



**UTERUS ELEKTROMYOGRAM SİNYALLERİ  
KULLANARAK KASILMALARIN TESPİTİ VE ERKEN  
DOĞUM KESTİRİMİ**

**DETECTION OF CONTRACTIONS AND ESTIMATION OF  
PRETERM BIRTH BY USING UTERUS  
ELECTROMYOGRAM SIGNALS**

**AYŞE TAŞDÖĞEN**

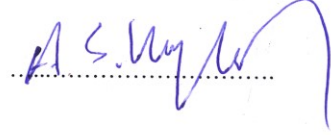
**DOÇ. DR. ATİLA YILMAZ**  
**Tez Danışmanı**

Hacettepe Üniversitesi  
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin  
Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü  
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2017

AYŞE TAŞDÖĞEN' in hazırladığı "Uterus Elektromyogram Sinyalleri Kullanılarak Kasılmaların Tespiti ve Erken Doğum Kestirimi" adlı bu çalışma aşağıdaki jüri tarafından ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI' nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Prof. Dr. A. Salim KAYHAN  
Başkan



Doç. Dr. Atila YILMAZ  
Danışman



Prof. Dr. H. Gökhan İLK  
Üye



Doç. Dr. Ali Ziya ALKAR  
Üye



Yrd. Doç. Dr. Yakup ÖZKAZANÇ  
Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından YÜKSEK LİSANS TEZİ olarak onaylanmıştır.

Prof. Dr. Salih Bülent ALTEN  
Fen Bilimleri Enstitüsü Müdürü

## ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

## ÖZET

# UTERUS ELEKTROMYOGRAM SİNYALLERİ KULLANARAK KASILMALARIN TESPİTİ VE ERKEN DOĞUM KESTİRİMİ

**AYŞE TAŞDÖĞEN**

**Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü**

**Tez Danışmanı: DOÇ. DR. ATİLA YILMAZ**

**Ocak 2017, 100 sayfa**

Dünya çapında her 10 bebekten biri erken doğum sonucu yani 37 haftayı tamamlamadan dünyaya gelmektedir. Erken doğum bir çok problemi beraberinde getirmektedir. Erken doğum yapmış anne ile bebeğin bir süre hastanede kalması ve bebeğe özenli tedavinin uygulanması gerekmektedir. Bu bebeklerde solunum yetersizliği, akciğer rahatsızlıkları, zayıf bağışıklık sistemleri, zihinsel problemler ve öğrenme bozuklukları gibi bir çok rahatsızlık görülmektedir. Bu nedenle erken doğumun önceden kestirilmesi ciddi önem teşkil etmektedir.

Bu problemin kestirilmesinde rahim elektromyogram sinyalleri yöntemi kullanılmıştır. Çalışmanın ilk aşamasında kaynak taraması yolu ile seçilmiş öznetelikler kullanılarak sinyal üzerinde meydana gelen önemli olaylardan kasılma olayı diğer olaylardan ayırt edilmiştir. Bu sınıflandırma için doğrusal sınıflandırıcı olan en yakın uzaklık sınıflandırıcı ve doğrusal olmayan sınıflandırıcı olarak yapay sinir ağları kullanılmıştır. En yakın uzaklık sınıflandırma performansını arttırmaya yönelik ağırlık

eniyileme çalışmaları yapılarak elde edilen sınıflandırma performansı arttırılmıştır. Doğrusal olmayan sınıflandırıcı yapay sinir ağları ile kasılma ve rahimde meydana gelen kasılma, muhtemel kasılma ve bebeğin hareketi gibi olaylar başarılı olarak sınıflandırılmıştır. Bu olaylardan doğum hakkında önemli bilgi içeren kasılma olayı diğer durumlardan (bebeğin hareketi gibi) daha fazla önem taşımaktadır. Kasılma olayı hamilelik, erken doğum veya normal doğuma ait sinyaller üzerinde oluşabilmektedir. İkinci aşamada yapay sinir ağları yöntemi kullanılarak önceki sınıflandırmada elde edilen kasılmaların erken doğum, hamilelik veya normal doğum olaylarından hangisine ait olduğu incelenmiştir. İnceleme sonucu erken doğum kasılmaları diğer kasılmalardan başarılı olarak ayırt edilmiştir.

İki sınıflandırma performansının da kanallara göre değişimi incelenmiştir. Yüksek başarı elde edilen kanallar iki sınıflandırma için de farklı kanallardır. Bununla birlikte aynı katılımcının farklı zamanlarda meydana gelmiş kasılmalarına ait öznitelik değerleri karşılaştırılmıştır. Bu şekilde zaman-öznitelik değişimleri incelenerek zamanla daha çok ayırt edici olan özneliğin belirlenmesi amaçlanmıştır.

Bu çalışmalara ek olarak Matlab ortamında sonraki çalışmalarda faydalı olabilmesi amacıyla bir sinyal işleme ve analiz arayüzü oluşturulmuştur. Arayüzde sinyal ön işleme çalışmaları, enerji ve korelasyon analizleri, öznitelik çıkarımı ve zaman-frekans analizleri yapılabilmektedir.

**Anahtar Kelimeler:** Erken doğum, rahim EMG, kasılma tespiti, yapay sinir ağları, Matlab.

## **ABSTRACT**

# **DETECTION OF CONTRACTIONS AND ESTIMATION OF PRETERM BIRTH BY USING UTERUS ELECTROMYOGRAM SIGNALS**

**AYŞE TAŞDÖĞEN**

**Master, Department of Electrical and Electronics Engineering**

**Supervisor: Assoc. Prof. DR. ATİLA YILMAZ**

**January 2017, 100 pages**

One in ten baby, worldwide borns before 37 weeks of pregnancy. Preterm birth brings lots of problems to the family afterwards. The mother who gives preterm birth and her child must stay in the hospital for a beginning and the child must be treated carefully. These babies might have many preterm associated discomforts such as respiratory insufficiency, lung disorders, weak immune systems, mental problems and learning disorders in their future. For this reason, the correct estimation of preterm has a great importance in order to increase the possibilities of eliminating some of those problems.

In this study, uterus EMG signals are used to estimate preterm births. In the first part of the study, using some features selected after the literature review, specifically contractions which are the set of important events occurred on the EMG signals were classified from other significant events. For the classification stage, minimum distance classifiers as a linear classifier example and artificial neural networks as a non-linear classifier example are used. The performance of minimum distance classifier has been

improved by adjusting class weights based on known class samples. Artificial neural networks classify the events like contraction, possible contraction and foetal movements that have occurred on the uterus. The contraction carrying important information about a birth is more important than other situations (such as baby movement) among all events. Besides, the contraction can occur in the signals including pregnancy, premature birth or normal birth. In the second part, contractions which were analysed by the first classification stage were reconsidered again in terms of understanding the differences of preterm birth, normal birth and pregnancy terms by assigning new artificial neural network units. As a result of this second part of the study preterm birth contractions were isolated from other term contractions successfully.

Both of two classification performances were analysed in terms of the use of different bipolar channels. It is reported that the channels giving the best performance for the certain classifiers for an each classification effort. At the same time, time dependent variations in the features of contractions have been monitored and compared for temporal analysis. In this way, it was aimed to define more distinctive feature associated by time dependent variations. In addition to these studies, an interface for signal processing and dedicated analysis tools has been developed in the Matlab environment in order to give a better presentation for the results. Through the interface, signal preprocessing studies, energy and correlation analysis, feature extractions and time-frequency analysis can be planned.

**Keywords:** Preterm birth, Uterine EMG, Contraction Detection, Artificial Neural Networks, Matlab.



## TEŐEKKÜR

Tez alıőmamın her aőamasında deęerli katkı ve eleőtrileriyle yol gősteren, sonsuz sabırla beni her zaman alıőmaya teővik edip guven veren ve yuereklemdiren deęerli danıőmanım Sayın Do. Dr. Atila YILMAZ'a, her turlu desteęi esirgemeyen ve her zaman yanımda olan aileme itenlikle teőekkurlerimi sunarım.



# İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	1
ABSTRACT.....	3
TEŞEKKÜR.....	5
ÇİZELGELER.....	8
ŞEKİLLER.....	9
SİMGELER VE KISALTMALAR.....	11
1.GİRİŞ .....	12
2. ERKEN DOĞUM TESPİT YÖNTEMLERİ .....	15
2.1. Rahim ve Anatomik Yapısı.....	15
2.2. Rahim EMG Veri Seti.....	17
2.3. Doğum Sinyali Kestirimi Uygulamaları.....	19
2.4.1. Yapay Sinir Ağı Uygulamaları.....	22
2.4.2. Sınıflandırma Amaçlı Sinyal İşleme Sistematiği .....	24
3. ÖZİNİTELİK BELİRLEME .....	25
3.1. İlgili Çalışmalarda Kullanılan Öz nitelikler .....	25
3.1.1. Doğrusal Öz nitelikler .....	26
3.1.2. Doğrusal Olmayan Öz nitelikler.....	29
3.2. Dalgacık Dönüşümü (Wavelet) Analizi .....	31
3.2.1. Dalgacık Dönüşümü.....	32
3.3. Boyut İndirgeme.....	36
3.3.1. FDA(Fischer Discriminant Analysis).....	36
4. SINIFLANDIRMA YÖNTEMLERİ .....	40
4.1. En Yakın Uzaklık Sınıflandırıcı.....	40
4.2. Yapay Sinir Ağları .....	41
4.2.1. Yapay Sinir Ağı Modelleri.....	43
4.2.2. Çok Katlı Perceptron (MLP) Yapay Sinir Ağı .....	45
5. SİNYAL ÖN İŞLEME ve SINIFLANDIRMA SONUÇLARI .....	47
5.1. Dalgacık Paket Dönüşümü Eşik Değer Yöntemi ile Gürültü Yok Etme.....	48
5.2. Kasılma Tespiti için Uygulamalar.....	51
5.2.1. Algoritma 1 .....	51
5.2.2. Algoritma 2 .....	53
5.2.3. Teager Enerji Operatörü.....	55

5.2.4. Dalgacık Dönüşümü ve Teager Enerji Dönüşümü .....	56
5.3. En Yakın Uzaklık Sınıflandırıcı İçin Ağırlık Düzeltme.....	58
5.4. Yapay Sinir Ağları ve En Yakın Uzaklık Sınıflandırıcı Sonuçları.....	59
5.4.1. Erken Doğum, Normal doğum ve Hamilelik Sinyallerinin Sınıflandırılması .....	62
5.4.2. Farklı Kanallar Üzerinden Yapılan Sınıflandırmalar .....	63
5.4.3. Zaman-Öznitelik Değişimi .....	65
6. MATLAB'TA SINYAL İŞLEME VE ANALIZI İÇİN GRAFİKSEL KULLANICI ARAYÜZÜ (GUI).....	69
6.1. Giriş.....	69
6.2. Matlab Ortamında Arayüz Oluşturma.....	69
6.3. EMG Sinyal İşleme ve Analiz Arayüzü .....	72
6.3.1. Veri Paneli.....	72
6.3.2. Enerji Paneli .....	76
6.3.3. İlinti Paneli .....	77
6.3.4. Dipnot Paneli.....	78
6.3.5. Kasılma Belirleme Paneli.....	79
6.4. Spektral Analiz ve Öznitelik Çıkarma Arayüzü.....	81
6.4.1. Yoğunluk Analiz Paneli .....	82
6.4.2. Öznitelik Çıkarımı Paneli.....	82
6.4.3. Dalgacık Dönüşümü Paneli.....	83
7. SONUÇLAR .....	87
KAYNAKÇA.....	90
ÖZGEÇMİŞ .....	96

## ÇİZELGELER

	<u>Sayfa</u>
Tablo 1- Sınıflandırıcı Sonuçları.....	60
Tablo 2-Bipolar Kanalların Genel ve Kasılma Sınıfı İçin Doğruluk Oranları .....	61
Tablo 3- Yapay Sinir Ağı Özellikleri.....	62
Tablo 4- Bipolar Kanalların Genel ve Erken Doğum Sınıfı İçin Doğruluk Oranları.....	53



