i, gebelik dönemini ifade etmek için (antepartum), a ifadesi kullanılmıştır.

Georgoulas ve arkadaşları [69], özellik çıkarımı için ADD, sınıflandırma için DVM tabanlı bir analizi, farklı özellik setleri ve işaret uzunluklarına bağlı olarak gerçekleştirmişlerdir. Araştırma sonucunda en yüksek doğruluk %88,7 ve geometrik ortalama %83,6 olarak rapor edilmiştir. Georgoulas ve arkadaşları [69], zaman, frekans ve morfolojik alandan elde edilen prognostik göstergeler ile DVM kullanarak KTG işaretlerini sınıflandırmış ve %81,2 doğruluk ile %77,1 geometrik ortalama başarımını bildirmişlerdir. Jezewski ve arkadaşları [207], morfolojik ve zaman alanından elde edilen toplam 17 adet özellik ile YSA kullanarak KTG işaretlerini sınıflandırmış ve %71,3 duyarlılık ve %72,5 özgüllük değerlerini elde etmişlerdir. Krupa ve arkadaşları [86], özellik çıkarımı için DMA ve sınıflandırma için DVM kullanarak, doğum öncesi döneme ait toplam 90 kayıt üzerinde bir analiz gerçekleştirmiş ve %81,5'lik geometrik ortalama değerine erişmişlerdir. Czabanski ve arkadaşları [33], araştırmalarında iki-aşamalı bir sınıflandırma prosedürü yürütmüşlerdir. Birinci aşamada işaretlerin sınıflandırılması için 4 farklı bulanık analiz gerçekleştirilmiştir. Temel amaç normal fetüslerin olası en iyi şekilde ayrılmasını sağlamaktır. İkinci aşamada, sadece anormal olarak etiketlenen işaretlerin analiz edilmesi sağlanmıştır ve %82,4 duyarlılık ve %94,8 özgüllük değeri elde edilmiştir. Spilka ve arkadaşları [93], morfolojik ve doğrusal olmayan özelliklere dayalı gerçekleştirdikleri analiz sonucunda %73,4 duyarlılık ve %76,3 özgüllük değeri elde etmişlerdir. Georgieva ve arkadaşları [209], 6 adet işaret, 6 adet kliniksel olmak üzere 12 adet parametreyi dikkate alıp YSA ile bir sınıflandırma gerçekleştirmişlerdir ve araştırma sonucunda %60,3 duyarlılık ve %67,5 özgüllük değeri raporlanmıştır. Jezewski ve arkadaşları [118], bulanık c-ortalama (BCO) yaklaşımı ile CTU-UHB veri tabanındaki işaretleri analiz etmiş, %68,29 kalite endeksine erişmişlerdir.

Çizelge 4.34'de genellikle ham KTG işaretlerinin işlendiği görülmektedir. Bu kapsamda, morfolojik alandan elde edilen tahmin edicilerin ortak olarak kullanıldığı görülmüştür. Ayrıca, araştırmalar için kullanılan veri setlerinin genellikle küçük boyutta olduğu, amaca yönelik kullanıldığı ve dağıtımının yapılmadığı da gözlemlenmiştir. Bir diğer önemli konu verilerin sınıflar üzerindeki dengesiz dağılımıdır. Pek çok çalışmada bu durum net bir şekilde görülmektedir.

Çizelge 4.35'de ise UCI-KTG veri seti kullanılarak gerçekleştirilmiş çeşitli çalışmalara yer verilmiştir.

Çizelge 4.35 UCI-KTG veri seti üzerinde yapılan çalışmalar

Araştırmacılar ve yöntem	Yazılım	Sınıf Sayısı	Özellik Sayısı	DĞR (%)	DUY (%)	ÖZG (%)	GO (%)
Huang ve Hsu [90], YSA, KA	M	3	11	86,2*	71,3*	80,3*	75,7*
Tomas ve arkadaşları [215], RO	W	3	7	93,7	84,6*	89,8*	87,2*
Yılmaz ve Kılıkçier [216], EK-DVM	M	3	21	91,6	81,4*	86,9*	84,1*
Ocak ve Ertunç [96], uyarlamalı bulanık girişim sistemi	M	2	21	97,1	97,2	96,6	96,9
Das ve arkadaşları [217], FURIA	W	3	21	94,6*	92,7*	93,6*	93,1*
Menai ve arkadaşları [218], özellik seçim algoritmaları, Naive Bayes sınıflandırıcısı	-	3	15	93,9	91,6	95,8	93,7*
Ocak H [97], GA ve DVM	M	2	13	-	99,3	100	99,7*
Ocak ve Ertunç [96], UBSCS	M	2	21	97,2*	97,2*	96,6*	96,9*
Karabulut ve İbrikçi [102], topluluk tabanlı KA	W	3	21	95,0	90,0*	92,8*	91,4*
Shah ve arkadaşları [107], topluluk tabanlı KA, korelasyon özellik seçimi	W	3	7	93,9	88,5*	-	-
Ravindran ve arkadaşları [105], TBA, GUGA, AÖM	-	3	13	93,6	86,7*	90,4*	85,6
Sahin ve Subaşı [106], 8 farklı sınıflandırıcı	W	2	21	99,2	99,7	94,1	96,9*
Jezewski ve arkadaşları [118], c-ortalama tabanlı bulanık sistem	-	3	21	87,8	-	-	92,9
Yılmaz [114], MLPNN	M	3	21	90,4	78,7	90,5	84,4
Yılmaz [114], PNN	M	3	21	91,9	82,8	92,2	87,4
Yılmaz [114], GRNN	M	3	21	95,1	83,9	92,6	88,2

\* ifadesi makalede verilen karmaşıklık matrisi veya diğer performans ölçütleri kullanılarak hesaplanmıştır. Yazılım sütunundaki M Matlab yazılımını W ise WEKA yazılımını temsil etmek üzere kullanılmıştır. – ise makalede raporlanmamış bilgiyi ifade etmek üzere kullanılmıştır.

Huang ve Hsu [90] çalışmalarında DA, KA ve YSA tekniklerini KTG işaretlerini sınıflandırmak üzere istihdam etmiş ve en iyi sonuçlara YSA ile erişmelerine rağmen KA'nın kararlılığını çalışmalarında vurgulamışlardır. Neticede, %75,7 GM değerine KA sınıflandırıcısıyla erişilmiştir. Sundar ve arkadaşları [92], YSA'ya dayalı bir model ile işaretleri analiz etmiş ve sırasıyla normal, şüpheli ve patolojik örüntüler için %96,66, %58,97 ve %97,06 duyarlılık ile %97,84, %45,14 ve %97,24 F-skor değerlerini rapor etmişlerdir. Tomas ve arkadaşları [215], RO, RepTree ve DDA algoritmaları ile KTG işaretlerini sınıflandırmışlardır. Veri işleme aşamasında korelasyon özellik seçimi uygulanarak, özellik setinin boyutu 21'den 7'ye indirgenmiş ve RO algoritması ile %87,16'lık GM değerine erişilmiştir. Yılmaz ve Kılıkçer [216], çalışmalarında parçacık sürü optimizasyonu yöntemiyle EK-DVM parametrelerini optimize edip KTG işaretlerini sınıflandırmışlardır ve araştırma sonucunda %84,1 GM değeri elde edilmiştir. Das ve arkadaşları [217], bulanık düzensiz kural induksiyon algoritması ile KTG işaretlerini kategorize etmiş ve %91,3 GM değerine ulaşmışlardır. Menai ve arkadaşları [218], dört farklı özellik seçimi algoritmasının Naive Bayes sınıflandırıcısı kullanarak KTG işaretlerini kategorize etmedeki etkisini incelemişlerdir ve araştırma sonucunda 15 özellik ile %93,7 GM değerine erişmişlerdir. Ocak [97] çalışmasında özellik seçimi için GA, sınıflandırma için DVM kullanarak iki sınıflı bir analiz gerçekleştirmiş ve %99,7 GM değeri rapor etmiştir. Ocak ve Ertunç [96] fetal durumunun değerlendirilmesini sağlamak üzere UBSCS önerisinde bulunup, %96,9 GM değeri elde etmişlerdir. İbrikçi ve Karabulut karar ağaçlarına dayalı uyarlamalı topluluk yaklaşımı ile %95,01 doğruluk değerine ulaşmışlardır. Karabulut ve İbrikçi [102] KA'ya dayalı uyarlamalı bir yükseltme topluluğunu bir sınıflandırıcı olarak kullanmışlardır ve %91,36 GM değerini rapor etmişlerdir. Shah ve arkadaşları [107], torbalama yaklaşımını ile RO, REPTree ve J48 algoritmalarını sınıflandırıcı olarak kullanmışlardır. Korelasyon tabanlı özellik seçimi uygulanarak, toplam 21 olan özellik uzayı boyutu 7'ye çekilmiş ve en iyi sınıflandırıcı RO olarak belirtilip, %93,93'lik doğruluk değeri rapor edilmiştir. Ravindran ve arkadaşları [105], GUGA tekniği ve AÖM makinesini kullanarak %85,57 GM değeri rapor etmişlerdir. Şahin ve Subaşı [106], 8 farklı makine öğrenmesi tekniği kullanarak ikili bir sınıflandırma gerçekleştirmiş ve en verimli sınıflandırıcı olarak RO'yu belirtip, %96,9 GM değeri elde etmişleridir. Jezewski ve arkadaşları (Michal Jezewski et al. 2016), önerdikleri BCO yaklaşımı ile UCI-KTG veri setini analiz etmiş ve %92,91 GM başarımına ulaşmışlardır.