# ŞEKİLLER

## Sayfa

Şekil 1.Rahim ve ana bölümleri[9].....	16
Şekil 2.Farklı elektrot Dizilimleri[10].....	18
Şekil 3.Elektrot Dizilimi[7].....	19
Şekil 4.ROC karakteristiklerinin karşılaştırılması[4] .....	22
Şekil 5. Sinyal İşleme Blok Diyagramı .....	24
Şekil 6. Dalgacık Dönüşümü Fonksiyonları [44].....	32
Şekil 7. a)Ölçek =1 b) Ölçek =2 c) Ölçek= 4 [44] .....	32
Şekil 8. Dalgacık Dönüşümü H_0:Yüksek Geçirgen,G_0:Alçak Geçirgen [44] .....	34
Şekil 9. Dalgacık Dönüşümü[1] .....	35
Şekil 10. DalgacıkPaket Dönüşümü[1] .....	35
Şekil 11. Farklı veri boyutuna ait grafiksel gösterim [45].....	36
Şekil 12. İki boyutlu üç farklı sınıf için farklı karar sınırları [45].....	37
Şekil 13. Farklı doğrular üzerine alınan iz düşümler [45].....	38
Şekil 14. En Yakın Uzaklık Sınıflandırıcı.....	40
Şekil 15. Biyolojik Sınır Hücresi (Fausset L. 1994) [48].....	41
Şekil 16. Yapay sinir ağı modeli .....	42
Şekil 17.Perceptron ağı (sol) ve tek perceptron (sağ).....	44
Şekil 18. Girdi katmanı, Ağırlıklar ve Ara katman Çıktı katmanı .....	45
Şekil 19. 4x4 elektrot Dizilimi[7] .....	47
Şekil 20. Monopolar Rahim Sinyalleri[9] .....	47
Şekil 21. Bipolar Sinyaller[9].....	47
Şekil 22. Dalgacık Paket dönüşümü a) Analiz b) Sentez blok diyagramları.....	48
Şekil 23. Gürültü Azaltma Öncesi ve Sonrası Rahim EMG Sinyali .....	50
Şekil 24. Sinyalin 1.ve 2. Türevleri.....	52
Şekil 25. Ağırlıklandırılmış ve Kare Alıcı Filtre ve Ortalama Alıcı Filtre sonuçları .....	53
Şekil 26. (a) Enerji Sinyali (b) Algoritmaya Göre Elde Edilen Kasılma bölgeleri .....	54
Şekil 27. Algoritma sonuçlarını karşılaştırma .....	54
Şekil 28. Teager Enerji Operatörü sonucu .....	55
Şekil 29. Teager Enerji ve Algoritma 2 Sonuçları Karşılaştırma .....	56
Şekil 30. Dalgacık Dönüşümünden Sonra Teager Enerji Analizine Teager Enerji Analizi.....	57
Şekil 31. Karmaşıklık Matrisleri .....	60
Şekil 32. Farklı Kanallara Ait Genel Doğruluk ve Kasılma Sınıfının Doğruluk Oranları .....	61
Şekil 33.Genel doğruluk ve Erken doğum sınıfına ait Doğruluk Oranlarının Kanallara Göre Dağılımı.....	64
Şekil 34.Farklı zamanlardaki Kasılma Öznitelik Değerleri .....	65
Şekil 35. İki farklı sinyalde meydana gelen kasılmalar.....	66
Şekil 36. Normal doğuma ait öznitelik değerleri .....	66
Şekil 37. Haftalara göre Öznitelik Değerleri.....	67
Şekil 38. Örnek Matlab Arayüzü.....	69
Şekil 39. Matlab'ta GUIDE Aracı .....	70
Şekil 40. Nesnelere Arayüze Ekleme.....	70

Şekil 41. Nesneleri Görselleştirme.....	71
Şekil 42. Arayüzden programlamaya geçiş.....	71
Şekil 43. Seçilen Nesnenin Fonksiyonu.....	72
Şekil 44. Sinyal Analiz Arayüzü.....	73
Şekil 45. Veri Paneli.....	73
Şekil 46. EMG Sinyalin Arayüze Aktarılması.....	74
Şekil 47. Kasılma Etiketleme için Uygulanan Algoritma 2 sonucu.....	75
Şekil 48. Teager Enerji Analiz Sonucu.....	76
Şekil 49. Dipnot Bilgileri fm:foetal hareket, C:kasılma.....	76
Şekil 50. Enerji Paneli.....	77
Şekil 51. Korelasyon Paneli.....	78
Şekil 52. Dipnot Paneli.....	79
Şekil 53. Kasılma Paneli.....	80
Şekil 54. Başlangıç(*) ve Bitiş(o) Noktaları.....	80
Şekil 55. Algoritma Sonuçları ile Dipnot Değerleri.....	81
Şekil 56. Spektral Analiz ve Öznitelik Çıkarma Arayüzü.....	81
Şekil 57. Hızlı Fourier Dönüşümü ve Güç Spektral Yoğunluk Fonksiyonu.....	82
Şekil 58. Öznitelik Paneli.....	82
Şekil 59. Dalgacık Dönüşümü Paneli.....	83
Şekil 60. Temel Dalgacık Dönüşümü Fonksiyonları.....	84
Şekil 61. Dalgacık Dönüşümü Katsayıları ve sinyalin tekrar elde edilmesi.....	84
Şekil 62. Dalgacık Dönüşümü ile Sinyalin Sentezi ve Fark Sinyali.....	85
Şekil 63. Dalgacık Dönüşümü Ayrışım ve Yaklaşım katsayıları.....	86

# SİMGELER VE KISALTMALAR

## Simgeler

## Kısaltmalar

EMG	Elektromyogram
EHG	Elektrohogram
EEG	Elektroensefalogram
GSY	Güç Spektral Yoğunluk



## 1.GİRİŞ

Dünya Sağlık Örgütü'nün tanımına göre erken doğum bebeğin 37 haftayı tamamlamadan önce doğmasına denir [1]. Normal gebelik süreci 37-40 hafta arasındadır. Erken doğumların %70'i 34-37' nci haftalar arasında gerçekleşir [1]. Dünya Sağlık Örgütü'nün açıklamalarına göre her yıl 15 milyon bebek bu süreden daha önce dünyaya gelmektedir. Bu rakam her 10 bebekten birinin erken doğum sonucu dünyaya geldiğini göstermektedir. Erken doğum sonucu dünyaya gelmiş bebeklerde kalıcı birçok sorun meydana gelmektedir. Anne karnında gelişimini yeterince tamamlamadan dünyaya gelen çocuklarda, beyin felci görülme oranı normal zamanında doğmuş çocuklara göre daha yüksektir. Öğrenme bozukluklarına dayalı zihinsel problemler, bağırsak ile ilgili rahatsızlıklar, solunum yetersizliği gibi akciğer hastalıkları, bağışıklık sisteminin zayıf olması ve buna bağlı enfeksiyonlar, görme ve işitme bozuklukları gibi problemler daha sık görülmektedir [1],[2]. Bu gibi ciddi sağlık problemleri çocuğun yaşamında kalıcı bir problem haline gelebilmektedir. Normal zamandan daha önce (37 haftayı tamamlamadan) doğan çocukların daha uzun süre hastanede kalması gerekmektedir. Bu olumsuz faktörler nedeniyle normal şartlarda bir bebeğin 9 ay 10 gün anne karnında kalması bebeğin sağlıklı olarak hayatta kalması açısından önem taşımaktadır. Anne karnında geçirilen bir gün bile bebeğin doğumdan sonraki hayatı için çok önemlidir. Erken doğum riski taşıyan bebeklerin bir süre daha anne karnında kalması için her türlü tıbbi çabasarfedilmektedir. Gerçek sebebi tam olarak açıklanamayan erken doğumu önceden kestirmek için bilimsel çalışmalar da sürmektedir. Doğum sancılarını durdurma işlemi olan tokoliz tedavisi bu müdahalelerden biridir. Bu tedavide anneye ağız ve damar yoluyla ilaçlar verilmektedir. Ayrıca bebeğin akciğer gelişimini tamamlamasına yönelik ilaçlar da anneye uygulanmaktadır. 34' üncü haftaya kadar devam ettirilen bu tedavide hala doğum sancıları kesilmezse tokoliz tedavisi yarıda bırakılır. Bu alandaki bilimsel çalışmalara rağmen henüz erken doğumu kesin olarak belirlemek mümkün değildir [3].

Erken doğum tespiti için amaç; mümkün olduğunca anne ve çocuk sağlığını doğru kararlarla korumak, bebeğin anne karnında kalma süresini arttırmak, hem doğum esnasında ve doğum sonrasında erken doğuma bağlı sorunların ve rahatsızlıkların ortadan kaldırılmasını sağlamak, doğum sonrası bebeğin ve annenin hastanede gereksiz kalmasını önlemek ve buna bağlı olarak kullanılan ilaç tedavisinin ortadan kaldırılarak daha sağlıklı bir doğumun gerçekleşmesini sağlamaktır [4]. Erken doğumun daha önceden kestirilememesi sonucu doğumu gerçekleştiren bir bebeğin dolayısıyla annenin yukarıda



belirtilen sađlık ve maddi problemlerle karřılařması önlenemeyecektir. Bu gibi istenmeyen durumların oluřmasını önlemek için en iyi sonuç verecek seviyede erken dođumun kestirilmesi ve kestirim yapılırken hata oranının enaz olması hedeflenmelidir. Erken dođumun kestirimi için uygulanan yöntemler arasında EMG sinyalleri kullanım kolaylıđı ve sonuçların güvenliđi açısından diđer yöntemlere göre daha uygun ve daha başarılı bir yöntem olarak sunulmaktadır [4]. 1950'li yıllardan beri birçok akademik çalıřmaya konu olan EHG, son yıllarda bu önemli amaç için umut verici bir yöntem olarak tekrar ele alınmaktadır.

EMG sinyallerinin frekans tabanlı çözümlenmeleri ve zaman tabanlı analizleri normal dođum kasılmaları ve erken dođum kasılmalarını birbirinden ayırabilme konusunda önemli ölçüde bilgi vermektedir. Bu tezde erken dođumun EMG sinyalleri yöntemiyle kestirim yapılması amaçlanmıřtır. Uygulanan çalıřmada öznitelikler ve sınıflandırıcı belirlenirken rahim sinyallerinin dođrusal ve durađan olmayan yapısı göz önünde tutulmuřtur. Kaynaklar incelendiđinde en belirleyici parametrenin ne olduđu ile ilgili çalıřmaların devam ettiđi görülmektedir ancak bu konuda kesin bir sonuca ulařılmamıřtır. Uygulanan çeřitli yöntemlere göre zamanında dođum için ve erken dođum tespiti için kabul edilen en önemli frekans tabanlı parametrelerden birisi olarak Güç Spektral Yođunluk Fonksiyonu gösterilebilir. Bununla birlikte bazı çalıřmalarda Fourier Dönüřümü, Dalgacık Analizi veya Zaman-Frekans Analizi hesaplanır ve ilgili yorumlar yapılabilir. Bu çalıřmada ise zaman ve frekans tabanlı özniteliklerden 11 adet öznitelik belirlenmiřtir. Kaynaklardan seçilen bu özniteliklerin farklı amaçlarla sınıflandırma performansına etkisi çalıřmaları yapılmıřtır [5],[6].

Günümüze kadar gelen arařtırmalarda erken dođum kestirim yöntemi olarak hangi yöntemin kullanılması konusunda da kesin bir sonuca ulařılmamıřtır. Bunun yanında rahim EMG sinyallerinin dođrusal ve durađan olmayan yapısından dolayı sınıflandırıcı olarak dođrusal olmayan yapay sinir ađları da uygun bir yöntem olarak görülmektedir. Bununla birlikte dođrusal sınıflandırıcılardan ise en temel sınıflandırma yöntemi olan en yakın uzaklık sınıflandırıcı incelemeye alınmıřtır. Elde edilen sonuçlar erken dođum kestirimi için umut vericidir.

Çalıřmada kullanılan veri seti Pyhsionet internet sitesinde yer alan İzlanda veri setidir. Bu veri setinde 45 farklı kadından hamilelik veya dođum anında kaydedilen 122 sinyal bulunmaktadır. Bu sinyaller 16 elektrot kullanılarak kaydedilmiřtir [7].

Sinyaller üzerinde yer alan kasılma bölgelerinin diğer bölgelerden ayırt edilmesinde %86,4 performans, genel doğruluk oranı olarak ise %79 performans elde edilmiştir. Hamilelik, erken doğum, normal doğum veya erken doğum ile sonuçlanmış hamilelik zamanına ait rahimde kasılmalar oluşabilmektedir. Bu kasılmaların diğer olaylardan ayırt edilmesinden sonra tekrar bu kasılmalar da kendi içinde sınıflandırılmıştır. Erken doğum, hamilelik ve normal doğum sinyallerinden oluşan kasılmalar içinde erken doğum kasılmaları 87,5% doğruluk oranı ile sınıflandırılmıştır. Sınıflandırma performansının kanallara göre değişimi de incelenmiştir.

Bu çalışma ile erken doğumun tespit edilmesi için önce kasılma bölgeleri sinyal üzerinde meydana gelen diğer önemli olaylardan ayrılmıştır. Belirlenen bu kasılmalarından erken doğuma ait kasılmalar da yapay sinir ağları ile sınıflandırılmıştır. Performans sonuçları değişimi her bir bipolar kanala göre incelenmiştir. Bu çoklu kanallar arasında 2, 4, 7 ve 12' nci bipolar kanallar sınıflandırma aşamasında en iyi sonuçları vermiştir.

Tezde rahim sinyallerini kolaylıkla analiz edebilmek için Matlab ortamı kullanılarak sinyal işleme ve analiz arayüzü oluşturulmuştur. Arayüzde sinyal ön işlemleri, filtreleme işlemleri, enerji analizleri, kanalların enerji ve ilinti kıyaslamaları, kasılma bölgelerinin otomatik olarak kestirilmesine yönelik çalışmalar, zaman ve frekansa dayalı özniteliklerin hesaplanması ve kaydedilmesi mümkündür. Ayrıca bu arayüze farklı veri setlerinin de uyarlanması ileride kaydedilen başka sinyallerin analizine yönelik çalışmalara da katkı sağlayacağı düşünülmektedir.

Bu çalışma genel olarak altı bölümden oluşmaktadır. Çalışmanın ikinci bölümünde erken doğum tespit yöntemleri, kullanılan veri setleri, rahmin anatomik yapısı ve kullanılan elektrot dizilimleri, erken doğum tespiti için yapay sinir ağları ile yapılan çalışmalar konusunda bilgi verilmiştir. Üçüncü bölümde öznitelik çıkarımı ve daha önce bu amaca yönelik olarak kullanılan öznitelikler ve bu çalışmada kullanılan öznitelikler hakkında bilgi verilmiştir. Dördüncü bölümde kullanılan sınıflandırıcılar, beşinci bölümde sinyal işleme adımları ve kullanılan sınıflandırıcılara göre elde edilen sonuçlar ve bu sonuçların farklı kanallara göre değişimi ile ilgili bilgi verilmiştir. Altıncı bölümde Matlab ortamında oluşturulan arayüz ile ilgili detaylı bilgi yer almaktadır. Son olarak yedinci bölümde değerlendirme ve sonuç kısmı yer almaktadır.

## 2. ERKEN DOĞUM TESPİT YÖNTEMLERİ

Erken doğum tespit yöntemlerini ayrıntılı incelemeden önce rahim yapısı ve kullanılabilir veri tabanları ile ilgili bilgileri gözden geçirmek gerekmektedir.

### 2.1. Rahim ve Anatomik Yapısı

Kadın üreme organı olan rahim bebeğin hamilelik süresi boyunca kaldığı yere denir. Rahimde, hamilelik ve doğum esnasında birçok değişiklik gözlenmektedir. Fiziksel olarak doğum işlemi genel olarak karmaşık bir süreçtir. Bu süreçte bir takım hormonal ve fiziksel değişiklikler olmasının yanında doğumu tetikleyen bu hormonal faktörlerin eşik değeri tam olarak bilinmemektedir.


Birden fazla parametre ve duruma bağlı olan karmaşık doğum olayının kesin zamanının belirlenmesi için hormonal faktörlerden başka parametrelerin de araştırılması yararlı olur. Bunun için rahim bölgesinden elektrotlar yardımıyla alınan sinyaller analiz edilmektedir. Rahim bölgesine farklı elektrot dizilimleri ile sinyaller kaydedilebilir. Fakat bu dizilimler belirlenirken rahmin fiziksel yapısı ve yeri göz önünde bulundurulmalı ya da bu konuda uzman doktorlardan yardım alınmalıdır. Çeşitli elektrot dizilimleri ve bu şekilde elde edilen sinyallere geçmeden önce rahmin anatomik yapısı ve doğum olayının rahim üzerindeki hormonal olarak etkisi aşağıda açıklanmıştır.

#### 2.1.1. Doğum Olayının Rahim Üzerindeki Hormonal Etkisi

Kadın üreme organı olan rahim kasık bölgesinin merkezindedir. Bu bölgede bulunan idrar torbası ve rectumun yani kalın bağırsağın son kısmı arasında yer alır. Sağ ve sol tarafında (fallop tüpleri) yumurtalıklar yer alır. Rahim normal durumda 30 ile 80 gram aralığındadır. Gebelik döneminde rahmin ağırlığında da artış görülmektedir. Ters üçgen şeklini andıran rahim üç ana bölümden oluşur. Bunlar, serviks (rahim ağzı), rahmin iç kısmı ve fundustur. Rahmin ana bölümleri Şekil 1'de verilmiştir.

Rahim ağzı boyutu ortalama 3 cm olurken (serviks) her kadının yaşına ve hormonal olarak menstrual döngüsüne göre farklılık gösterir [8]. Rahmin en alt kısmında bulunur. Hamilelik boyunca embriyoya zarar verebilecek zararlı her türlü şeyin rahme girişini engeller. Rahim kasılma yeteneği çok güçlü olan kaslardan meydana gelir. Rahim ana

duvarında 3 ana kısım vardır. En içten dışa doğru; endometriyum, miyometriyum ve seroza yer alır [9].



Şekil 1.Rahim ve ana bölümleri[9]

Endometriyum bölgesi rahmin en iç kısmında bulunur ve eğer yumurta döllenmiş ise embriyo gelişim sürecinde kalınlaşır ve embriyonun gelişimini tamamlayacağı rahat yatak ortamını oluşturur. Yumurtalıklarda gelişen yumurta döllenmez ise menstürel döngü ile birlikte dışarı atılır. Miyometriyum rahmin dış kısmında bulunan en kalın yapıdır. Hamilelik boyunca bu yapı da boyut olarak değişiklik gösterir. Doğum sırasında hormonal ve fiziksel faktörlerin de etkisiyle bebeğin ve plasentanın dışarı atılmasında rol oynar. Embriyonun büyümesi ile miyometriyum hacimsel olarak yeterince genişleyebilecek yapıya sahiptir. Doğum sonrasında ise hacimsel olarak eski şeklini alır.


En dış kısımda bulunan yapı serosa, rahmi çevreler ve korur. Yüzeyindeki bağlar sayesinde rahmin sabit durabilmesini sağlar. Hamilelik süresi boyunca meydana gelen fiziksel ve hormonal değişiklikler sayesinde doğum meydana gelir. Hormonal olarak progesteron ve östrojen hormonlarının değişimi rahim üzerindeki kasların kasılabilirliğini arttırdığı için doğum üzerinde etkilidir. Progesteron hormonu hamilelik süresince rahimdeki kasların kasılabilirliğinin aşırı artışını kontrol eder. Bu şekilde embriyonun tutunmasında rol oynar. Östrojen hormonu temel olarak rahim kaslarının kasılabilirliğini arttırarak doğumda etkin role sahiptir. Bu kasılmalar sayesinde doğum başlayacağı için, kasılabilirliğini azaltan progesteron-östrojen oranı doğum öncesi azalır. Fakat bu hormonların neye göre artış ya da azalış gösterdiği bilinmemektedir. Oksitosin hormonu

doğum olayında etkili olan bir diğer hormondur. Doğum yaklaştıkça bu hormonun seviyesi artar. Rahim yüzeyindeki kasların kasılabilirliğinin artmasında yine bu hormon etkilidir [9].

## 2.2. Rahim EMG Veri Seti

Erken doğum istatistiksel olarak normal doğumların %10'unu oluşturduğu için bu alanda geniş ve kapsamlı veri setinin elde edilmesi erken doğum kestirimi üzerinde büyük etkisi olacaktır. Çünkü rahim sinyalleri her bir kadında farklı olabilmektedir. Veri seti ne kadar kapsamlı olursa elde edilen doğruluk değerleri de gerçeğe o kadar yakın olacaktır. Rahim EMG sinyalleri rahim yüzeyine yerleştirilen farklı elektrot dizilimleri ile kayıt edilebilir. Bu dizilimler daha önce deneysel çalışmalar sonucu ve Kadın Doğum doktorları tarafından belirlenmiş olup rahmin bulunduğu bölge yapısına göre belirlenmiştir. Pysionet internet sitesinde kolaylıkla ulaşılabilen 2 farklı rahim EMG veri tabanı bulunmaktadır. Lubliyana ve İzlanda veri setleri kaynaklarda sunulan çalışmalarda da sıklıkla kullanılmıştır. Lubliyana veri seti 4 elektrot kullanılarak kayıt edilmiş erken doğum ve normal doğum sinyallerini içerir. Bu veri setinde bulunan kayıt edilen sinyaller her biri farklı kadından elde edilmiştir. Ayrıca bu sinyaller üzerinde çok fazla gürültü mevcuttur [10].

Elektrot sayısının fazla olması rahim sinyallerinin incelenmesinde daha fazla bilgi içerir. Bu tezde üzerinde çalışılan veri seti Physionet internet sitesinde bulunan İzlanda veri setidir [11]. 16 kanaldan kayıt edilen bu veri seti doğum ve normal doğum, erken doğum sinyallerini içermektedir. İzlanda veri seti 16 elektrot ile 45 farklı kadından kaydedilmiş 122 rahim sinyali içerir. 45 kadından kaydedilen sinyallerin 112 tanesi hamilelik 10 tanesi doğum sinyalidir. Her bir kadından sinyaller hamileliğin belirli haftalarında, hem hamilelikte hem doğum anında ya da yalnız doğum anında kaydedilmiştir. Kayıtlarda sinyallerin ilk 30 saniyesi için takograf cihazı kaydının görüntüsü bulunmaktadır. Sinyallerle ilgili diğer bilgi ise 111 sinyal için bulunan ön bilgilerdir. Şekil 2'de elektrotlar 7 cm'lik aralıklarla dördü dizilim yada 16 elektrotluk olarak verilen iki farklı elektrot dizilimi verilmiştir.



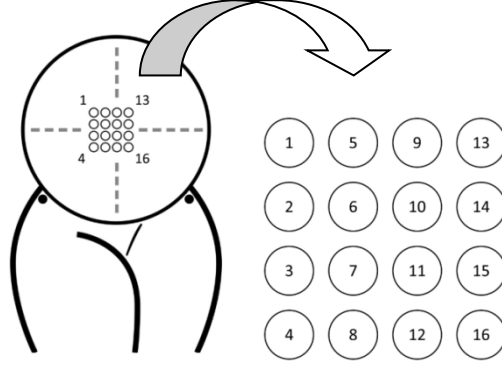
**Şekil 2.** Farklı elektrot Dizilimleri [10]

Önemli olayların çeşidini ve zamanını içeren bu bilgiler hem kayıt sırasında katılımcı üzerindeki gözlemler ve katılımcının hissettiği kasılmalar, hareketlenmelerdir. Bunların ön bilgi olarak kaydedilmesi için takograf kaydında da gözlemlenmiş olması gerekir. Bazen katılımcının hissettiği kasılma ve hareketlenmeler takograf cihazında görülmeyebilir. Ya da katılımcının hissedemediği olaylar takograf cihazında gözlemlenebilir. Ön bilgiler yani katılımcının kayıt sırasında hissettiği olaylar aynı zamanda takograf kaydında da görülmesi sonucunda kaydedilir. Bu yüzden her sinyal için bilgi notu bulunmamaktadır. Ön bilgiler şu şekildedir:

- Kasılma
- Muhtemel kasılma
- Katılımcının hareketi
- Pozisyon değişimi
- Bebeğin hareket etmesi
- Kayıt cihazlarından kaynaklı gürültü

Hamilelik süreç (pregnancy) sinyallerinin ortalama kayıt süresi 61 dakika olmak üzere en kısa kayıt 19, en uzun 81 dakikadan oluşmaktadır. Hamilelik doğum (labor) sinyallerinin kayıt süresi ise ortalama 36 dakikadan yine en kısa kayıt 8 dakika en uzun kayıt 64 dakikadan oluşmaktadır. Kaydedilen her sinyal için ilgili açıklama (gestasyonel zamanı, varsa önceki doğum bilgileri ve doğum şekli, yapay oksitosin bilgisi vb.) detaylı olarak yer almaktadır [7].

Katılımcılardan elde edilen sinyaller Şekil 3' te verilen elektrot dizilimine göre elde edilmektedir. Monopolar 16 kanal sinyalden bipolar sinyaller elde edilmiştir. Gürültü seviyesini azaltmak için sinyal işleme aşamasında kanallar bipolar olarak ele alınmıştır.



**Şekil 3.** Elektrot Dizilimi [7]

Kayıtlı bilgiler yardımıyla, kasılma, bebek hareketi gibi sinyal aralıkları bilinmektedir. Bu nedenle kasılma, muhtemel kasılma, bebek hareketi, pozisyon değişimi, kasılma ve bebek hareketi olarak daha önceden belirlenen sinyal aralıklarının her birine özgü öznitelikler çıkarılmıştır.

Özniteliği çıkarılan önemli olayların sayısı şöyledir:

- 223 Bebek hareketi (Foetal movement),
- 224 Kasılma (Contraction),
- 44 Muhtemel kasılma (Possible Contraction),
- 43 Kasılma ve bebek hareketi
- 42 Katılımcının hareketi (Participant Movement),
- 4 Katılımcının pozisyon değişimi (Participant Change of Position),
- 21 Ekipmandan kaynaklı gürültü (Equipment Manipulation),

Bu olaylardan; ekipmandan kaynaklanan gürültü, katılımcının hareketi veya pozisyon değiştirmesi hamilelik ya da doğum ile ilgili kasılmalar hakkında bilgi içermemektedir. Bu nedenle bunlar dışındaki bilgiler kullanılmıştır. Bu bilgiler yardımıyla kasılma muhtemel kasılma ve foetal hareketlenmeleri en iyi performansta kestirim yapılmaktadır. Bu kestirim bilgilerine göre kasılma bölgeleri tespit edildikten sonra erken doğum kaydı yeralan sinyallerin kasılmaları sınıflandırılmaktadır.

### 2.3. Doğum Sinyali Kestirimi Uygulamaları

Doğum ve hamilelik sinyallerinin belirlenmesinde yapılan çalışmalar incelenmiştir. Hamilelik ve doğum sinyallerini sınıflandırma doğruluğunu arttırmak için frekans ile ilgili

parametreler yardımıyla çoklu destek vektör makinesi (Support Vector Machines) yöntemi ile farklı bir veri setine uygulanmıştır. Hamilelik ve doğum sırasında alınan sinyallere uygulanan çoklu SVM metodu sonucu sınıflandırma doğruluk oranı hamilelik için %93,5 iken doğum için %84,3 olarak elde edilmiştir [12].

Zaman ve frekans tabanlı analiz yöntemi olan dalgacık yönteminde gerçekleştirilen analiz sonucu hamilelik ve doğum kasılmalarının enerjisi karşılaştırılmıştır. 3'üncü seviyeden dalgacık paket açılımının enerjisi, hamilelik ve doğum sinyalleri arasında ayırt edici bir yöntem olarak belirlenmiştir. Gestasyon haftası arttıkça dalgacık paketlerinin enerjilerinin arttığı görülmüştür [13].

Doğum ve hamilelik sinyallerinin kestirilmesinde ortalama frekans ve kasılmanın süresi önemli bir ipucu vermektedir. Doğum sinyalleri genel olarak yüksek frekanslı ve meydana gelen kasılmalar uzun süreli olmaktadır. Hamilelikteki kasılmalar bunun aksine daha kısa süreli olmaktadır. Ayrıca bu sinyallerin doğum kayıtlarına göre daha düşük frekansta ve parametre değerlerinin düşük olduğu tespit edilmiştir [14].

Uygulanan çalışmalarda önemli olan üç temel unsur vardır. Bu unsurlar; veri seti, sınıflandırıcı yöntemi ve özneliliklerdir. Bunun önemini vurgulayan bir çalışma aynı veri setinde frekans analizi yapıp medyan frekansının en iyi ayırt edici parametre olduğu görülmüştür [15]. Bu araştırmanın devamı olarak aynı veri seti ve öznelilikler kullanılarak iki farklı yapay sinir ağları modeli ve performansları karşılaştırılmıştır. Yarışan (Competitive) Neural Network sinir ağı ile Radial Tabanlı fonksiyon sinir ağı sırasıyla %78,4 ve %82,65 doğruluk oranlarını vermiştir [5].