## 5. SONUÇ VE ÖNERİLER

Bu doktora tez çalışmasında, öncelikle KTG işaretlerinin biyofiziksel temeli incelenmiştir. KTG işaretinin sahip olduğu avantaj ve dezavantajlar açıkça listelenerek, bilgisayarlı KTG analizinin kliniksel gerekliliği, özellikle tutarlı ve yeniden üretilebilir değerlendirme sonuçlarının elde edilmesini açısından belirgin bir şekilde ortaya konmuştur. Geniş ölçekli bir literatür çalışması gerçekleştirilerek, bilgisayarlı KTG analizi kapsamında yapılan çalışmalar sistematik bir şekilde özetlenmiştir. Literatürde görüldüğü gibi, aynı zamanda tez çalışmasında da açıkça vurgulandığı üzere, bilgisayarlı KTG analizi, KTG testinin sahip olduğu problemlerin üstesinden gelmek üzere en umut verici yöntem olarak kabul edilmiştir.

Tez çalışması kapsamında gerçekleştirilen deneysel çalışmalar, iki farklı veri kaynağı üzerinde yürütülmüştür. Bunlardan birincisi, dünyada en yaygın şekilde kullanılan, ticarileşmiş bir yazılım olan SisPorto® tarafından sağlanan ve 21 özellik ile 2126 işaret örneğini tanımlayan bir veri seti olan UCI-KTG'dir. Özellik seçimi ve farklı sınıflandırma algoritmalarının performansını ölçmek üzere bilhassa bu veri setinden istifade edilmiştir. Daha sonra, açık erişilebilir durumda olan ve Physionet'in altında bulunan CTU-UHB veri tabanında yer alan ham KTG işaretlerine odaklanılmıştır. Bu veri tabanı için denetimli öğrenme açısından gerekli olan etiketleme işlemi, tüm gözlemcilerin değerlendirmeleri dikkate alınarak, çoğunluk oyuna göre gerçekleştirilmiştir. Deneysel çalışmaların çok büyük bir çoğunluğu gerek özellik çıkarma, gerekse özellik seçimi ve sınıflandırma için bu veri tabanı üzerinde gerçekleştirilmiştir.

Önişleme aşaması, başlıca işaret üzerindeki güvenilir alanların saptanması, aykırılıkların taranması ve gürültü probleminin giderilmesi prosedürlerinden oluşturulmuştur. Ham KTG işaretleri üzerinde, uygulanan önişleme prosedürlerinden sonra işaretler analiz edilmeye hazır hale getirilmiş, güvenilir ve gürültüden arındırılmış KTG işaretlerine erişilmiştir. Bu aşamada, KTG işaretlerinin doğasına uygun olarak, güvenilir bir önişleme için gerekli prosedürler tanımlanmış ve uygulanmıştır.

Bilgisayarlı KTG analizi yaklaşımıyla işaretleri analiz etmek üzere ilk adımında, kliniksel açıdan vazgeçilmez olan TKH, hızlanma ve yavaşlama örüntülerinin sayısı gibi morfolojik özelliklerin tespit edilmesi sağlanmıştır. Deneysel çalışmalar



neticesinde en yüksek sınıflandırma doğruluğuna her zaman morfolojik özelliklerin özellik setine eklenmesiyle erişilmiştir. Bu nedenle bu özelliklerin bilgisayarlı KTG analizi için vazgeçilmez olduğu sonucuna varılmıştır.

Daha sonra makine öğrenmesi tekniklerinin kullanılması aşamasında, işaretleri tanımlamak üzere doğrusal ve doğrusal olmayan alanlardan, FKH işaretlerinin daha iyi bir şekilde karakterize edilmesini sağlayan ve literatürde yaygın olarak kullanılan özelliklerin çıkartılması sağlanmıştır. Doğrusal özelliklerin sınıflandırma doğruluğunu arttırdığı görülmüştür. Özellikle doğum sırasındaki döneme ait işaretler üzerinde, doğrusal olmayan alanlardan elde edilen prognostik endekslerin sınıflandırma doğruluğuna ciddi katkı sağladığı görülmüştür.

ADD yardımıyla FKH işaretlerinin farklı çözünürlüklerde ve farklı seviyelerde analiz edilmesi sağlanarak, zaman ölçeğine bağlı özelliklerin irdelenmesi sağlanmıştır. FKH işaretleri farklı dalgacık aileleriyle yakınsama ve detay bileşenlere ayrıştırılmış ve elde edilen bu alt-bantlardan çıkartılan istatistiksel özellikler ile işaret karakterizasyonu desteklenmiştir. Deneysel çalışmalar neticesinde, normal ve hipoksik fetüslerin tespiti açısından alt-bantlardan elde edilen istatistiksel özelliklerin sınıflandırma doğruluğunu arttırdığı sonucuna varılmıştır.

Spektral alanda, FKH işaretleri sahip olduğu doğal karakteristik yapıya uygun olarak işaretler ÇDF, DF, OF ve YF olmak üzere 4 farklı deneysel bant aralığında incelenmiş ve GSY değerleri hesaplatılmıştır. Bu değerler makine öğrenmesi algoritmalarına girdi olarak uygulanmak üzere özellik setine eklenmiştir. İyi bir işaret karakterizasyonu için bant gücünün kullanılmasının faydalı olduğu tarafımızca rapor edilmiştir.

KTG işaretlerinin tanımlanmasını sağlamak üzere, yukarıda ifade edildiği gibi morfolojik, doğrusal–doğrusal olmayan ve dalgacık alanından çeşitli tahmin ediciler elde edilmiştir. Bunlara ek olarak tez çalışması kapsamında önerilen yeni bir prognostik model yaklaşımıyla popüler doku tanımlayıcıları olan GSEM, BFDA ve YİD teknikleri İTZF özelliklerinin elde edilmesini sağlamak üzere kullanılmıştır. ÇDF, DF, OF ve YF bantlarında ayrı ayrı uygulanan bu özellikler, işaretleri tanımlayan pek çok istatistiksel değerlerin elde edilmesini sağlamıştır. Geleneksel özellikler ile kombine edilen İTZF özelliklerinin son derece umut verici sonuçlara erişilmesinde

önemli derecede katkı sağladığı görülmüştür. Özellik seçimi için uygulanan filtreme yaklaşımı sonucunda  $\delta = 1$ ,  $\theta = 0, 45, 90, 135$  parametreleri için GSEM tarafından sağlanan kontrast özelliklerinin tümünün ve yine  $\delta = 1$  ve  $\theta = 90$  parametreleri için GSEM tarafından sağlanan kontrast, korelasyon, enerji ve homojenlik değerlerinin hipoksik fetüsleri normal fetüslerden ayırt etme noktasında sağlam bir ayırım gücünün olduğu sonucuna varılmıştır.

Geniş kapsamda yürütülen özellik çıkarma aşamasından sonra GDÖS, *t*-testi ve TBA yardımıyla özellik seçimi prosedürünün yürütülmesi sağlanmıştır. GDÖS algoritması yardımıyla özellik setinin boyutu 93'den 30'a indirilmiştir. Daha sonra daha önceki bölümlerde ifade edilen tüm alanlardan elde edilen toplam 93 özelle birlikte DVM kullanılarak erişilen %86,86'lık GM değeri,  $p < 0.01$  ve  $p < 0.05$  hipotez değerleri ile sıralanan sırasıyla 22 ve 30 özellik ile %85,46 ve %85,99 olarak elde edilmiştir.

DeneySEL çalışmalar kapsamında sınıflandırma işlemini yürütmek üzere YSA, AÖM, DVM, k-EK, RTFA ve RO algoritmaları kullanılmıştır. Sınıflandırıcıların performans değerleri birbirleriyle karşılaştırılmıştır. Genel olarak en verimli sonuçlara DVM ve YSA ile erişilmiştir. Diğer sınıflandırıcıların da tatmin edici sonuçlar ürettiği görülmüştür.

Son olarak, literatürde yer alan çalışmalar verilerin toplanma şekli, kullanılan kayıt sayısı, dikkate alınan kayıt süresi, kayıtların sınıflara göre dağılımı, kayıtların işaretlenme kriterleri, RK kayıtlarının dikkate alınıp alınmaması, odaklanılan doğum aşaması, klinik ve teknik bilgilerin yer alıp almaması ve doğruluk, duyarlılık, özgüllük ve geometrik ortalama gibi performans değerlerine bağlı olarak derlenmiştir. Önerilen prognostik modelin ilgili çalışmalar ile karşılaştırılması sağlanmıştır.