Rahim EMG sinyallerini erken doğum, normal doğum veya hamilelik sinyalleri olarak ayırt edebilmek amacıyla ANN (Artificial Neural Network) birçok kez kullanılmıştır. 37 haftanın öncesi ve sonrasında kaydedilen hamilelik veya doğum sinyalleri frekans tabanlı öznelilikler kullanıldığında ortalama %80 doğruluk oranı ile sınıflandırılabilmiştir [6].

#### **2.4. Erken Doğum Tespiti**

Erken doğum tespiti için amaç; hem doğum esnasında ve doğum sonrasında erken doğuma bağlı sorunların ve rahatsızlıkların ortadan kaldırılması ve doğum sonrası bebeğin ve annenin hastanede gereksiz kalmasının önlenmesi ve buna bağlı olarak kullanılan ilaç tedavisinin ortadan kaldırılarak daha sağlıklı bir doğumun gerçekleşmesini sağlamaktır [4]. Erken doğumun daha önceden kestirilememesi sonucu doğumu gerçekleştiren bir bebeğin

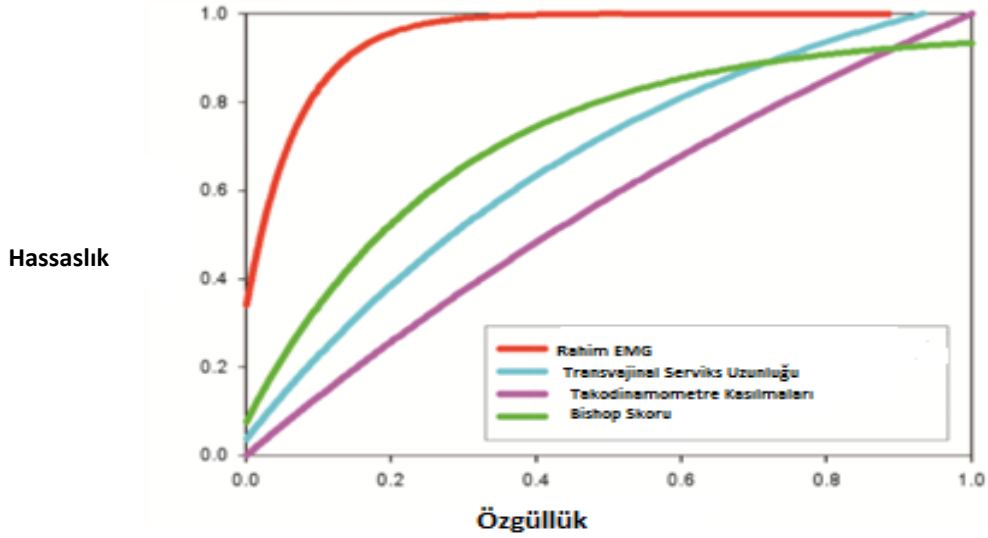


dolayısıyla annenin yukarıda belirtilen sağlık ve maddi problemlerle karşılaşması önlenemeyecektir. Bu gibi istenmeyen durumların oluşmasını önlemek için optimum seviyede erken doğumun kestirilmesi ve kestirim yapılırken hata oranının enaz olması hedeflenmelidir.

Erken doğumu tespit etmek için günümüze kadar birçok yöntem araştırılıp denenmiştir. Yaygın olarak kullanılan yöntemler; Takodinamometre cihazı, Transvajinal Serviks Uzunluğu, Bishop Skoru ve Elektromiyografi sinyalıdır. Takodinamometre cerrahi müdahale ile rahim duvarına yerleştirilir. Rahim yüzeyinde meydana gelen fiziksel değişiklikleri ölçer. Bu değişiklikler rahimdeki kasılmalar olarak yorumlanır [4]. Transvajinal Serviks uzunluğu ultrason yardımıyla ölçülebilir. Deneysel bir çalışma sonucunda bu uzunluk ile erken doğum riski arasında ters orantı bulunmaktadır. Bu uzunluk değeri kısaltıkça erken doğum yapma riski artmaktadır [8]. Diğer bir yöntem olan Bishop skoru birden fazla parametre kullanılarak hesaplanan bir değerdir. Leğen kemiğinin genişleme miktarı, rahim boyunun kısıalma oranı, yeri ve durumu değerlerinden hesaplanır. Bishop Skor değerine göre normal doğum veya erken doğum kestirimi yapılabilmektedir. Skor ne kadar yüksek ise normal doğum gerçekleşme olasılığı o kadar yüksek demektir [4]. Tüm bu yöntemler erken doğum tespiti için kullanılmış olan yöntemlerdir. Bir diğer yöntem ise rahim dış yüzeyindeki elektrotlar ile kaydedilen elektromiyogram (EMG) sinyallerini incelemektir. EMG sinyali cerrahi müdahaleye gerek duyulmadan rahmin dış yüzeyine yerleştirilen elektrotlar yardımıyla kayıt edilebilir. Bu yönüyle daha önceden uygulanan yöntemlere göre daha avantajlıdır. Erken doğum tespiti için rahim EMG yöntemi uygulanan diğer yöntemlere göre daha uygulanabilir ve daha güvenilir sonuç vermektedir [4].

Kas elektriksel sinyallerinin elektrotlar yardımıyla ölçen ve kayıt eden cihaza elektromiyografi kaydedilen sinyallere de elektromiyogram sinyalleri denir. Girişimsiz (non-invasive) olarak yani cerrahi müdahale olmadan yapılan rahim elektromiyogramı (uterus electromyogram), diğer bir adıyla elektrohistogram (EHG), rahimde meydana gelen kasılma hareketlerinden oluşan biyolojik sinyallerdir. Bu sinyaller erken doğumun kestirimi için önemli bilgi kaynağıdır.

Şekil 4' te dört farklı erken doğum kestirim metodunun ROC (Receiver Operating Characteristic) eğrileri verilmiştir. Bu şekilde anlaşılan rahim EMG yöntemi diğerlerine göre daha hassas ve bu nedenle daha güçlü bir kestirim metodu olduğu görülmektedir.



**Şekil 4.**ROC karakteristiklerinin karşılaştırılması[4]

Rahim EMG sinyallerini kaydetmek için elektrotlar rahim yüzeyindeki belirli noktalara yerleştirilir. Rahim bölgesinden hamileliğin farklı zamanlarında veya doğum anında EMG sinyalleri kaydedilir. EMG sinyalleri durağan veya periyodik sinyaller gibi değildir. Bu yüzden aynı haftaya ait farklı iki hamileden alınan sinyaller arasında gözle ayırt edilebilecek bir benzerlik bulunmaz. Hatta aynı kadının farklı zamanlardaki rahim EMG sinyallerini kolaylıkla belirlemek zordur. EMG sinyallerinin bu tür karmaşık özelliğinden dolayı, sinyalin doğrusal ve doğrusal olmayan özellikleri belirlenerek bu özellikler yardımıyla sinyallerin doğum, erken doğum ve hamilelik gibi sınıflara ayırt etmek mümkün olabilmektedir.

#### 2.4.1. Yapay Sinir Ağı Uygulamaları

Yapay sinir ağları daha önceki çalışmalarda farklı veri setlerine, farklı öznitelikler kullanılarak erken doğumun belirlenmesi için uygulanmıştır. Bu yöntem önce farelerin rahim EMG sinyalleri üzerinde erken doğumu belirlemek amacıyla kullanılmıştır ve yüksek performans elde edilmiştir [8],[16]. Dalgacık paket enerjisi özniteliği ve yapay sinir ağı kullanılarak erken doğum ile normal doğum sinyalleri %64,1 performans ile sınıflandırılmıştır [17]. Öznitelik seçimi sınıflandırma işleminde en önemli aşamadır. Sınıflandırma yaparken bu değerler kullanıldığı için doğru ve uygun parametrelerin seçiminin sınıflandırma performansı üzerinde büyük etkisi vardır. Öznitelikler zaman frekans veya istatistiksel tabanlı seçilebilmektedir. Frekans tabanlı seçilen özniteliklerden

erken doğum üzerinde en ayırt edici öznelik güç spektral yoğunluk fonksiyonunun tepe frekansdır [18].

Sinyali hem zamana hem de frekansa bağlı olarak analiz etmeye yarayan yöntem dalgacık paket dönüşümü özneliği kullanılarak yapay sinir ağı tasarlanmıştır. Hamilelik sinyalleri %96,3 doğum sinyalleri %71 doğruluk oranı ile sınırlandırılmıştır [19]. Doğum anında olduğu gibi normal hamilelik döneminde ve erken doğum zamanlarında rahim sinyallerinde kasılmalar meydana gelebilmektedir. Bu kasılmaların hangi zamana ait olduğunu belirleyebilmek erken doğumu kestirebilmenin bir başka yoludur. Yine yapay sinir ağı kullanılarak farklı dönemlere ait kasılmalar yüksek performans göstererek sınıflandırılmıştır [6].

Dalgacık Paket Dönüşümü öznelikleri de kullanılarak erken doğum kestirilmeye çalışılmıştır. Bu çalışmaya göre destek vektör makineleri kullanılarak uygulanan sınıflandırma sonucu yüksek performansta erken doğum kasılmaları tespit edilmiştir [20]. Erken doğum tespiti için makine öğrenmesi teknikleri sonucu elde edilen sonuçlar yaklaşık olarak klinik verilere uygulanmış ve ortalama %61 doğruluk oranını geçememiştir [21]. Düşük sonuçlar elde edilmesinin önemli sebeplerinden birisi erken doğum verisinin yeterli sayıda olmaması olarak açıklanmıştır [21]. Bir başka çalışmada danışsız (Unsupervised) sınıflandırma yöntemi diğeri ise AR modele dayalı K-en yakın komşuluk sınıflandırıcı yöntemi uygulanmıştır. Yapılan çalışmada AR model, filtre gibi işlev gördüğü için danışsız sınıflandırma yöntemine göre daha yüksek bir başarı elde edilmiştir [22].

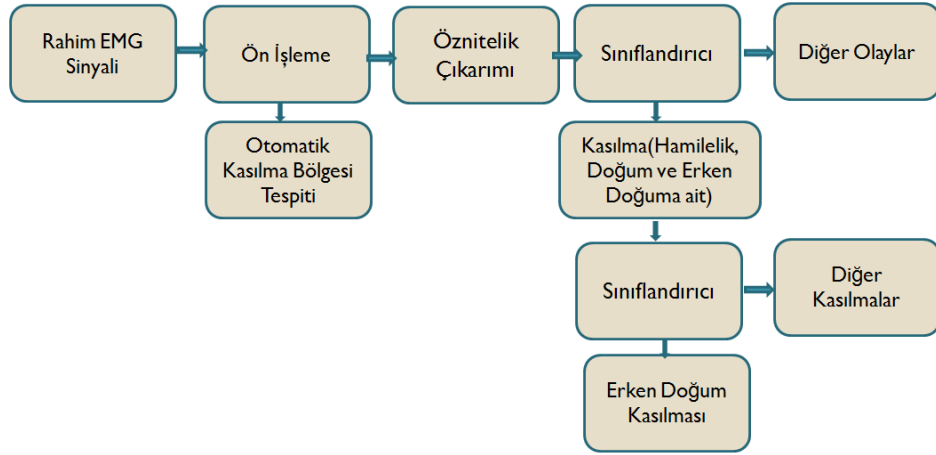
Yapay sinir ağına yönelik çeşitli çalışmalar Ampirik Mod Ayrışımı ile analiz edilmiş ve elde edilen sonuçlar ciddi oranda iyileştirilmiştir. Ampirik Mod Ayrışımı, Kısa Süreli Fourier ve Dalgacık Dönüşümü gibi özellikle durağan olmayan sinyalleri analiz etmeye yarayan bir yöntemdir. Erken doğum kestirimi için yapay sinir ağı yöntemlerinin sonuçlarının iyileştirilmesinde faydalı olduğu görülmüştür [16]. Kaynaklar incelendiğinde 2000’li yıllardan günümüze kadar erken doğum tespiti için rahim EHG sinyallerine birçok farklı yöntemin uygulandığı görülmektedir. Uygulanan yöntemler sonucunda; gerek veri setinin yeterince kapsamlı olmaması; farklı bölgelere ait çeşitli veri seti havuzunun oluşturulamaması, gerekse uygun doğrusal ve doğrusal olmayan özneliklerin seçilememesi veya uygun ve yüksek performanslı sınıflandırıcıların kullanılmaması nedeniyle hala erken doğum başarılı ve kesin olarak tespit edilememektedir.

Erken doğum problemine bir diğeri yaklaşım doğum sinyalleri ile hamilelik sinyallerini ayırt edebilmeye yöneliktir. Bu amaçla yapılan çalışmalar sonucu doğum

sinyallerinin başarılı olarak kestirilebilmesi yine bir doğum sinyali olan erken doğum sinyallerini belirlemede önemli bir yeri olduğu açıktır.

#### 2.4.2. Sınıflandırma Amaçlı Sinyal İşleme Sistematiği

Bu çalışmada erken doğum kestirimi amacıyla yapılan işlemlerin blok diyagramı Şekil 5'te verilmiştir. Veri setindeki sinyallere sinyal ön işleme yöntemleri uygulandıktan sonra blok diyagramında da verildiği gibi iki kanaldan birinde sinyal kayıt bilgilerinden faydalanılarak sinyal üzerinde meydana gelen olaylara ait öznitelikler çıkarılmıştır. Diğer yandan da bu bölgelerin otomatik olarak tespit edilmesine yönelik çalışmalar yapılmıştır. Bu amaçla 3 farklı algoritma uygulanarak; kasılma, bebek hareketlemesi gibi önemli olaylar otomatik olarak bölütlenmiştir. Her sinyale ait ön bilgi yer almadığı için bu algoritma sonuçları yalnızca kendi içinde karşılaştırılmıştır.



Şekil 5. Sinyal İşleme Blok Diyagramı

Ön bilgilere ait öznitelikler çıkartıldıktan sonra doğrusal ve doğrusal olmayan sınıflandırıcılar kullanılarak kasılma sınıfının da içinde bulunduğu rahimden kaynaklı (bebek hareketi, muhtemel kasılma ve kasılma) 3 farklı sınıfa ayrılmıştır. Bu aşamadan sonra veri setinde yer alan erken doğum ile sonuçlanan hamilelik kasılmaları, normal doğum ile sonuçlanan kasılmalar ve doğum anında meydana gelen kasılmalar olarak yine 3 sınıf olarak ele alınmıştır. İkinci kez sınıflandırma işleminde doğrusal olmayan sınıflandırıcılar kullanılarak erken doğum kasılması ve diğer kasılmalar ayrı olarak sınıflandırılmıştır. Bu gösterimin önemli adımlarından öznitelik belirleme bir sonraki bölümde ayrıntıları ile sunulmaktadır.

### 3. ÖZNETELİK BELİRLEME

Sinyal analizinde özniteliklerin belirlenmesi önemli bir aşamadır. Doğrusal olmayan ve belirli bir yapısı bulunmayan rahim EMG sinyallerini analiz ederken yapılması gereken öncelikle bu sinyalin karakteristiğini en iyi yansıtan özniteliklerin belirlenip ve çıkartılması gerekmektedir. Çünkü sinyalin kestirilmesi işleminde çıkarılan öznitelik değerleri kullanılır. Bu nedenle bu değerlerin uygun seçilmesi ve doğru hesaplanması sinyal sınıflandırmasında en önemli kısımlardan biridir. Çok sayıda öznitelik belirlemek sinyalin analizinde doğru tespitleri elde etmemize fayda sağlarken bir yandan da veri boyutu artışından kaynaklı iş gücü ve karmaşıklık problemlerini beraberinde getirir. Bu nedenle sinyal analizinde en iyi performansı gösteren özniteliklerin belirlenmesi ve kullanılması gerekmektedir. Bu çalışmada, öznitelikler seçilirken ilgili alanda çalışmalar yapılırken kullanılan özniteliklerin sınıflandırma performansına olumlu yönde etkileyen özniteliklerden seçilmesine özen gösterilmiştir.

#### 3.1. İlgili Çalışmalarda Kullanılan Öznitelikler

Erken doğum problemini belirleyebilmek için kullanılan veri seti ve uygulanan yöntem kadar seçilen öznitelikler ve sayısı da önemlidir. Hangi parametrelerin sınıflandırma yaparken daha verimli sonuç vereceği konusunda pek çok çalışma yapılmıştır. Öznitelik seçiminde kullanılan veri seti, kullanılan sınıflandırıcı gibi değişkenler uygun özniteliklerin seçiminde etkilidir. Bu konu ile ilgili çalışmalar bize amaç doğrultusunda yol gösterici olurken erken doğum tespiti için kesin bir sonuç verememektedir. Çünkü çalışmalar karşılaştırıldığında veri seti ya da sınıflandırıcı değiştirildiğinde elde edilen sonuç ve gözlem de değişmektedir. Bu konuda geniş kapsamlı bir veri seti üzerinde çalışarak değişkenlerin (sınıflandırıcı yöntemi, öznitelik) problem çözümü üzerindeki etkisi daha sağlıklı gözlemlenebilir.

Biyolojik sinyaller analiz edilirken seçilen parametreler zaman, frekans tabanlı doğrusal veya doğrusal olmayanlardan seçilebilmektedir. Sınıflandırma için seçilen doğrusal ve doğrusal olmayan öznitelikler arasında erken doğum ve normal doğum kasılmalarının ayırt edilmesinde en belirleyici parametreler seçildiğinde performans artacaktır. Kaynak çalışmalarında görülen doğrusal ve doğrusal olmayan öznitelikler arasından medyan frekansı ve örnek entropisi erken doğumun kestiriminde en etkili parametreler arasında

olduğudur [24],[23],[24]. Yapılan bazı çalışmalar doğrusal olmayan parametrelerin erken doğum kestiriminde daha iyi sonuç verdiğini göstermektedir [25].

Tüm rahim EMG sinyalinden çıkartılan parametreler ve farklı frekans bantlarına ait olan parametreler hamilelik ve doğum sinyallerini ayırt etmek için kullanılmıştır [31],[26]. Tüm frekans bandına ait parametreler arasında ortalama güç frekansı (mpf) parametresi söz konusu sinyalleri ayırt etmede en önemli etkene sahiptir. Farklı frekans bantlarına ait parametreler değerlendirilirken paketler (D1...D9), ortalama güç frekansı gibi parametreler sınıflandırma işleminde kullanılabilir ve erken doğum sinyallerini belirleyici öneme sahiptirler.

Rahim EMG sinyalinin gücü, ortalama güç frekansı, spektral güç yoğunluğunun %95' ini kapsayan limit frekansı ve sinyalin spektral değişimi gibi parametre değerleri için genel olarak hamilelik döneminde ve doğum anında ölçülen değerler karşılaştırıldığında hamilelik döneminde bu parametrelerin daha düşük olduğu daha önce yapılan çalışmalarda gözlemlenmiştir [27].

Öznitelikler belirlenirken temelde dikkat edilen doğrusal ve doğrusal olmayan öznitelik seçimidir. Durağan olmayan EMG sinyalleri analiz edilirken doğrusal olmayan özniteliklerin seçimi yapılan çalışmanın performansını etkileyebilmektedir. Bu nedenle öznitelikler doğrusal ve doğrusal olmayan olmak üzere iki sınıfa ayırmak bu etkenin sonuçlar üzerindeki etkisini incelememizde etkili olacaktır.

Doğrusal olmayan özniteliklerin kestirim performansı daha yüksek olmasına rağmen bu çalışmada doğrusal öznitelikler de kullanılmıştır [25].

Öznitelik çıkarımı aşaması dahilinde doğrusal ve doğrusal olmayan olmak üzere 11 adet öznitelik çıkarılmıştır.

### **3.1.1. Doğrusal Öznitelikler**

Öznitelikler sinyalin frekans veya genliğine dayalı parametrelerden elde edilmiştir. Sinyalin Güç Spektral Yoğunluğu, zaman-frekans gösterimi (wavelet dönüşümü) öznitelik çıkarımı için kullanılmıştır.

Ortalama Frekans, Güç Spektral Yoğunluğun Tepe Frekansı, Güç Spektral Yoğunluğun Tepe Genliği, Medyan Frekansı, Karelerin Ortalamasının Karekökü (RMS), Dalgacık Dönüşüm Paketleri, (D1...D9) Sinyalin Gücü, Kasılma (Burst) Süresi, Ortalama

Güç Frekansı, Dalgacık Dönüşümü Analizi, Hızlı Fourier Dönüşümünün Genliğinin Karesi, Sıfırdan Geçiş Oranı (Zero-Crossing), Kesikli Zaman Kosinüs Dönüşümü, öznitelikleri rahim EMG sinyallerinin analizinde kullanılmıştır.

Frekansa dayalı parametrelerden; Güç Spektral Yoğunluğun Tepe Frekansı, Medyan Frekansı, Karelerin Ortalama Karekökü (RMS), Güç Spektral Yoğunluğun Tepe Genliği ve kasılma süresi doğum sinyallerini belirlemede kullanılmıştır. Bu sinyalleri hamilelik dönemindeki sinyallerden ayırt etmede Spektral Yoğunluğun Tepe Frekansı en önemli etkene sahiptir [18].

Frekans analizi ile ilgili öznitelikler kullanılarak rahim EMG sinyalleri analiz edilmiştir. Farklı frekans bantları kullanılarak çıkarılan öznitelik değerlerinin hamilelik döneminden doğum zamanına kadar artış gösterdiği gözlemlenmiştir [27],[28]. Frekansa dayalı bir parametre olan ortalama frekansı tanımlamak için; öncelikle Güç Spektral Yoğunluk fonksiyonunu tanımlamak gerekir. Güç Spektral Yoğunluk (GSY) fonksiyonu, sinyalin gücünü frekansın fonksiyonu olarak gösterir [29]. Yani frekans bölgesinde gücün dağılımıdır. Bu yoğunluğun belirlenmesinde çeşitli yöntemler geliştirilmiştir. GSY fonksiyonu sinyalin frekans bölgesindeki özelliklerini içeren (genlik, güç, yoğunluk, faz) ve bu özellikler sinyalin karakteristiği hakkında çok önemli bilgiler içerdiği için sinyal işlemede incelenmesi gereken önemli bir fonksiyondur. Bu fonksiyonun belirlenmesinde temelde üç farklı yaklaşım bulunmaktadır.

**Parametrik Olmayan Yöntemler:** Bu yöntem sinyal hakkında bir ön bilgi içermeden direk Kesikli Fourier Dönüşümünü kullanarak GSY fonksiyonunun kestirimini yapar. Ön bilgi kullanılmadığı için herhangi bir tipte sinyalin GSY fonksiyonu kestirimi için kullanılabilir. Periodogram, geliştirilmiş periodogram, Welch ve multitaper parametrik olmayan yöntemlerdir. Denklem (1) de Periodogram kestiriminin matematiksel gösterimi verilmiştir [30].

$$P_{xx}(w) = \lim_{m \rightarrow \infty} E \left\{ \frac{1}{2m+1} \left| \sum_{n=-m}^m x(n) e^{-jwn} \right|^2 \right\} \quad (1)$$

Geliştirilmiş periodogram kestirimi Kesikli Fourier Dönüşümü uygulamadan önce zaman bölgesinde uygun bir pencere fonksiyonu ile çarpılır.

Welch yöntemi için önce zaman bölgesinde bölütleme yapılır, her bir bölüt için geliştirilmiş periodogram uygulanır. Tüm zaman serileri için elde edilen kestirim değerlerinin ortalaması alınarak GSY fonksiyonu kestirilir.

**Parametrik Yöntemler:** Bu yöntem sinyalin GSY fonksiyonunu kestirmek yerine sistemi doğrusal bir sistem gibi modelleyip, sistemin katsayılarını kestirmeyi hedefler (Yule-Walker AR Yöntem ve Burg Yöntem) [30].

Rahim EMG sinyallerinin Güç Spektral Yoğunluk analizinde çeşitli kestirim yöntemleri mevcuttur. GSY fonksiyonun kestiriminde Periodogram ve Welch yöntemleri iyi performans gösteren iki kestirim yöntemidir [31].

GYS fonksiyonu kullanılarak aşağıdaki öznitelikler çıkartılmıştır.

**a) Ortalama Frekans:** GSY fonksiyonun her bir frekansa ait değeri ile frekansların çarpımların toplamının, tüm frekans değerlerine karşılık gelen değerlerin toplamına oranı ortalama frekansı verir. Matematiksel denklem (2) de verilmiştir [32].

$$f_{mean} = \frac{\sum_{i=1}^n f_i \cdot P_i}{\sum_{i=1}^n P_i} \quad (2)$$

Bu eşitlikte  $n$  sinyalin uzunluğu  $f_i$  güç yoğunluk fonksiyondaki  $i$ . bins'deki frekans değeri,  $P$  GSY fonksiyonudur.

**b) Medyan Frekansı:** GYS fonksiyonunun medyan frekansının üst frekans değerlerinin toplamı ile altında kalan değerlerinin toplamı birbirine eşittir. Denlem (3.1) ve (3.2) deki gibi ifade edilir [32].

$$\sum_{i=1}^{i_m} P(i) = \sum_{i=i_m}^n P(i) \quad (3.1)$$

$$f_{medyan} = i_m \frac{f_s}{n} \quad (3.2)$$

$f_s$ : Örnekleme frekansı

$P$ : GYS fonksiyonu  $f_{medyan}$ : Hertz cinsinden medyan frekansı

**c) Güç Spektral Yoğunluk Fonksiyonunun Tepe Frekansı:** Güç yoğunluk Fonksiyonunun maksimum olduğu noktadaki frekans değeridir [32],[15]. Denklem (4) te tepe frekansı matematiksel olarak verilmiştir.

$$f_{peak} = \frac{f_s}{n} \max(P(i))_{i=1}^n \quad (4)$$

$f_s$ : örnekleme frekansı,  $n$ : sinyalin uzunluğu,  $f_{peak}$ : Hertz cinsinden tepe frekans değeri



**d) Güç Spektral Yoğunluk Fonksiyonunun Tepe Genliği:** Güç yoğunluk fonksiyonunun maksimum olduğu noktadaki genlik değeridir [25]. Denklem (5) de verildiği gibi tepe genlik değeri belirlenebilir.

$$A = \max(P(i))_{i=1}^n \quad (5)$$

**e) Karelerin Ortalamasının Karekökü**

Tüm örneklerin genlik değerlerinin karelerinin toplamının kareköküdür [25]. Karelerin ortalama karekökü denklemi denklem (6) da verilmiştir.

$$rms = \sqrt{\frac{1}{n} \sum_{i=1}^n x(i)^2} \quad (6)$$

**f) Ortalama Güç Frekansı:** Güç Spektral Yoğunluk fonksiyonunun değerlerinin ortalamasına karşılık gelen frekans değeri ortalama güç frekansını verir [25].