Yürütülen deneysel çalışmalarında dışında, akademik amaçlarla kullanılmak üzere yeni bir KTG analiz yazılımı geliştirilmiştir. Yazılım MATLAB® GUIDE ortamında tasarlanmıştır. Dosyalama, önişleme, özellik çıkarımı, özellik seçimin ve sınıflandırma prosedürlerini içeren yazılım kod karmaşasını elemine ederek KTG işaretlerinin objektif bir şekilde kullanılmasını sağlamaktadır.

Sonuç olarak, bu doktora tez çalışması kapsamında KTG işaretlerinin makine öğrenmesi teknikleriyle sınıflandırılması sağlanarak bir KTG analiz yazılımının gerçekleştirilmesi sağlanmış ve oldukça umut verici sonuçlara erişilmiştir.

Gelecek süreçte, tez çalışması kapsamında yapılan literatür incelemeleri sonucunda, oldukça belirgin bir şekilde görülen “*Açık Erişimli KTG İşaretlerinin Dağıtımı*” konusuna odaklanılacaktır. Bu kapsamda, gerek klinik gerekse teknik açıdan tespit edilen tüm parametreler dikkate alınarak farklı nitelik ve karakterlere sahip açık erişimli KTG veri tabanlarının oluşturulması ve ücretsiz bir şekilde dağıtılması hedeflenmektedir. Bu amaca ulaşmak üzere bir “*Çevrimiçi KTG Analiz Platformu*” oluşturulacaktır. İlaveten, bu platformda bu tez çalışması kapsamında geliştirilen KTG analiz yazılımının araştırmacıların istifadesine sunulması düşünülmektedir. Ayrıca, zengin web araçları ile bu alanda çalışan araştırmacılar için yüksek etkileşime sahip bir topluluk oluşturulması da hedeflenmektedir.

## 6. KAYNAKAR

- [1] D. J. Jagannath and A. I. Selvakumar, *Issues and research on foetal electrocardiogram signal elicitation*, **Biomed. Signal Process. Control**, 10 (2014) 224–244.
- [2] A.-K. Sundström, D. Rosén, and K. G. Rosén, *Fetal surveillance*, Neoventa Medical AB, 2005 .
- [3] M. J. Stout and A. G. Cahill, *Electronic Fetal Monitoring: Past, Present, and Future*, **Clin. Perinatol.**, 38:1 (2011) 127–142.
- [4] *ACOG Practice Bulletin No. 106: Intrapartum fetal heart rate monitoring: nomenclature, interpretation, and general management principles*, **Obstet. Gynecol.**, 114:1 (2009) 192–202.
- [5] K. H. Hokegard, B. O. Eriksson, I. Kjellmer, R. Magno, and K. G. Rosen, *Myocardial metabolism in relation to electrocardiographic changes and cardiac function during graded hypoxia in the fetal lamb.*, **Acta Physiol. Scand.**, 113:1 (1981) 1–7.
- [6] R. M. Grivell, Z. Alfirevic, G. M. Gyte, and D. Devane, *Antenatal cardiotocography for fetal assessment.*, **Cochrane database Syst. Rev.**, :1 (2010) 1–48.
- [7] K. G. Goldaber, L. C. 3rd Gilstrap, K. J. Leveno, J. S. Dax, and D. D. McIntire, *Pathologic fetal acidemia.*, **Obstet. Gynecol.**, 78:6 (1991) 1103–1107.
- [8] Z. Alfirevic, D. Devane, and G. M. L. Gyte, *Continuous cardiotocography (CTG) as a form of electronic fetal monitoring (EFM) for fetal assessment during labour*, **Cochrane database Syst. Rev.**, :3 (2006).
- [9] A. Pinas and E. Chandrachan, *Continuous cardiotocography during labour: Analysis, classification and management*, **Best Pract. Res. Clin. Obstet. Gynaecol.**, 30 (2016) 33–47.
- [10] S. P. von Steinburg *et al.*, *What is the “normal” fetal heart rate?*, **PeerJ**, 1 (2013) e82.
- [11] J. Kottner *et al.*, *Guidelines for Reporting Reliability and Agreement Studies (GRRAS) were proposed*, **J. Clin. Epidemiol.**, 64:1 (2011) 96–106.
- [12] J. Spilka, *Complex approach to fetal heart rate analysis: A hierarchical classification model*, PhD Thesis, Czech Technical University Prague, 2013.
- [13] P. J. Steer and R. W. Beard, *Fetal Heart Monitoring*, **Br. Med. J.**, 3:5977 (1975) 236.
- [14] H. P. van Geijn, *2 Developments in CTG analysis*, **Baillieres. Clin. Obstet. Gynaecol.**, 10:2 (1996) 185–209.
- [15] T. P. Sartwelle, *Electronic fetal monitoring: a bridge too far.*, **J. Leg. Med.**, 33:3 (2012) 313–379.
- [16] R. Goddard, *Electronic fetal monitoring. Is not necessary for low risk labours*, **BMJ**, 322:7300 (2001) 1436–1437.
- [17] L. Borgatta, P. E. Shrouf, and M. Y. Divon, *Reliability and reproducibility of nonstress test readings*, **Am. J. Obstet. Gynecol.**, 159:3 (1988) 554–558.

- [18] D. Ayres-de-Campos, C. Y. Spong, and E. Chandrachan, *FIGO consensus guidelines on intrapartum fetal monitoring: Cardiotocography*, **Int. J. Gynecol. Obstet.**, 131:1 (2015) 13–24.
- [19] N. I. of C. H. and H. D. R. P. Workshop, *Electronic fetal heart rate monitoring: Research guidelines for interpretation*, **Am. J. Obstet. Gynecol.**, 177:6 (1997) 1385–1390.
- [20] G. A. Dildy, S. L. Clark, and C. A. Loucks, *Intrapartum fetal pulse oximetry: past, present, and future*, **Am. J. Obstet. Gynecol.**, 175:1 (1996) 1–9.
- [21] R. R. C. of O. and Gynecologists, *The use of electronic fetal monitoring*, **J. Chem. Inf. Model.**, (2001) 1–136.
- [22] G. Macones, *ACOG Practice Bulletin No. 106: Intrapartum fetal heart rate monitoring: nomenclature, interpretation, and general management principles*, **Obstet. Gynecol.**, 114:1 (2009) 192–202.
- [23] National Institute for Health and Clinical Excellence, *Intrapartum care for healthy women and babies* (2014) pp.1–88.
- [24] J. Bernardes, A. Costa-Pereira, D. Ayres-De-Campos, H. P. Van Geijn, and L. Pereira-Leite, *Evaluation of interobserver agreement of cardiotocograms*, **Int. J. Gynecol. Obstet.**, 57:1 (1997) 33–37.
- [25] J. B. Trimbos and M. J. Keirse, *Observer variability in assessment of antepartum cardiotocograms*, **Br. J. Obstet. Gynaecol.**, 85:12 (1978) 900–906.
- [26] D. K. Donker, H. P. van Geijn, and A. Hasman, *Interobserver variation in the assessment of fetal heart rate recordings*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 52:1 (1993) 21–28.
- [27] C. Cattani, O. Doubrovina, S. Rogosin, S. L. Voskresensky, and E. Zelianko, *On the Creation of a New Diagnostic Model for Fetal Well-Being on the Base of Wavelet Analysis of Cardiotocograms*, **J Med Syst**, 30:6 (2006) 489–494.
- [28] D. Ayres-de-campos, J. Bernardes, A. Garrido, J. Marques-de-sá, and L. Pereira-leite, *SisPorto 2.0: A Program for Automated Analysis of Cardiotocograms*, **J. Matern. Fetal. Med.**, 9:5 (2000) 311–318.
- [29] B. K. Strachan, D. S. Sahota, W. J. Van Wijngaarden, D. K. James, and A. M. Z. Chang, *Computerised analysis of the fetal heart rate and relation to acidemia at delivery*, **Br. J. Obstet. Gynaecol.**, 108:8 (2001) 848–852.
- [30] J. Pardey, M. Moulden, and C. W. G. Redman, *A computer system for the numerical analysis of nonstress tests*, **Am. J. Obstet. Gynecol.**, 186:5 (2002) 1095–1103.
- [31] G. Magenes, M. G. Signorini, M. Ferrario, and F. Lunghi, *2CTG2: A new system for the antepartum analysis of fetal heart rate*, 11th Mediterranean Conference on Medical and Biomedical Engineering and Computing (MEDICON), (2007) pp.781–784.
- [32] S. N. Al-yousif and M. A. M. Ali, *Cardiotocography Trace Pattern Evaluation Using MATLAB Program*, International Conference on Biomedical Engineering and Technology, (2011) pp.153–158.
- [33] R. Czabanski, J. Jezewski, A. Matonia, and M. Jezewski, *Computerized*