### 3.1.2. Doğrusal Olmayan Öznitelikler

Rahim EMG sinyallerinin analizinde doğrusal özniteliklerin yanı sıra doğrusal olmayan öznitelikler de kullanılmıştır. Bu parametrelerin her biri ayrı incelenmiş ve genel olarak maksimum performansı veren parametreleri belirlemeye yönelik çalışmalar yapılmıştır.

Bu çalışmalardan birisinde doğrusal veya doğrusal olmayan parametrelerin kullanılmasının rahim EMG sinyalinin sınıflandırılmasındaki etkisi incelenmiştir. EMG sinyali, durağan olmayan yapıya sahip olduğundan dolayı sınıflandırma yapılırken kullanılan doğrusal olmayan parametreler doğrusal olanlara göre daha başarılı sonuçlar vermektedir [25]. Bu öznitelikler; zamanda değişmezlik, Lyapunov üsteli, örnek entropi, yaklaşık entropi, ilinti (korelasyon) boyutudur.

Doğrusal olmayan yapıya sahip rahim EMG sinyalleri çözümlenirken işlem yükü, zamandan tasarruf başka diğer dezavantajlar göz önünde bulundurulmalıdır. Bazı durumlarda sinyal elde edilirken saatlerce kayıt alınmaktadır. Bu sinyallerin işlenmesinde düşük örnekleme frekansı işlem yükünü azaltabilir. Aynı zamanda da asıl amacımız olan erken doğumun hızla belirlenmesi yolunda bir dezavantaja dönüşebilir. Diab ve grubu bu problemle ilgili bir çalışma yapmıştır. Bu çalışmada 200 Hz olan normal örnekleme frekansını 20 Hz olarak düşürmüş ve bu değişimin dört farklı doğrusal olmayan öznitelikler üzerindeki etkisini araştırmıştır. Kullanılan öznitelikler; zamanda

terslenebilirlik (TR), örnek entropisi (SE), Lyapunov üsteli (LE), gecikmeli vektör varyansdır (Delay Vector Varyans, DVV). Örenkleme frekansı değişiminin yöntemlerin performansına etkisi ROC (Receiver Operating Characteristic) eğrilerine bakılarak incelenmiştir. Zamanda terslenebilirlik ve Lyapunov parametreleri etkilenmemiştir. Örnek entropisi olumlu olarak frekans düşüşünden etkilenmiştir. Bu çalışmada kayıt sırasındaki örnekleme frekansı üzerinden tekrar örnekleme işlemi yapılmamıştır.

**a) Örnek Entropisi:** Örnek entropi EMG sinyalleri gibi dinamik zaman serilerindeki karmaşıklığın veya düzensizliğin incelenmesinde kullanılan yaygın bir parametredir [25],[10]. Matematiksel olarak denklem (7) de ifade edilmiştir.

$$SampEn = -\log \frac{A}{B} \quad (7)$$

$A : d|x_{m+1}(i), x_{m+1}(j)| < r; \quad r; \text{tolerans değeri, } m \text{ gömme boyutu}$

$B : d|x_m(i), x_m(j)| < r; \quad r; \text{tolerans değeri, } m \text{ gömme boyutu}$

Veri uzunluğu çok büyük olan örneklerde tolerans değeri  $0,2x\text{standart sapma}$  olarak alınır [33],[34]. Gömme boyutu entropi hesabında kullanılan verinin uzunluğu yani kesikli uzayda pencere boyutudur.

Sinyalin örnek entropi değerinin küçük olması bu sinyaldeki düzensizliğin, karmaşıklığın ya da gürültünün az olduğu bilgisini verir. Örnek entropisi durağan olmayan sinyallerin analizinde kullanılan önemli bir özniteliktir [25],[21],[35],[36].

Bu öznitelik değeri hamilelikten doğum zamanına kadar geçen süre boyunca dalgacık yöntemi kullanılarak incelenmiştir. Dalgacık dönüşümü biyolojik sinyallerin çözümlemesinde başarılı sonuçlar veren bir yöntemdir. Rahim EMG sinyallerinde meydana gelen kasılmaları sınıflandırabilmek için kullanılan dalgacık dönüşümü sonucu hamilelik ve doğum kasılmaları arasında ayırt edici değerlerin elde edildiği görülmüştür [46]. İncelemeler sonucunda örnek entropisinin doğum zamanında hamileliğe göre zamanla arttığı görülmüştür [47],[37].

**b) Zamanda terslenebilirlik:** Sinyalin istatistiksel özellikleri zamanla değişmiyor ise verinin zamanda terslenebilir özelliği vardır. Denklem (8)'de zamanda terslenebilirlik matematiksel olarak ifade edilmiştir.  $x_i$  ve  $x_{i-\tau}$  sırasıyla  $x$  sinyalinin  $i$ . noktadaki değeri ve zaman gecikmesinden sonraki değeridir.

$$Tr(\tau) = \frac{1}{n-\tau} \sum_{i=\tau+1}^n (x_i - x_{i-\tau})^3 \quad (8)$$

$n$ ; sinyalin uzunluğu,  $\tau$ ; zaman gecikmesi

Zamanda terslenebilirlik durağan olmayan sinyallerin (uterine EMG, EEG gibi ) analizi ve sınıflandırılmasında kullanılan en önemli yöntemlerden biridir [38]. Bu parametre erken doğum kestirimi için kullanıldığında yüksek performans sonucu elde edilmiştir [39]. Rahim sinyallerinin zamanda değişmezlik özelliği hamilelik kayıtlarında varken doğum sinyallerinde bu özelliğin olmadığı doğrusal olmayan parametrelerin analizinde tespit edilmiştir [40].

**c) Lyapunov Üsteli:** Durağan olmayan bir zaman dizisinde, zaman içinde birbirine yakın noktalar bir üstel değere göre yakınlaşıp uzaklaşması söz konusudur. Bu yakınlaşma veya uzaklaşmayı tanımlayan parametre Lyapunov üsteli olarak adlandırılır. Lyapunov üsteli ve buna bağlı değişkenler denklem (9) ve (10) da verilmiştir.

$$\lambda = \frac{1}{t_N - t_0} \log_2 \frac{d(t_k)}{d(t_{k-1})}, \quad (9)$$

$$d(t) = d_0 e^{\lambda t} \quad (10)$$

$d_0$ : noktalar arasındaki uzaklık,

Maksimum Lyapunov üsteli sinyalin karmaşıklığını ölçer [41].

Doğrusal olan ve olmayan öznitelikler arasında doğum zamanını tespit etmede en önemli etkene, ayırt edici özelliğe sahip öznitelikler; doğrusal özniteliklerden medyan frekansı ile doğrusal olmayanlardan örnek entropisidir [24].

Rahim EMG sinyalinde örnek entropisinin, Dalgacık Paket Dönüşümü yöntemi kullanılarak hamilelik boyunca nasıl değiştiği incelenmiştir. Hamilelik boyunca yavaş yavaş azaldığı görülen örnek entropisi ve Lyapunov üsteli rahim EMG sinyallerinin analizinde kullanıldığında başarılı sonuç veren doğrusal olmayan parametrelerdendir [42],[43].

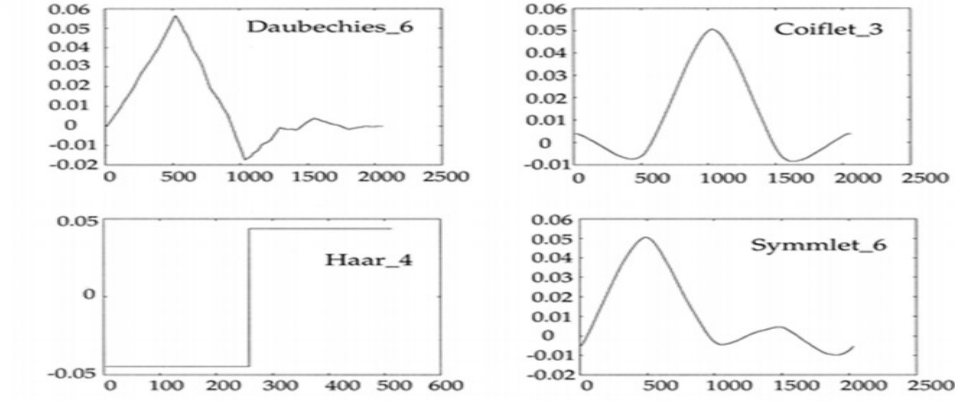
### 3.2. Dalgacık Dönüşümü (Wavelet) Analizi

Biyolojik sinyaller analiz edilirken sadece zaman veya frekans bölgesinde analiz yapmak bizi optimum sonuçtan uzaklaştırır. Rahim EMG sinyalleri incelenirken dalgacık dönüşüm yönteminin kullanılması hem frekans hem zaman bölgesinde analiz edildiği için

çok daha sağlıklı sonuçlar verdiği yapılan literatür araştırmasında anlaşılmıştır. Bu durum biyolojik sinyallerin durağan olmayan yapısından kaynaklanmaktadır.


### 3.2.1. Dalgacık Dönüşümü

Sinyal işleme alanında frekans bölgesi analizi için yaygın yöntem olarak kullanılan Fourier dönüşümünde zaman bilgisi kaybolmaktadır. Dalgacık Dönüşümü bu dezavantajı ortadan kaldırarak zaman bilgisini korur. Durağan olmayan sinyallerin analizinde de kullanılan Dalgacık analizi bu tip sinyallerde Fourier analizine göre daha avantajlı sonuçlar vermektedir. Dalgacık dönüşümünde kullanılan sonsuz Dalgacık fonksiyonu vardır. Dönüşüm için öncelikle Dalgacık fonksiyonuna karar vermek gerekmektedir. Şekil 6'da başlıca kullanılan Dalgacık Dönüşüm fonksiyonları yer almaktadır. Bu temel fonksiyonlar sıkıştırma, germe, yumuşatma (smoothing), gürültü azaltma gibi amaçlar için kullanılır.



Şekil 6. Dalgacık Dönüşümü Fonksiyonları [44]

Fourier Dönüşümde olduğu gibi Dalgacık fonksiyonu ile sinyalin iç çarpımı sinyalin Dalgacık Dönüşümünü verir. Bu dönüşümün temel amacı sinyalin zamanda kayan Dalgacık fonksiyonununun sıkıştırılmış veya gerilmiş halini inceleyebilmektir. Bunun için sıkıştırma veya germe işlemi için bir katsayı (scale, ölçek) belirlemek gerekmektedir. Şekil 7 'de farklı katsayı değerlerine göre sinüs sinyali gösterilmiştir.



Şekil 7. a) Ölçek =1 b) Ölçek =2 c) Ölçek= 4 [44]

Dalgacık Dönüşümü, düşük frekanslı bölgeler için geniş pencere yüksek frekanslı bölgeler için dar pencere boyutlarına sahiptir. Böylece bütün frekans bölgelerinde Fourier analizine

göre daha faydalı bir zaman frekans çözünürlüğüne sahiptir. Ayrıca Dalgacık analiz yöntemi diğer zaman-frekans tabanlı analiz yöntemlerine göre daha hızlı çalıştığı görülmüştür. Biyolojik işaretlerin yani durağan olmayan sinyallerin analizinde Fourier analizinden faydalanılsa da Dalgacık dönüşümü daha yararlı sonuçlar vermektedir.

Dalgacık dönüşümü işaret işlemede sinyali frekans aralıklarına bölerek bu aralıklarda ayrı ayrı analiz yapılarak sinyalin karakteristiği hakkında bilgi edinmeyi sağlar. Bu frekans bantlarına ayırma nedeniyle durağan olmayan sinyalleri incelemede avantajlı olduğu görülmektedir. Bu dönüşüm işlemi sürekli zaman ve ayrık zamanda yapmak mümkündür.

### 3.2.2. Sürekli Zaman Dalgacık Dönüşümü

Bu dönüşüm belirlenen özel dalgacık fonksiyonu  $\psi$  ile, sinyalin ağırlıklandırılarak, zamanda kaydırılıp çarpımlarının toplanması demektir. Sürekli zaman dalgacık dönüşümü matematiksel olarak denklem (13) de verilmiştir.

$$CWT(a, b) = \int x(t)\psi_{a,b}^*(t) dt \quad (13)$$

a ölçek, b kaydırılan zamanı ifade etmektedir ve bu parametrelere göre dalgacık fonksiyonunu denklem (14) de verilmiştir.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right) \quad (14)$$

### Süzgeç Blokları


Dalgacık dönüşümünde temel olarak sinyale iki tane alçak ve yüksek geçiren filtre (birbirini tümleyen) uygulanır. Dalgacık Dönüşümünde uygulanan ana fonksiyon denklemi denklem (15) de verilmiştir.

$$\psi_{j,k}(t) = 2^{-j/2}\psi(2^{-j}t - k) \quad (15)$$

Temel fonksiyonu bu olan Dalgacık Dönüşümü ile sinyal alt ve üst bileşenlerine ayrılır.

Bu işlem istenilen frekans aralığı elde edilene kadar veya işaret üzerinde belirli bölgelerin tespitine kadar uygulanmaya devam edilir.


Şekil 8'de verilen sinyal 3. Seviyeden yaklaşım ve ayrıştırma katsayılarına yani alt ve üst frekans bileşenlerine ayrılmıştır.




**Şekil 8.** Dalgacık Dönüşümü  $H_0$ :Yüksek Geçirgen, $G_0$ :Alçak Geçirgen [44]

Bu algoritma Mallat algoritması (Hızlı Dalgacık Dönüşümü) olarak bilinir. İncelenmek istenen seviyeye kadar ayrışım yapılır, bu dönüşüm sonucu alçak geçirgen filtre katsayıları; yaklaşım ( $c[n]$ ), benzer şekilde yüksek geçirgen katsayıları; ayrışım ( $d[n]$ ) katsayıları olarak tanımlanır.

Dalgacık dönüşümünün temelinde sinyali yüksek ve düşük frekanslı bileşenlerine ayırarak analiz etmek yer almaktadır. Aşağıdaki verilen şekilde  $x$  sinyali 3'üncü seviyede alt ve üst frekans bileşenlerine ayrılmıştır. Kesikli dalgacık dönüşümü sadece alçak geçirgen filtrelere uygulanmaktadır. Bu dönüşüm her iki filtre sonucuna da uygulandığında elde edilen dönüşüm dalgacık paket dönüşümü adını almaktadır. Dalgacık dönüşümünde alçak geçirgen filtre çıkışına tekrar dönüşüm yapılarak alt ve üst frekans sinyallerine ayrılırken paket dönüşümünde ise yaklaşım ve ayrışım çıktılarının her ikisine de dönüşüm uygulanır. Şekil 9 ve Şekil 10' da verilen şekillerde Dalgacık Dönüşümü ve Dalgacık Paket Dönüşümü gösterilmiştir.



Şekil 9. Dalgacık Dönüşümü[1]




Şekil 10. DalgacıkPaket Dönüşümü[1]

### 3.3. Boyut İndirgeme

Sınıflandırma problemlerinde öznitelikler önemli bir yere sahiptir. Özniteliklerin doğru olarak hesaplanmasının öneminin yanında hangilerinin kullanılacağı da bir başka problemdir. Çünkü sınıflandırma işlemi seçilen bu öznitelikler kullanılarak yapılır.

Yüksek boyutlu veri örneklerinin kullanılması hem hesaplama maliyeti hem de daha az önemsiz denilebilen gürültü öznitelikleri sınıflandırmanın performansını olumsuz etkileyebilir. Çok boyutluluğun laneti olarak bilinen bu problemin çözümünde öznitelik çıkarımı ve seçimi yöntemlerinden oluşan boyut indirgeme yöntemleri geliştirilmiştir. PCA (Principle Component Analysis) ve FDA (Fischer Discriminant Analysis) bu yöntemler arasında yer alır. Şekil 11' de farklı sayıda veri boyutuna ait verinin grafiksel gösterimi yer almaktadır.



Şekil 11. Farklı veri boyutuna ait grafiksel gösterim [45]

Boyut sayısı arttıkça öznitelik dağılımının merkezi varyansı artmaktadır. Daha az belirleyici özelliğe sahip öznitelikler, öznitelik vektörünün uzaydaki dağılımının odağını beklenmeyen veya önemsiz bölgelere doğru çekmektedir. Bu da yanlış veya kötü performanslı sınıflandırma sonuçları almanın bir nedeni olabilir.


Öznitelik boyutunun sınıf sayısından daha büyük olan veri setlerinde en önemli öznitelikler belirlenip bu öznitelikler kullanılabilir.

#### 3.3.1. FDA(Fischer Discriminant Analysis)

Doğrusal olarak sınıflandırma yapabilmenin de mümkün olduğu boyut indirgeme yöntemi ile en önemli boyutlara göre kestirim yapıldığı için doğruluk performansı artmaktadır.



Şekil 12'de verilen örneklerde sınıflandırıcı yüzeyleri farklı iki doğru bulunmaktadır. Sol tarafta yanlış sınıflandırılmış veriler mevcutken sağ taraftaki karar sınır yüzeyleri ile tüm veriler hatasız sınıflandırılmıştır.



**Şekil 12.** İki boyutlu üç farklı sınıf için farklı karar sınırları [45]

Fisher yöntemi ile boyut indirgeme için  $x$  veri setininin bir düzlem üzerine iz düşümü alınır. Denklem (16) ile verilen iz düşümü çalışması yapılır.

$$y = w^T x \quad (16)$$

Bu izdüşüm bölgesine düşen  $x'$  verilerine eşikleme yöntemi uygulanarak uygun sınıflara atanır. İz düşüm alınırken dikkat edilmesi gereken kural izdüşüm doğrusunda verilerin üst üste gelmesini engellemektir. Veri çakışmasını önlemek için uygun  $w$  değerini bulmak için her bir verinin kendi içinde ortalamaları belirlenir. Denklem (17) de kendi içindeki ortalamaları verilmiştir.


$$m_1 = \frac{1}{N_1} \sum_{n \in C_1} x_n, m_2 = \frac{1}{N_2} \sum_{n \in C_2} x_n \quad (17)$$

İz düşüm üzerindeki verilen ortalamaları her bir sınıf için sırasıyla  $m_1'$  ve  $m_2'$  olsun. Denklem (18) de ortalamaların farkının izdüşümleri yer almaktadır.

$$m_1' - m_2' = w^T (m_1 - m_2) \quad (18)$$

Çakışmayı minimum seviyede tutmak amacıyla ortalamaların izdüşümleri arasındaki uzaklığın artırılması gerekir. Yani temel amaç farklı sınıflardan gelen verilerin izdüşümlerinin ayrık olacağı yani çakışmanın minimum olacağı doğruyu belirlemektir.

Şekil 13'te sol tarafta izdüşümler arasında çakışma mevcuttur. Sağ tarafta ise çakışmanın minimum olduğu görülmektedir.



Şekil 13. Farklı doğrular üzerine alınan iz düşümler [45]

Görsel olarak verilen örnekten de anlaşıldığı gibi iz düşüm doğrusunu iz düşümü alınan her iki verinin de varyansının küçük olduğu yöne paralel seçildiği zaman çakışma minimumdur.

Fischer yöntemi ile iz düşümü alınan verilerin ortalamaları arası uzaklığın maksimum olması ve bu uzaklığın aynı anda izdüşümü alınan her sınıfın kendi içindeki varyansına orantılı olarak da maksimum olması istenmektedir.

İz düşümü alınan verinin varyansı denklem (19) daki gibi hesaplanır.

$$S_k'^2 = \sum_{n \in C_k} (y_n - m_k')^2 \quad (19)$$

$$y_n = w^T x_n \quad (20)$$

Fischer yöntemi her sınıfın kendi arasındaki varyansın, sınıfların kendi içindeki varyansların toplamının oranına bağlı olarak maksimum yapacak iz düşüm doğrusunun bulunmasını amaçlar. Denklem (21) de verilen matematiksel ifadede J' yi maksimum yapan w' nin bulunması Fischer yönteminin temel amacıdır.

$$J(w) = \frac{(m_1' - m_2')^2}{S_1'^2 + S_2'^2} \quad (21)$$

Varyansların iz düşümü yani  $S_k'^2$  'yi normal verinin varyansı  $S_k$  cinsinden yazmak için toplam sembolünün içindeki ifade açılıp denklem (22) elde edilir.

$$S_k'^2 = \sum_{n \in C_k} (w^T x_{kn} - w^T m_k)^2 = \sum_{n \in C_k} w^T (x_{kn} - m_k)(x_{kn} - m_k)^T w = w^T S_k w \quad (22)$$

$$S_c'^2 + S_k'^2 = w^T (S_c + S_k) w \quad (23)$$

$S_c + S_k$  her sınıfın kendi içindeki varyansı  $S_w$  olsun.

$$(m_c' - m_k')^2 = w^T (m_c - m_k)(m_c - m_k)^T w \quad (24)$$

$= w^T S_B w S_B$ : sınıflar arasındaki varyans

$$J(w) = \frac{w^T S_B w}{w^T S_w w} \quad (25)$$

J'yi maksimum yapan w yı bulmak için bu değişkene göre türevini bulup sıfıra eşitlenirse denklem (26) ve (27)'de elde edilir.

$$\frac{\partial J}{\partial w} = 0 \quad (26)$$

$$S_B \vec{w} - \alpha S_w \vec{w} = 0, \quad S_B \vec{w} = \alpha S_w \vec{w} \quad (27)$$

Bu eşitliği sağlayan w değerlerinin bulunması bilinen birim değer (eigenvalue) probleminin çözümüdür.

$S_w^{-1} S_B \vec{w}$ ' nin en büyük öz vektörleri, özniteliklerin en büyük öz değerlerine karşılık gelmektedir [46].

Doğrusal olarak sınıflandırma için de kullanılabilen Fischer yöntemi ile öznitelikler istenilen boyuta indirgenir. Özniteliklerin indirilmesi istenen boyut r olsun. Bu vektörlerin en büyük ilk r tane öz birim değerleri indirgenmiş öznitelik değerlerini verir [47],[46].

## 4. SINIFLANDIRMA YÖNTEMLERİ


### 4.1. En Yakın Uzaklık Sınıflandırıcı

Bu sınıflandırıcı kullanımı ve uygulaması basit olan bir sınıflandırıcı çeşididir. Eğitici setinden her sınıfa ait ortalama öznelik değerleri belirlenir. Test için belirlenen verilerden her biri, ortalaması hesaplanan her sınıfın özneliklerine uzaklığı hesaplanır. Uzaklık ölçümü için farklı yöntemler kullanılabilir. Öklid uzaklık, Mahalanobis ve Manhattan uzaklık bunlardan sıkça kullanılanlardandır. Uzaklık olarak hangi sınıfa daha yakın ise test edilen veri örneği o sınıfa atanır. Denklem (28) de her bir ağırlık vektörüne uzaklık hesabı denklemi verilmiştir.

$x$  Test girdisi olsun.  $m_1, m_2, \dots, m_k$  k tane farklı sınıfa ait öznelikler olsun.

$$d = \|x - m_i\|, \quad 0 < i \leq c \quad (28)$$

Her sınıfa olan uzaklık hesaplanır ve  $x$  en yakın uzaklık elde edilen sınıfa aittir [48]. Şekil 14' te verilen grafikte de görüldüğü gibi en yakın uzaklık sınıflandırıcı algoritmasında her sınıfın ortalama vektörüne olan uzaklıklar tek tek hesaplanır.



Şekil 14. En Yakın Uzaklık Sınıflandırıcı

Bu sınıflandırıcıda genel olarak amaç veriye en yakın sınıfı, uzaklık parametrelerine göre belirleyip ve veriyi en yakın olan bu sınıfa atamaktır. Sınıfa ait ağırlıklara olan uzaklığı minimize etmek gerekir. Uzaklığı minimize etmek için karesi alınır. (29) ve (31) denklemleri arasında en yakın uzaklık sınıflandırıcı denklemi elde edilir.

$$d = \|x - m_i\| = \|x - m_i\|^2 \quad (29)$$

Vektör olduğu için devriği ile ifadenin çarpımı karesini verecektir.

$$\|x - m_i\|^2 = (x - m_i)^T (x - m_i) \quad (30)$$

$$= x^T x - 2x^T m_i + m_i^T m_i \quad (31)$$

$-2x^T m_i + m_i^T m_i$  ifadesini minimize etmek  $x^T m_i - \frac{1}{2} m_i^T m_i$  'yi maksimize etmek demektir [47].

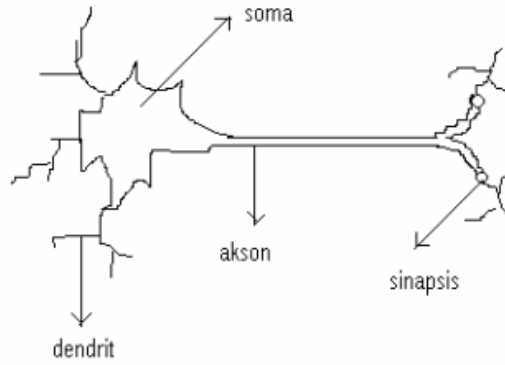
$$g(x) = x^T m_i - \frac{1}{2} m_i^T m_i \quad (32)$$

Bu sonuca göre eğitim setinde bulunan sınıflara ait verilerin ortalaması alınarak ağırlıklar belirlenir. Test setindeki her verinin bu ağırlıklara uzaklığı denklem 32' ye göre hesaplanır ve maksimum değerin sınıfına atanır.

## 4.2. Yapay Sinir Ağları

Rahim EMG sinyallerinin sınıflandırılmasında doğrusal olmayan sınıflandırıcılar kullanılırsa yüksek performansta sonuçlar elde edilir [28]. Bu çalışmada kullanılan doğrusal olmayan sınıflandırıcı yapay sinir ağlarıdır.

Biyolojik sistemleri matematiksel olarak temsil eden yapıya yapay sinir ağı (YSA) denir. Normal sinir hücreleri arasında bilgi alışverişi aksonlar yardımıyla olur. Bilgi sinir hücresine aksonlar yardımıyla gelir ve yine bir diğer hücreye aynı şekilde iletilir. Şekil 15' te biyolojik bir sinir hücresinin yapısı görülmektedir.




**Şekil 15.** Biyolojik Sinir Hücresi (Fausset L. 1994) [48]

Temel olarak sinir hücresinin yapısı; dendrit, soma, akson ve sinapsisten oluşur. Sinir hücresine gelen bilgi sinyalleri ilk önce dendritler yardımıyla hücrenin somabölgesinde toplanır. Soma toplanan sinyalleri aksonlar yardımıyla bir diğer sinir hücresine iletir. Aksonlar üzerinden geçen sinyal sinapsis boşluğu denilen bölgeye gelir. Buraya gelen bilgi sinyalleri dendritlere geçmeden önce gerekli ön işlemden geçmektedir.

Bu işlem eşik değer işlemi gibi düşünülebilir. Örneğin ağrı eşik değeri insanlarda farklılık gösterebilir. Kullanılan ağrı kesici sinirlerin ağrıyı hissetme eşik değerini yükselterek gerçekte var olan ağrıyı hissetmememizi sağlar.

Sinapsis aksondan gelen bilgiyi yorumlayıp diğer sinir hücresinin dentritine ulaştıran son durak olduğu için bu kısım sinir yapısının karar verici bölgesi olarak düşünülebilir. İki dentrit arasında yer alan soma, akson ve sinapsis bölgelerinin matematiksel olarak modellenmesi mümkündür. Şekil 16 ile Şekil 15 incelendiğinde ağırlıklar aksonları, eşikleme kısmı da sinapsisi temsil etmektedir.