- analysis of fetal heart rate signals as the predictor of neonatal acidemia*, **Expert Syst. Appl.**, 39:15 (2012) 11846–11860.
- [34] M. Romano, P. Bifulco, M. Ruffo, G. Improta, F. Clemente, and M. Cesarelli, *Software for computerised analysis of cardiotocographic traces*, **Comput. Methods Programs Biomed.**, 124 (2016) 121–137.
- [35] G. S. Dawes, C. R. Houghton, and C. W. Redman, *Baseline in human fetal heart-rate records*, **Br J Obs. Gynaecol.**, 89:4 (1982) 270–275.
- [36] R. Mantel, H. P. van Geijn, F. J. Caron, J. M. Swartjes, E. E. van Woerden, and H. W. Jongsma, *Computer analysis of antepartum fetal heart rate: 1. Baseline determination*, **Int. J. Biomed. Comput.**, 25:4 (1990) 261–272.
- [37] R. Mantel, H. P. van Geijn, F. J. M. Caron, J. M. Swartjes, E. E. van Woerden, and H. W. Jongsma, *Computer analysis of antepartum fetal heart rate: 2. Detection of accelerations and decelerations*, **Int. J. Biomed. Comput.**, 25:4 (1990) 273–286.
- [38] J. Bernardes, C. Moura, J. P. de Sa, and L. P. Leite, *The Porto system for automated cardiotocographic signal analysis*, **J. Perinat. Med.**, 19:1–2 (1991) 61–65.
- [39] J. Karin, M. Hirsch, C. Sagiv, and S. Akselrod, *Fetal autonomic nervous system activity monitoring by spectral analysis of heart rate variations*, *Computers in Cardiology (CinC)*. pp. 479–482, 1992.
- [40] L. J. Groome, D. M. Mooney, L. S. Bentz, and K. P. Singh, *Spectral analysis of heart rate variability during quiet sleep in normal human fetuses between 36 and 40 weeks of gestation*, **Early Hum. Dev.**, 38:1 (1994) 1–9.
- [41] A. Alonso-Betanzos, B. Guijarro-Berdinas, V. Moret-Bonillo, and S. Lopez-Gonzalez, *The NST-EXPERT project: the need to evolve*, **Artif. Intell. Med.**, 7:4 (1995) 297–313.
- [42] A. Alonso-Betanzos, B. Guijarro-Berdinas, V. Moret-Bonillo, A. Castro-Martinez, and L. D. Devoe, *An expert system approach to antenatal assessment*, **New Rev. Appl. Expert Syst. Emerg. Technol.**, 2 (1996) 139–153.
- [43] T. Todros, C. U. Preve, C. Plazzotta, M. Biolcati, and P. Lombardo, *Fetal heart rate tracings: observers versus computer assessment*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 68 (1996) 83–86.
- [44] M. Mongelli, R. Dawkins, T. Chung, D. Sahota, J. A. Spencer, and A. M. Chang, *Computerised estimation of the baseline fetal heart rate in labour: the low frequency line*, **Br. J. Obstet. Gynaecol.**, 104:10 (1997) 1128–1133.
- [45] R. Mantel, H. P. Van Geijn, I. A. P. Ververs, G. J. Colenbrander, and P. J. Kostense, *Automated analysis of antepartum fetal heart rate in relation to fetal rest-activity states: A longitudinal study of uncomplicated pregnancies using the Sonicaid System 8000*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 71:1 (1997) 41–51.
- [46] C. Ulbricht, G. Dorffner, and A. Lee, *Neural networks for recognizing patterns in cardiotocograms*, **Artif Intell Med**, 12:3 (1998) 271–284.
- [47] J. Bernardes, D. Ayres-de-Campos, A. Costa-Pereira, L. Pereira-Leite, and A. Garrido, *Objective computerized fetal heart rate analysis*, **Int. J. Gynecol.**

- Obstet.**, 62:2 (1998) 141–147.
- [48] G. M. Taylor *et al.*, *The development and validation of an algorithm for real-time computerised fetal heart rate monitoring in labour*, **BJOG**, 107:9 (2000) 1130–1137.
- [49] G. Magenes, M. G. Signorini, and R. Sassi, *Automatic diagnosis of fetal heart rate: comparison of different methodological approaches*, Engineering in Medicine and Biology Society, (2001) pp.1604–1607 vol.2.
- [50] O. Fontenla-Romero, A. Alonso-Betanzos, and B. Guijarro-Berdinas, *Adaptive pattern recognition in the analysis of cardiotocographic records*, **IEEE Trans. Neural Networks**, 12:5 (2001) 1188–1195.
- [51] L. Jimenez, R. Gonzalez, M. Gaitan, S. Carrasco, and C. Vargas, *Computerized algorithm for baseline estimation of fetal heart rate*, Computers in Cardiology (CinC), (2002) pp.477–480.
- [52] E. Salamalekis *et al.*, *Computerised intrapartum diagnosis of fetal hypoxia based on fetal heart rate monitoring and fetal pulse oximetry recordings utilising wavelet analysis and neural networks*, **BJOG An Int. J. Obstet. Gynaecol.**, 109:10 (2002) 1137–1142.
- [53] B. Guijarro-Berdiñas, A. Alonso-Betanzos, and O. Fontenla-Romero, *Intelligent analysis and pattern recognition in cardiotocographic signals using a tightly coupled hybrid system*, **Artif. Intell.**, 136:1 (2002) 1–27.
- [54] M. Kazandi, F. Sendag, F. Akercan, M. C. Terek, and G. Gundem, *Different types of variable decelerations and their effects to neonatal outcome*, **Singapore Med. J.**, 44:5 (2003) 243–247.
- [55] M. G. Signorini, G. Magenes, S. Cerutti, and D. Arduini, *Linear and nonlinear parameters for the analysis of fetal heart rate signal from cardiotocographic recordings*, **IEEE Trans. Biomed. Eng.**, 50:3 (2003) 365–374.
- [56] J. Chuang, C.-T. Chou, W.-C. Cheng, L.-W. Huang, J.-L. Hwang, and Y.-L. Tsai, *Spontaneous fetal heart rate deceleration: an ominous sign for fetal outcome*, **Arch. Gynecol. Obstet.**, 269:4 (2004) 254–258.
- [57] G. Magenes, L. Pedrinazzi, and M. G. Signorini, *Identification of fetal sufferance antepartum through a multiparametric analysis and a support vector machine*, 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, (2004) pp.462–465.
- [58] G. G. Georgoulas, C. D. Stylios, G. Nokas, and P. P. Groumpos, *Classification of fetal heart rate during labour using hidden Markov models*, IEEE International Joint Conference on Neural Networks, (2004) pp.2471–2475.
- [59] D. Ayres-de-Campos and J. Bernardes, *Comparison of fetal heart rate baseline estimation by SisPorto® 2.01 and a consensus of clinicians*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 117:2 (2004) 174–178.
- [60] D. Ayres-de-Campos, C. Costa-Santos, and J. Bernardes, *Prediction of neonatal state by computer analysis of fetal heart rate tracings: the antepartum arm of the SisPorto® multicentre validation study*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 118:1 (2005) 52–60.
- [61] D. Gavrilis and I. G. Tsoulos, *Classification of fetal heart rate using*

- grammatical evolution*, IEEE Workshop on Signal Processing Systems Design and Implementation, (2005) pp.425–429.
- [62] P. Warrick, E. Hamilton, and M. Macieszczak, *Neural network based detection of fetal heart rate patterns*, IEEE International Joint Conference on Neural Networks, (2005) pp.2400–2405.
- [63] T. Tongsong *et al.*, *Accuracy of fetal heart-rate variability interpretation by obstetricians using the criteria of the National Institute of Child Health and Human Development compared with computer-aided interpretation*, **J. Obstet. Gynaecol. Res.**, 31:1 (2005) 68–71.
- [64] M. R. Ortiz *et al.*, *Analysis of high frequency fetal heart rate variability using empirical mode decomposition*, Computers in Cardiology (CinC), (2005) pp.675–678.
- [65] T. Kupka, J. Wrobel, J. Jezewski, A. Gacek, and M. Jezewski, *Evaluation of Fetal Heart Rate Baseline Estimation Method Using Testing Signals Based on a Statistical Model*, Engineering in Medicine and Biology Society (EMBS), (2006) pp.3728–3731.
- [66] G. Georgoulas, C. Stylios, and P. Groumpos, *Feature Extraction and Classification of Fetal Heart Rate Using Wavelet Analysis and Support Vector Machines*, **Int. J. Artif. Intell. Tools**, 15:3 (2006) 411–432.
- [67] M. Ferrario, M. G. Signorini, G. Magenes, and S. Cerutti, *Comparison of entropy-based regularity estimators: application to the fetal heart rate signal for the identification of fetal distress*, **IEEE Trans. Biomed. Eng.**, 53:1 (2006) 119–125.
- [68] H. Gonçalves, A. P. Rocha, D. Ayres-de-Campos, and J. Bernardes, *Linear and nonlinear fetal heart rate analysis of normal and acidemic fetuses in the minutes preceding delivery*, **Med. Biol. Eng. Comput.**, 44:10 (2006) 847.
- [69] G. Georgoulas, D. Stylios, and P. Groumpos, *Predicting the risk of metabolic acidosis for newborns based on fetal heart rate signal classification using support vector machines*, **IEEE Trans. Biomed. Eng.**, 53:5 (2006) 875–884.
- [70] M. Romano *et al.*, *Antepartum cardiotocography: A study of fetal reactivity in frequency domain*, **Comput. Biol. Med.**, 36:6 (2006) 619–633.
- [71] M. David, M. Hirsch, and S. Akselrod, *Maturation of fetal cardiac autonomic control as expressed by Fetal Heart Rate variability*, Computers in Cardiology (CinC), (2006) pp.901–904.
- [72] M. Romano, P. Bifulco, M. Cesarelli, M. Sansone, and M. Bracale, *Foetal heart rate power spectrum response to uterine contraction*, **Med. Biol. Eng. Comput.**, 44:3 (2006) 188–201.
- [73] H. Goncalves, A. P. Rocha, D. Ayres-de-Campos, and J. Bernardes, *Internal versus external intrapartum foetal heart rate monitoring: the effect on linear and nonlinear parameters*, **Physiol. Meas.**, 27:3 (2006) 307–319.
- [74] G. Georgoulas, D. Gavriliis, I. G. Tsoulos, C. Stylios, J. Bernardes, and P. P. Groumpos, *Novel approach for fetal heart rate classification introducing grammatical evolution*, **Biomed. Signal Process. Control**, 2:2 (2007) 69–79.
- [75] M. David, M. Hirsch, J. Karin, E. Toledo, and S. Akselrod, *An estimate of fetal*



- autonomic state by time-frequency analysis of fetal heart rate variability*, **J. Appl. Physiol.**, 102:3 (2007) 1057–1064.
- [76] H. Gonçalves, J. Bernardes, A. Paula Rocha, and D. Ayres-de-Campos, *Linear and nonlinear analysis of heart rate patterns associated with fetal behavioral states in the antepartum period*, **Early Hum. Dev.**, 83:9 (2007) 585–591.
- [77] J. O. E. H. Van Laar, M. M. Porath, C. H. L. Peters, and S. G. Oei, *Spectral analysis of fetal heart rate variability for fetal surveillance: review of the literature*, **Acta Obstet. Gynecol. Scand.**, 87:3 (2008) 300–306.
- [78] B. Niranjana Krupa, M. A. Mohd. Ali, and E. Zahedi, *Computerized Fetal Heart Rate Baseline Estimation Based on Number and Continuity of Occurrences*, 4th Kuala Lumpur International Conference on Biomedical Engineering (BIOMED), (2008) pp.162–165.
- [79] S. Schiermeier *et al.*, *Sensitivity and specificity of intrapartum computerised FIGO criteria for cardiotocography and fetal scalp pH during labour: multicentre, observational study*, **BJOG**, 115:12 (2008) 1557–1563.
- [80] D. Ayres-de-Campos, P. Sousa, A. Costa, and J. Bernardes, *Omniview-SisPorto 3.5 - a central fetal monitoring station with online alerts based on computerized cardiotocogram+ST event analysis*, **J. Perinat. Med.**, 36:3 (2008) 260–264.
- [81] V. Chudacek *et al.*, *Evaluation of feature subsets for classification of cardiotocographic recordings*, *Computers in Cardiology (CinC)*, (2008) pp.845–848.
- [82] M. Ferrario, M. G. Signorini, and G. Magenes, *Complexity analysis of the fetal heart rate variability: early identification of severe intrauterine growth-restricted fetuses*, **Med Biol Eng Comput**, 47:9 (2009) 911–919.
- [83] M. Romano, M. Cesarelli, P. Bifulco, M. Ruffo, A. Fratini, and G. Pasquariello, *Time-Frequency Analysis of CTG Signals*, **Curr. Dev. Theory Appl. Wavelets**, 3:2 (2009) 169–192.
- [84] M. Cesarelli, M. Romano, and P. Bifulco, *Comparison of short term variability indexes in cardiotocographic foetal monitoring*, **Comput. Biol. Med.**, 39:2 (2009) 106–118.
- [85] S. Nidhal, M. A. M. Ali, and H. Najah, *A novel cardiotocography fetal heart rate baseline estimation algorithm*, **Sci. Res. Essays**, 5:24 (2010) 4002–4010.
- [86] N. Krupa, M. A. MA, E. Zahedi, S. Ahmed, and F. M. Hassan, *Antepartum fetal heart rate feature extraction and classification using empirical mode decomposition and support vector machine*, **Biomed. Eng. Online**, 10:1 (2011) 1–15.
- [87] M. Cesarelli, M. Romano, M. Ruffo, P. Bifulco, G. Pasquariello, and A. Fratini, *PSD modifications of FHRV due to interpolation and CTG storage rate*, **Biomed. Signal Process. Control**, 6:3 (2011) 225–230.
- [88] J. Y. Kwon, I. Y. Park, J. C. Shin, J. Song, R. Tafreshi, and J. Lim, *Specific change in spectral power of fetal heart rate variability related to fetal acidemia during labor: Comparison between preterm and term fetuses*, **Early Hum. Dev.**, 88:4 (2012) 203–207.
- [89] P. A. Warrick and E. F. Hamilton, *Fetal heart-rate variability response to*

*uterine contractions during labour and delivery*, *Computing in Cardiology (CinC)*, (2012) pp.417–420.

- [90] M.-L. Huang and H. Yung-Yan, *Fetal distress prediction using discriminant analysis, decision tree, and artificial neural network*, **J. Biomed. Sci. Eng.**, 5 (2012) 526–533.
- [91] M. Cesarelli, M. Romano, P. Bifulco, G. Improta, and G. D’Addio, *An application of symbolic dynamics for FHRV assessment*, **Stud. Health Technol. Inform.**, 180 (2012) 123–127.
- [92] C. Sundar, M. Chitradevi, and G. Geetharamani, *Classification of cardiogram data using neural network based machine learning technique*, **Int. J. Comput. Appl.**, 47:14 (2012).
- [93] J. Spilka *et al.*, *Using nonlinear features for fetal heart rate classification*, **Biomed. Signal Process. Control**, 7:4 (2012) 350–357.
- [94] C. Sundar, M. Chitradevi, and G. Geetharamani, *An overview of research challenges for classification of cardiogram data*, **J. Comput. Sci.**, 9:2 (2013) 198–206.
- [95] M. Romano *et al.*, *Symbolic dynamics in cardiographic monitoring*, *E-Health and Bioengineering Conference (EHB)*, (2013) pp.1–4.
- [96] H. Ocak and H. M. Ertunc, *Prediction of fetal state from the cardiogram recordings using adaptive neuro-fuzzy inference systems*, **Neural Comput. Appl.**, 23:6 (2013) 1583–1589.
- [97] H. Ocak, *A medical decision support system based on support vector machines and the genetic algorithm for the evaluation of fetal well-being*, **J Med Syst**, 37:2 (2013) 9913.
- [98] M. Cesarelli, M. Romano, P. Bifulco, G. Improta, and G. D’Addio, *Prognostic decision support using symbolic dynamics in CTG monitoring.*, **Stud. Health Technol. Inform.**, 186 (2013) 140–144.
- [99] A. Fanelli, G. Magenes, M. Campanile, and M. G. Signorini, *Quantitative Assessment of Fetal Well-Being Through CTG Recordings: A New Parameter Based on Phase-Rectified Signal Average*, **IEEE J. Biomed. Heal. Informatics**, 17:5 (2013) 959–966.
- [100] M. P. Tarvainen, J.-P. Niskanen, J. A. Lipponen, P. O. Ranta-aho, and P. A. Karjalainen, *Kubios HRV – Heart rate variability analysis software*, **Comput. Methods Programs Biomed.**, 113:1 (2014) 210–220.
- [101] G. Improta, M. Romano, A. Ponsiglione, P. Bifulco, G. Faiella, and M. Cesarelli, *Computerized Cardiography: A Software to Generate Synthetic Signals*, **J Heal. Med Informat**, 5:4 (2014) 1–6.
- [102] E. M. Karabulut and T. Ibrikci, *Analysis of Cardiogram Data for Fetal Distress Determination by Decision Tree Based Adaptive Boosting Approach*, **Comput. Commun.**, 2:7 (2014) 32–37.
- [103] M. Jezewski, R. Czabanski, and J. Leski, *The influence of cardiogram signal feature selection method on fetal state assessment efficacy*, **J. Med. Informatics Technol.**, 23 (2014) 1642–6037.
- [104] J. Spilka *et al.*, *Analysis of obstetricians’ decision making on CTG recordings*,

**J. Biomed. Inform.**, 51 (2014) 72–79.

- [105] S. Ravindran, A. B. Jambek, H. Muthusamy, and S.-C. Neoh, *A novel clinical decision support system using improved adaptive genetic algorithm for the assessment of fetal well-being*, **Comput. Math. Methods Med.**, 2015 (2015) 283532.
- [106] H. Sahin and A. Subasi, *Classification of the cardiotocogram data for anticipation of fetal risks using machine learning techniques*, **Appl. Soft Comput.**, 33 (2015) 231–238.
- [107] S. A. A. Shah, W. Aziz, M. Arif, and M. S. A. Nadeem, *Decision Trees Based Classification of Cardiotocograms Using Bagging Approach*, 13th International Conference on Frontiers of Information Technology (FIT), (2015) pp.12–17.
- [108] M. Romano, L. Iuppariello, A. M. Ponsiglione, G. Improta, P. Bifulco, and M. Cesarelli, *Frequency and time domain analysis of foetal heart rate variability with traditional indexes: A critical survey*, **Comput. Math Methods Med**, (2016) 1–12.
- [109] R. Jyothi, R. S. Soans, and P. V. Bhat, *Automatic classification of toco-signals: An approach towards comprehensive monitoring of labour progress*, International Conference on Signal Processing and Communications (SPCOM), (2016) pp.1–5.
- [110] A. H. de l’Aulnoit, S. Boudet, R. Demailly, L. Peyrodie, R. Beuscart, and D. H. de l’Aulnoit, *Baseline fetal heart rate analysis: Eleven automatic methods versus expert consensus*, 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), (2016) pp.3576–3581.
- [111] K. Horoba, J. Wrobel, J. Jezewski, T. Kupka, D. Roj, and M. Jezewski, *Automated detection of uterine contractions in tocography signals – Comparison of algorithms*, **Biocybern. Biomed. Eng.**, 36:4 (2016) 610–618.
- [112] J. Jezewski, K. Horoba, D. Roj, J. Wrobel, T. Kupka, and A. Matonia, *Evaluating the fetal heart rate baseline estimation algorithms by their influence on detection of clinically important patterns*, **Biocybern. Biomed. Eng.**, 36:4 (2016) 562–573.
- [113] G. Magenes, R. Bellazzi, A. Malovini, and M. G. Signorini, *Comparison of data mining techniques applied to fetal heart rate parameters for the early identification of IUGR fetuses*, 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), (2016) pp.916–919.
- [114] E. Yılmaz, *Fetal State Assessment from Cardiotocogram Data Using Artificial Neural Networks*, **J. Med. Biol. Eng.**, (2016) 1–13.
- [115] A. Wosiak, A. Zamecznik, and K. Niewiadomska-Jarosik, *Supervised and unsupervised machine learning for improved identification of intrauterine growth restriction types*, Federated Conference on Computer Science and Information Systems (FedCSIS), (2016) pp.323–329.
- [116] K. Yu, J. G. Quirk, and P. M. Djuri, *Fetal heart rate analysis by hierarchical dirichlet process mixture models*, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), (2016) pp.709–713.
- [117] R. Czabanski, M. Jezewski, K. Horoba, J. Jezewski, and J. Leski, *Fuzzy Analysis*

*of Delivery Outcome Attributes for Improving the Automated Fetal State Assessment*, **Appl. Artif. Intell.**, 30:6 (2016) 556–571.

- [118] M. Jezewski, R. Czabanski, K. Horoba, and J. Leski, *Clustering with Pairs of Prototypes to Support Automated Assessment of the Fetal State*, **Appl. Artif. Intell.**, 30:6 (2016) 572–589.
- [119] E. Yılmaz, *A Decision Support System for Determination of Fetal Well-Being from Cardiotocogram Data*, **Uludağ Univ. J. Fac. Eng.**, 21:2 (2016) 331–340.
- [120] D. Ayres-de-Campos, M. Rei, I. Nunes, P. Sousa, and J. Bernardes, *SisPorto 4.0 - computer analysis following the 2015 FIGO Guidelines for intrapartum fetal monitoring*, **J. Matern. neonatal Med.**, 30:1 (2017) 62–67.
- [121] Z. Cömert and A. F. Kocamaz, *Determination of QT interval on synthetic electrocardiogram*, 23rd Signal Processing and Communications Applications Conference (SIU), (2015).
- [122] I. Nunes and D. Ayres-de-Campos, *Computer analysis of foetal monitoring signals*, **Best Pract. Res. Clin. Obstet. Gynaecol.**, 30 (2016) 68–78.
- [123] V. Chudáček *et al.*, *Open access intrapartum CTG database*, **BMC Pregnancy Childbirth**, 14 (2014) 16.
- [124] M. Cesarelli, M. Romano, P. Bifulco, F. Fedele, and M. Bracale, *An algorithm for the recovery of fetal heart rate series from CTG data*, **Comput. Biol. Med.**, 37:5 (2007) 663–669.
- [125] D. Kahaner, C. Moler, and S. Nash, *Numerical Methods and Software*, Prentice-Hall, Inc., 1989 .
- [126] K. J. Dalton and A. J. Dawson, *Baseline: A computer method of calculating baseline in fetal heart rate recordings*, **Int. J. Biomed. Comput.**, 15:4 (1984) 311–317.
- [127] D. Ayres-de-Campos *et al.*, *Can the reproducibility of fetal heart rate baseline estimation be improved?*, **Eur. J. Obstet. Gynecol. Reprod. Biol.**, 112:1 (2004) 49–54.
- [128] H. Okosun and S. Arulkumaran, *Intrapartum fetal surveillance*, **Curr. Obstet. Gynaecol.**, 15:1 (2005) 18–24.
- [129] S. Segal, *Labor epidural analgesia and maternal fever.*, **Anesth. Analg.**, 111:6 (2010) 1467–1475.
- [130] S. Das, K. Roy, and C. K. Saha, *Determination of window size for baseline estimation of fetal heart rate using CTG*, *The third International Conference on Computer, Communication, Control and Information Technology (C3IT)*. pp. 1–5, 2015.
- [131] R. Nurani, E. Chandrachan, V. Lowe, A. Ugwumadu, and S. Arulkumaran, *Misidentification of maternal heart rate as fetal on cardiotocography during the second stage of labor: the role of the fetal electrocardiograph*, **Acta Obstet. Gynecol. Scand.**, 91:12 (2012) 1428–1432.
- [132] Y. Çekiç, *Time-Frequency Analysis for Non-Stationary Signals* , PhD Thesis, İstanbul University Turkey, 2004.
- [133] E. Hamilton, P. Warrick, and D. O’Keefe, *Variable decelerations: do size and*

- shape matter?*, **J. Matern. Fetal. Neonatal Med.**, 25:6 (2012) 648–653.
- [134] I. Nunes, D. Ayres-de-Campos, A. Kwee, and K. G. Rosen, *Prolonged saltatory fetal heart rate pattern leading to newborn metabolic acidosis*, **Clin. Exp. Obstet. Gynecol.**, 41:5 (2014) 507–511.
- [135] M. Akay, *Nonlinear Biomedical Signal Processing Vol. II: Dynamic Analysis and Modeling*, Wiley-IEEE Press, 2000 .
- [136] D. Yılmaz and F. Güler, *Kaotik zaman serisinin analizi üzerine bir araştırma*, **Gazi Üniv. Müh. Mim. Fak. Der.**, 21:4 (2006) 759–779.
- [137] A. Voss *et al.*, *The application of methods of non-linear dynamics for the improved and predictive recognition of patients threatened by sudden cardiac death*, **Cardiovasc. Res.**, 31:3 (1996) 419–433.
- [138] P. Grassberger and I. Procaccia, *Measuring the strangeness of strange attractors*, **Phys. D Nonlinear Phenom.**, 9:1 (1983) 189–208.
- [139] S. Pincus, *Approximate entropy (ApEn) as a complexity measure*, **Chaos**, 5:1 (1995) 110–117.
- [140] S. M. Pincus and R. R. Viscarello, *Approximate entropy: a regularity measure for fetal heart rate analysis*, **Obs. Gynecol**, 79:2 (1992) 249–255.
- [141] J. S. Richman and J. R. Moorman, *Physiological time-series analysis using approximate entropy and sample entropy*, **Am. J. Physiol. Heart Circ. Physiol.**, 278:6 (2000) H2039-49.
- [142] A. Lempel and J. Ziv, *On the Complexity of Finite Sequences*, **IEEE Trans. Inf. Theory**, 22:1 (1976) 75–81.
- [143] M. Ferrario, M. G. Signorini, and S. Cerutti, *Complexity analysis of 24 hours heart rate variability time series*, 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, (2004) pp.3956–3959.
- [144] E. M. Stein and R. Shakarchi, *Fourier analysis: An introduction*, 2011 .
- [145] J. Allen, *Short term spectral analysis, synthesis, and modification by discrete Fourier transform*, **IEEE Trans. Acoust.**, 25:3 (1977) 235–238.
- [146] M. Malik *et al.*, *Heart rate variability Standards of measurement, physiological interpretation, and clinical use*, **Eur. Heart J.**, 17:3 (1996) 354–381.
- [147] M. H. Hayes, *Statistical Digital Signal Processing and Modelling*, 1996 .
- [148] T. Suzuki *et al.*, *Power spectral analysis of R-R interval variability before and during the sinusoidal heart rate pattern in fetal lambs*, **Am. J. Obstet. Gynecol.**, 182:5 (2000) 1227–1232.
- [149] R. M. Haralick, K. Shanmugam, and I. Dinstein, *Textural Features for Image Classification*, **IEEE Trans. Syst. Man. Cybern.**, SMC-3:6 (1973) 610–621.
- [150] Y. Guo, G. Zhao, and M. Pietikäinen, *Discriminative features for texture description*, **Pattern Recognit.**, 45:10 (2012) 3834–3843.
- [151] A. Şengür, Y. Guo, and Y. Akbulut, *Time–frequency texture descriptors of EEG signals for efficient detection of epileptic seizure*, 3:2 (2016) 101–108.
- [152] Z. Cömert and A. F. Kocamaz, *A Study Based on Gray Level Co-Occurrence Matrix and Neural Network Community for Determination of Hypoxic Fetuses*,

- International Artificial Intelligence and Data Processing Symposium (IDAP), (2016) pp.569–573.
- [153] R. M. Haralick, *Statistical and structural approaches to texture*, **Proc. IEEE**, 67:5 (1979) 786–804.
- [154] Matlab, (2017).  
<https://www.mathworks.com/help/images/ref/graycomatrix.html> (on-line access on 8, Mar., 2017).
- [155] T. Ojala, M. Pietikainen, and T. Maenpaa, *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*, **IEEE Trans. Pattern Anal. Mach. Intell.**, 24:7 (2002) 971–987.
- [156] A. F. Costa, G. Humpire-Mamani, and A. J. M. Traina, *An Efficient Algorithm for Fractal Analysis of Textures*, 25th SIBGRAPI Conference on Graphics, Patterns and Images, (2012) pp.39–46.
- [157] M. Karabatak, *Özellik Seçimi, Sınıflama ve Öngörü Uygulamalarına Yönelik Birliktelik Kuralı Çıkarımı ve Yazılım Geliştirilmesi*, PhD Thesis, Fırat University Turkey, 2008.
- [158] V. Onnia, M. Tico, and J. Saarinen, *Feature selection method using neural network*, International Conference on Image Processing, (2001) pp.513–516.
- [159] R. Spilegel, M. and L. Stephens, *İstatistik*, Nobel Yayın Dağıtım, 1999 .
- [160] K. Z. Mao, *Orthogonal forward selection and backward elimination algorithms for feature subset selection*, **IEEE Trans. Syst. Man, Cybern. Part B**, 34:1 (2004) 629–634.
- [161] R. Kohavi and G. H. John, *Wrappers for feature subset selection*, **Artif. Intell.**, 97:1 (1997) 273–324.
- [162] L. J. P. Van Der Maaten, E. O. Postma, and H. J. Van Den Herik, *Dimensionality Reduction: A Comparative Review*, **Tilbg. Cent. Creat. Comput.**, 10 (2009) 1–41.
- [163] X. Wang and K. K. Paliwal, *Feature extraction and dimensionality reduction algorithms and their applications in vowel recognition*, **Pattern Recognit.**, 36:10 (2003) 2429–2439.
- [164] E. Alpaydın, *Yapay Öğrenme*, Boğaziçi Üniversitesi Yayınevi, 2013 .
- [165] A. K. Jain and J. Mao, *Artificial Neural Network: A Tutorial*, 29 (1996) 31–44.
- [166] H. Demuth, M. Beale, and M. Hagan, *Neural Network Toolbox™ 6 User's Guide*, The MathWorks, Inc., 2010 .
- [167] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, *Extreme learning machine: Theory and applications*, **Neurocomputing**, 70:1–3 (2006) 489–501.
- [168] O. F. Alcin, A. Sengur, S. Ghofrani, and M. C. Ince, *GA-SELM: Greedy algorithms for sparse extreme learning machine*, 55 (2014) 126–132.
- [169] Ö. F. Alçın, S. Siuly, V. Bajaj, Y. Guo, A. Şengu'r, and Y. Zhang, *Multi-category EEG signal classification developing time-frequency texture features based Fisher Vector encoding method*, **Neurocomputing**, 218 (2016) 251–258.
- [170] V. N. Vapnik, *The Nature of Statistical Learning Theory*, Springer-Verlag New

York, Inc., 1995 .

- [171] P. A. Warrick, E. F. Hamilton, D. Precup, and R. E. Kearney, *Classification of Normal and Hypoxic Fetuses From Systems Modeling of Intrapartum Cardiotocography*, **IEEE Trans. Biomed. Eng.**, 57:4 (2010) 771–779.
- [172] C.-C. Chang and C.-J. Lin, *LIBSVM: A library for support vector machines*, **Comput. Math. Methods Med.**, 2:3 (2011) 1–27.
- [173] H. Wang and I. Duntsch, *Nearest Neighbours without k: A Classification Formalism based on Probability*, **Brock Univ.**, (2003) 1–10.
- [174] K. Q. Weinberger and L. K. Saul, *Distance metric learning for large margin nearest neighbor classification*, **J. Mach. Learn. Res.**, 10 (2009) 207–244.
- [175] J. Moody and C. J. Darken, *Fast Learning in Networks of Locally-tuned Processing Units*, **Neural Comput.**, 1:2 (1989) 281–294.
- [176] K. Warwick and R. Craddock, *Introduction to radial basis functions for system identification a comparison with other neural network methods*, **IEEE Conference on Decision and Control**, (1996) pp.464–469.
- [177] L. Breiman, *Random Forests*, **Mach. Learn.**, 45:1 (2001) 5–32.
- [178] K. J. Archer and R. V. Kimes, *Empirical characterization of random forest variable importance measures*, **Comput. Stat. Data Anal.**, 52:4 (2008) 2249–2260.
- [179] P. Yang, Y. Hwa Yang, B. B. Zhou, and A. Y. Zomaya, *A Review of Ensemble Methods in Bioinformatics*, **Curr. Bioinform.**, 5:4 (2010) 296–308.
- [180] M. W. Powers, David, *Evaluation: From Precision, Recall and F-Measure To Roc, Informedness, Markedness & Correlation*, **J. Mach. Learn. Technol.**, 2:1 (2011) 37–63.
- [181] H. He and E. A. Garcia, *Learning from Imbalanced Data*, **IEEE Trans. Knowl. Data Eng.**, 21:9 (2009) 1263–1284.
- [182] Y. Bengio and Y. Grandvalet, *No Unbiased Estimator of the Variance of k-Fold Cross-Validation*, **J. Mach. Learn. Res.**, 5 (2004) 1089–1105.
- [183] R. Kohavi, *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection*, **International Joint Conference on Artificial Intelligence**, (1995) pp.1137–1143.
- [184] P. E. McSharry, G. D. Clifford, L. Tarassenko, and L. A. Smith, *A dynamical model for generating synthetic electrocardiogram signals.*, **IEEE Trans. Biomed. Eng.**, 50:3 (2003) 289–294.
- [185] Z. Cömert and A. F. Kocamaz, *Comparison of Machine Learning Techniques for Fetal Heart Rate Classification*, **3rd International Conference on Computational and Experimental Science and Engineering (ICCESEN)**, (2016) pp.599.
- [186] D. Marquardt, *An Algorithm for Least-Squares Estimation of Nonlinear Parameters*, **J. Soc. Ind. Appl. Math.**, 11:2 (1963) 431–441.
- [187] Z. Cömert and A. F. Kocamaz, *Performance Comparison of Neural Network Training Algorithms for Fetal Heart Rate Patterns*, **3rd International Conference on Computational and Experimental Science and Engineering**

(ICCESEN), (2016) pp.600.

- [188] Z. Cömert, A. F. Kocamaz, and S. Gungor, *Cardiotocography signals with artificial neural network and extreme learning machine*, 24th Signal Processing and Communication Application Conference (SIU), (2016).
- [189] Z. Cömert and A. F. Kocamaz, *Evaluation of Fetal Distress Diagnosis during Delivery Stages based on Linear and Nonlinear Features of Fetal Heart Rate for Neural Network Community*, **Int. J. Comput. Appl.**, 156:4 (2016) 26–31.
- [190] S. Rhose, A. M. F. Heinis, F. Vandenbussche, J. van Drongelen, and J. van Dillen, *Inter- and intra-observer agreement of non-reassuring cardiotocography analysis and subsequent clinical management*, **Acta Obstet. Gynecol. Scand.**, 93:6 (2014) 596–602.
- [191] F. N. Fritsch and R. E. Carlson, *Monotone Piecewise Cubic Interpolation*, **SIAM J. Numer. Anal.**, 17:2 (1980) 238–246.
- [192] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*, Springer, 2009 .
- [193] P. V Nielsen, B. Stigsby, C. Nickelsen, and J. Nim, *Computer assessment of the intrapartum cardiotocogram. II. The value of compared with visual assessment*, **Acta Obstet. Gynecol. Scand.**, 67:5 (1988) 461–464.
- [194] R. D. Keith, S. Beckley, J. M. Garibaldi, J. A. Westgate, E. C. Ifeakor, and K. R. Greene, *A multicentre comparative study of 17 experts and an intelligent computer system for managing labour using the cardiotocogram*, **Br. J. Obstet. Gynaecol.**, 102:9 (1995) 688–700.
- [195] MathWorks, *MATLAB Creating Graphical User Interfaces*, 2015 .
- [196] V. Chudacek, J. Spilka, P. Janku, M. Koucky, L. Lhotska, and M. Huptych, *Automatic evaluation of intrapartum fetal heart rate recordings: a comprehensive analysis of useful features*, **Physiol. Meas.**, 32:8 (2011) 1347–1360.
- [197] O. Palomaki, T. Luukkaala, R. Luoto, and R. Tuimala, *Intrapartum cardiotocography -- the dilemma of interpretational variation.*, **J. Perinat. Med.**, 34:4 (2006) 298–302.
- [198] H. Cao, D. E. Lake, J. E. 2nd Ferguson, C. A. Chisholm, M. P. Griffin, and J. R. Moorman, *Toward quantitative fetal heart rate monitoring*, **IEEE Trans. Biomed. Eng.**, 53:1 (2006) 111–118.
- [199] T. K. Chung, M. P. Mohajer, Z. J. Yang, A. M. Chang, and D. S. Sahota, *The prediction of fetal acidosis at birth by computerised analysis of intrapartum cardiotocography*, **Br. J. Obstet. Gynaecol.**, 102:6 (1995) 454–460.
- [200] Maeda *et al.*, *Neural Network Computer Analysis of Fetal Heart Rate*, **J. Matern. Fetal. Investig.**, 8:4 (1998) 163–171.
- [201] A. Lee, C. Ulbricht, and G. Dorffner, *Application of artificial neural networks for detection of abnormal fetal heart rate pattern: a comparison with conventional algorithms*, **J. Obstet. Gynaecol. (Lahore)**, 19:5 (1999) 482–485.
- [202] D. Y. Chung, Y. B. Sim, K. T. Park, S. H. Yi, J. C. Shin, and S. P. Kim, *Spectral analysis of fetal heart rate variability as a predictor of intrapartum fetal*



- distress*, **Int. J. Gynecol. Obstet.**, 73:2 (2001) 109–116.
- [203] S. M. Siira *et al.*, *Marked fetal acidosis and specific changes in power spectrum analysis of fetal heart rate variability recorded during the last hour of labour*, **BJOG**, 112:4 (2005) 418–423.
- [204] E. Salamalekis *et al.*, *Computerized analysis of fetal heart rate variability using the matching pursuit technique as an indicator of fetal hypoxia during labor*, **J. Matern. Fetal. Neonatal Med.**, 19:3 (2006) 165–169.
- [205] A. Costa, D. Ayres-de-Campos, F. Costa, C. Santos, and J. Bernardes, *Prediction of neonatal acidemia by computer analysis of fetal heart rate and ST event signals*, **Am. J. Obstet. Gynecol.**, 201:5 (2009) 464.e1-6.
- [206] C. Elliott, P. A. Warrick, E. Graham, and E. F. Hamilton, *Graded classification of fetal heart rate tracings: association with neonatal metabolic acidosis and neurologic morbidity*, **Am. J. Obstet. Gynecol.**, 202:3 (2010) 258.e1-8.
- [207] M. Jezewski, R. Czabanski, J. Wrobel, and K. Horoba, *Analysis of Extracted Cardiotocographic Signal Features to Improve Automated Prediction of Fetal Outcome*, **Biocybern. Biomed. Eng.**, 30:4 (2010) 29–47.
- [208] H. Helgason, P. Abry, P. Goncalves, C. Gharib, P. Gaucherand, and M. Doret, *Adaptive multiscale complexity analysis of fetal heart rate*, **IEEE Trans. Biomed. Eng.**, 58:8 (2011) 2186–2193.
- [209] A. Georgieva, S. J. Payne, M. Moulden, and C. W. G. Redman, *Artificial neural networks applied to fetal monitoring in labour*, **Neural Comput. Appl.**, 22:1 (2013) 85–93.
- [210] R. Czabanski, J. Jezewski, J. Wrobel, J. Sikora, and M. Jezewski, *Application of fuzzy inference systems for classification of fetal heart rate tracings in relation to neonatal outcome*, **Ginekol. Pol.**, 84:1 (2013) 38–43.
- [211] P. Van Leeuwen, D. Geue, S. Lange, W. Hatzmann, and D. Grönemeyer, *Changes in the frequency power spectrum of fetal heart rate in the course of pregnancy*, **Prenat. Diagn.**, 23:11 (2003) 909–916.
- [212] M. Cesarelli *et al.*, *Floatingline Estimation in FHR Signal Analysis*, 5th European Conference of the International Federation for Medical and Biological Engineering, (2012) pp.179–182.
- [213] H. Gonçalves, A. Costa, D. Ayres-de-Campos, C. Costa-Santos, A. P. Rocha, and J. Bernardes, *Comparison of real beat-to-beat signals with commercially available 4 Hz sampling on the evaluation of foetal heart rate variability*, **Med. {&} Biol. Eng. {&} Comput.**, 51:6 (2013) 665–676.
- [214] M. Romano, G. Faiella, F. Clemente, L. Iuppriello, P. Bifulco, and M. Cesarelli, *Analysis of Foetal Heart Rate Variability Components by Means of Empirical Mode Decomposition*, XIV Mediterranean Conference on Medical and Biological Engineering and Computing (MEDICON), (2016) pp.71–74.
- [215] P. Tomáš, J. Krohová, P. Dohnálek, and P. Gajdoš, *Classification of cardiotocography records by random forest*, 36th International Conference on Telecommunications and Signal Processing (TSP), (2013) pp.620–923.
- [216] E. Yılmaz and Ç. Kılıkçier, *Determination of Fetal State from Cardiotocogram Using LS-SVM with Particle Swarm Optimization and Binary Decision Tree*,

**Comput. Math. Methods Med.**, 2013 (2013) 1–8.

- [217] K. Roy, S. Das, and K. Saha, C., *Application of FURIA in the Classification of Cardiotocograph*, IEEE International Conference on Research and Development Prospects on Engineering and Technology, (2013) pp.120–124.
- [218] M. Menai, F. Mohder, and F. Al-mutairi, *Influence of Feature Selection on Naïve Bayes Classifier for Recognizing Patterns in Cardiotocograms*, **J. Med. Bioeng.**, 2:1 (2013) 66–70.

## ÖZGEÇMİŞ



### KİŞİSEL BİLGİLER

<b>Adı Soyadı</b>	Zafer CÖMERT
<b>Doğum Yeri ve Tarihi</b>	Elazığ – 1985
<b>Adres</b>	Bitlis Eren Üniversitesi Mühendislik-Mimarlık Fakültesi Bilgisayar Mühendisliği Bölümü Rahva Yerleşkesi Beş Minare Mah. Ahmet Eren Bulvarı 13000 Merkez/Bitlis
<b>E-Posta</b>	<a href="mailto:comertzafer@gmail.com">comertzafer@gmail.com</a>
<b>Web</b>	<a href="http://www.zafercomert.com">www.zafercomert.com</a>

### EĞİTİM BİLGİLERİ

<b>Lisans</b>	Fırat Üniversitesi, Teknik Eğitim Fakültesi, Elektronik- Bilgisayar Eğitimi, 2008
<b>Yüksek Lisans</b>	Fırat Üniversitesi, Eğitim Bilimleri Enstitüsü, Bilgisayar ve Öğretim Teknolojileri Anabilim Dalı, 2012

### MESLEKİ DENEYİMLER

<b>Milli Eğitim Bakanlığı</b>	Şehit Polis Ahmet Yaşar Mesleki ve Teknik Eğitim Merkezi Öğretmen, Teknik Öğretmen (2008-2009)
	Bingöl Endüstri Meslek Lisesi, Teknik Öğretmen (2009-2010)
<b>Üniversite</b>	Bitlis Eren Üniversitesi, Araştırma Görevlisi (2010 – Devam Ediyor)

---

## YAYIN LİSTESİ

---

- Cömert, Z. and Kocamaz, A. F. (2016), “*Evaluation of Fetal Distress Diagnosis during Delivery Stages based on Linear and Nonlinear Features of Fetal Heart Rate for Neural Network Community,*” **International Journal of Computer Applications**, 156 (4)
- Cömert, Z. and Kocamaz, A. F. (2017), “*Prognostic Model for Predicting of Hypoxic Fetuses from CTG Signals using Discrete Wavelet Transform and Image-based Time-Frequency Analysis,*” **Biomedical Signal Processing and Control**, (provisional acceptance)
- Cömert, Z. and Kocamaz, A. F. (2015). “*Determination of QT interval on synthetic electrocardiogram,*” 23rd Signal Processing and Communications Applications Conference (SIU), IEEE.
- Cömert, Z., et al. (2016). “*Cardiotocography signals with artificial neural network and extreme learning machine,*” 24th Signal Processing and Communication Application Conference (SIU), IEEE.
- Cömert, Z. and Kocamaz, A. F. (2016). “*A Study Based on Gray Level Co-Occurrence Matrix and Neural Network Community for Determination of Hypoxic Fetuses,*” International Artificial Intelligence and Data Processing Symposium (IDAP'16)
- Cömert, Z. and Kocamaz, A. F. (2016). “*Comparison of Machine Learning Techniques for Fetal Heart Rate Classification,*” 3rd International Conference on Computational Experimental Science and Engineering. Antalya, Turkey: 601.
- Cömert, Z. and Kocamaz, A. F. (2016). “*Performance Comparison of Neural Network Training Algorithms for Fetal Heart Rate Patterns,*” 3rd International Conference Computational and Experimental Science and Engineering, Antalya, Turkey.