Şekil 16. Yapay sinir ağı modeli

Yapay sinir ağı yapay sinir hücrelerinden oluşur. Hücreler arasındaki katmanların ağırlık değerleri ile öğrenme işlemi gerçekleşir.

Yapay sinir ağı modelleri, hayatın hemen her alanında yer almaktadır. Uygun öğrenme yolu izlendiğinde yani ağırlıklar belirlendiğinde başarılı sonuçlar verebilmektedir. Sınıflandırma, optimizasyon, konuşma tanıma gibi pek çok alanda sıkça kullanılmaktadır. Yapay sinir ağı modellerinde birçok nöronun eş zamanlı olarak çalışabilmesi ve çıktı üretebilmesi mümkündür. Eğitilen nöronların eğitim setinde olmayıp hiç girdi olarak verilmeyen girdilere doğru sonuçlar üretebilme özelliği vardır. Yapay sinir ağı modellerini hem donanım hem yazılım alanında geliştirmek mümkündür. Donanım alanında yapay sinir ağı modeli geliştirmek için öncelikle yazılım olarak modellenen yapay sinir ağının performansı çok iyi düzeyde olmalıdır.

Yapay sinir ağı ile sınıflandırma işleminde en temel amaç; girdiyi (x<sub>1</sub>, x<sub>2</sub> ... x<sub>h</sub>,) aktivasyon fonksiyonuna iletip beklenen çıktıyı (y) elde etmektir. Denklem (33) de verilen eşitlikte x girdilerinin toplanıp aktivasyon fonksiyonuna girdi olarak verilip çıktı olarak y çıktısının elde edildiği görülmektedir.

$$y(x, w) = f\left(\sum_{j=1}^h w_j x_j\right) \quad (33)$$

Bu sınıflandırıcı modeli temel olarak üç katmandan meydana gelir. Bu katmanlar; girdi katmanı, ara katman ve çıktı katmanıdır. Girdi katmanı verinin sonraki katmanlara iletiildiği katmandır. Bu katmanda veri sayısı kadar sinir nöronu bulunur. Ara katmanlardaki nöron sayısı girdi ve çıktı katmanlarından bağımsız olarak seçilir. Ağ modelinde birden fazla ara katman yer alabilir. Ara katmanlardaki ağırlıkların belirlenmesi öğrenme işleminin bir parçasıdır. Öğrenme aşamasında  $w_j$  katsayıları öyle bir seçilmelidir ki beklenen çıktı değeri elde edilsin. Tüm ağırlıklar girdi verileri ile işlemde geçirilerek merkezde toplanır. Elde edilen değer  $f(\cdot)$  aktivasyon fonksiyonundan geçirilerek çıktı üretilir. Geri beslemeli katmanlarda üretilen çıktı değeri, ağırlıkların güncellenip hatanın yok edilmesi için girdi olarak yeniden ağına girişine verilir. Başlangıç ağırlık değerleri eğitim süresi boyunca güncellenerek son halini alır. Bir başka ifade ile beklenen çıktı değeri elde edilinceye kadar eğitim devam eder.

Yapay sinir ağına ara katmanındaki nöron ve katman sayısı hesaplamasının karmaşıklığını artırsa bile, zor problemlerin çözümünde iyi performans göstermesi kullanılan nöron sayısı ile ilişkilidir. Kullanılan katman sayısına göre farklı türlerde yapay sinir ağı mevcuttur.

#### 4.2.1. Yapay Sinir Ağı Modelleri

- Tek Katmanlı yapay sinir ağı modelleri:
  - Perceptron
  - Adaline


Sinir ağı modelleri tek katmanlı modellerdendir.

- Çok katmanlı yapay sinir ağı modelleri:
  - Çok katlı Perceptron (MLP)
  - Hopfield Ağı
  - Self Organizing Map (SOM)
  - Recurrent Ağı

#### Perceptron

Tek katmanlı en basit yapı olan perceptron modeli yapay sinir ağları için önemli bir temel oluşturmaktadır. Perceptron ağına çıktı katmanında birden fazla nöron yer

almaktadır. Perceptron doğrusal olarak ayrılabilen verileri sınıflandırabilir. Bunun için eğitim sürecinde ağırlıklar güncellenerek en uygun karar sınır yüzeyinin elde edilmesi amaçlanır. Perceptron ve perceptron ağı Şekil 17' de verilmiştir.



Şekil 17. Perceptron ağı (sol) ve tek perceptron (sağ)

Belirlenecek ağırlık değerleri için başlangıç değeri atanır. Eğitim seti için belirlenen girdiler başlangıç ağırlıkları ile tek tek çarpılır ve toplanır. Elde edilen değer eşikleme fonksiyonu kullanılarak; eşik değerinin altında kalan değerleri bir sınıfa, üstünde kalan değerleri diğer sınıfa atayarak her bir girdi değeri için tahmini bir çıktı değeri üreterek bu tahmine bağlı olarak girdiyi bir sınıfa atar. Gerçek sınıf değerleri ve belirlenen çıktı değerleri kıyaslanır. Hata hesabı yapıldıktan sonra ağırlıklar hata değerine göre güncellenerek döngü devam eder. Bu süreç her bir girdinin doğru sınıfa atılması ile sonlanır. En son elde edilen ağırlık değerlerine göre karar verici yüzey belirlenir.

Perceptron yapay sinir ağı modelinin yukarıda anlatılan algoritması şu şekildedir. Denklem (34) – (37) algoritmanın adımlarını matematiksel olarak vermektedir.

**Adım 0:** başlangıç ağırlık değerlerini  $w_i$  ve kutup değerini  $b$  belirle, öğrenme katsayısı ( $\mu$ ) belirle,

**Adım 1:** Belirli bir iterasyon sayısı kadar veya her girdi değeri için uygun  $y$  değeri elde edilene kadar 2-5 adımlarını tekrarla,

**Adım 3:** Girdi değerlerini girdi setinden al,

**Adım4:** Perceptrona gelen toplam bilgi sinyalini belirle,

$$y_{in} = b + \sum w_i x_i \quad (34)$$

$$y = f(y_{in}), \quad y = \begin{cases} -1, & eğer y < \emptyset \\ +1, & eğer y > \emptyset \end{cases} \quad (35)$$



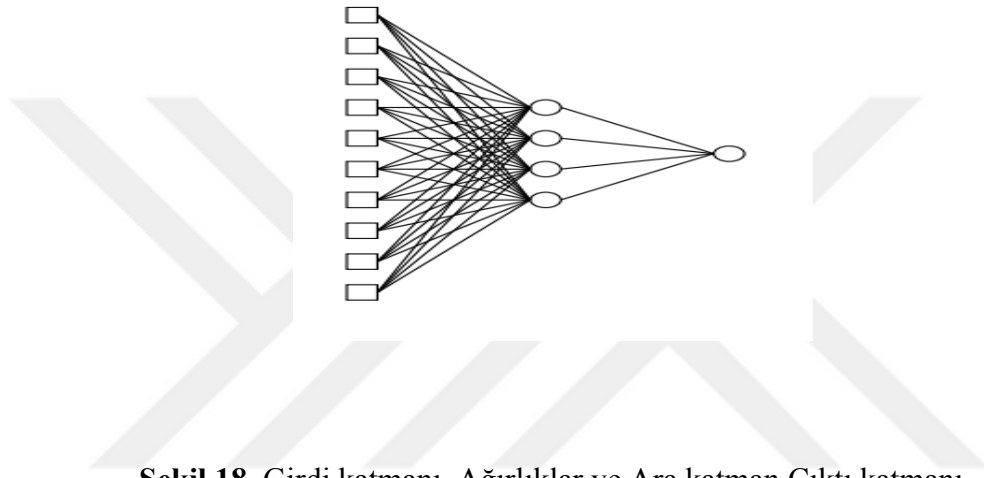
**Adım 5:** Beklenen t değerinden elde edilen y çıktı değeri farklı ise hata var demektir. Hata varsa;

$$w_{iyeni} = w_{ieski} + t * \mu * x_i \quad (36)$$

$$b_{yeni} = b_{eski} + t * \mu \quad (37)$$

Hata yoksa en uygun ağırlık değeri belirlenmiş demektir.

**Adım 6:** Öğrenme işlemini bitir [45].



**Şekil 18.** Girdi katmanı, Ağırlıklar ve Ara katman Çıktı katmanı

Hatanın minimize edilmesi için kullanılan çeşitli yöntemler şunlardır:

- Gradient Descent Metodu
- Steepest Descent Metodu
- Newton Metodu
- Conjugate Gradient Metodu

#### 4.2.2. Çok Katlı Perceptron (MLP) Yapay Sinir Ağı

Tek katmanlı perceptron yapısı doğrusal olmayan problemlerin çözümünde yetersiz kalmaktadır. Bu yapının yetersiz kaldığı yerde çok katmanlı perceptron yapısı kullanışlı bir yöntemdir. Çok katlı perceptron sinir ağı modelinde giriş katmanından verilen girdilerin çıktı katmanında doğru çıktı değerlerini vermesi için uygun ağırlık değerlerinin belirlenmesini amaçlar. Standart geriye yayılım algoritması (Back-Propagation) ve momentumlu geriye yayılım algoritması bu model için kullanılır.

Standart geriye yayılım algoritması şöyledir:


- Eğitim seti için belirlenen verilerden biri ağ girişine uygulanması
- Ağın çıkışının hesaplanması
- Ağın çıkışı ile beklenen değer arasındaki hatanın hesaplanması
- Hatanın küçültülmesi için geriye doğru ağırlıkların güncellenmesi

Yapay sinir ağının Matlab'ta hazır arayüzü bulunmaktadır. Veri setinin ve etiket vektörünün bu arayüze yüklenmesi, ara katmanlardaki nöron sayısının belirlenmesi, aktivasyon fonksiyonunun seçilmesi ile yapay sinir ağı modeli eğitilir. Bu arayüzde sonucun performans grafiklerinin incelenmesi, eğitim süresinde toplam iterasyon sayısı bilgilerine ulaşılabilmektedir.




## 5. SİNYAL ÖN İŞLEME ve SINIFLANDIRMA SONUÇLARI


Bu çalışmada kullanılan veri seti 16 elektrot kullanılarak kaydedilen İzlanda veri setidir [7]. Sinyaller 200 Hz örnekleme frekansı ile örneklenmiştir. Kayıt cihazında kesim frekansı 100 Hz olan anti-aliasing filtre kullanılmıştır. 4x4 elektrotlardan alınan sinyaller sinyal gürültü oranını arttırmak için yatay olarak bipolar sinyallere dönüştürülmüştür [49]. Şekil 19'da bipolar kanal gösterimi verilmiştir. Şekil 20 ve 21' de verilen grafiklerde monopolar ve bipolar sinyallerin karşılaştırılması görülmektedir.



Şekil 19. 4x4 elektrot Dizilimi[7]



Şekil 20. Monopolar Rahim Sinyalleri[9]




Şekil 21. Bipolar Sinyaller[9]

Bu grafikler incelendiğinde bipolar sinyallerde olayların daha keskin olarak görüldüğü anlaşılmaktadır. Rahim EMG sinyallerinde annenin solunum, EKG ve EGG (Electrogastrogram, mide sinyalleri) sinyalinden bebeğin kalp sinyaline kadar sinyal bileşenleri mevcuttur. Özellikle annenin solunum sinyalinin sinyaller üzerindeki etkisini azaltmak için bipolar sinyaller üzerinden analiz yapmak kasılma gibi bölgelerin tespit edilmesinde daha etkili olacaktır. Bu yüzden bipolar sinyaller üzerinde istenmeyen yani gürültü olarak tanımlanan bileşenlerin etkisinin azaltılması için sinyaller bipolar forma çevrilmiştir. Böylece sinyal gürültü oranının artırılması hedeflenmiştir.

Bipolar rahim sinyallerine ilk işlem olarak Dalgacık Paket Dönüşümünden yararlanarak gürültü azaltma işlemi uygulanmıştır.

### 5.1. Dalgacık Paket Dönüşümü Eşik Değer Yöntemi ile Gürültü Yok Etme

Rahim dış yüzeyinden alınan sinyaller birçok gürültü bileşeni içerir. Gerçek zamanlı her sinyalde meydana gelebilen bu gibi sinyalleri gürültü gibi genel bir ifade ile tanımlayabiliriz. İstenmeyen bu sinyaller elektrotlar ile deri arasındaki yüzeyden, kayıt cihazından kaynaklanan bileşenlerden, elektronik ekipmanlardan, ortamdaki elektromanyetik gürültü, elektrot ve elektrot kablolarından kaynaklanabilmektedir. Bu gürültü bileşenlerinin kaydedilen sinyal üzerindeki etkisi en aza indirilmelidir. Bu nedenle sinyalin içerdiği gürültü bileşenlerini minimum seviyeye düşürdükten sonra sinyal işleme amaçlanmıştır. Bunun için gürültüyü azaltma veya yok etme (de-noising) yöntemlerinden dalgacık eşik değer yöntemi kullanılmıştır. Bu yöntem ile öncelikle dalgacık katsayıları belirlenen bir dalgacık fonksiyonu ile hesaplanır. Dalgacık dönüşümü ile ilgili bilgiler üçüncü kısımda ayrıntılı olarak anlatılmaktadır. Temel olarak Dalgacık Paket Dönüşümü ile gürültü yok etme blok şeması Şekil 22'de gösterilmiştir.



Şekil 22. Dalgacık Paket dönüşümü a) Analiz b) Sentez blok diyagramları

İlk olarak sinyal dalgacık katsayılarına ayrıştırılır ve önceden belirlenen  $T$  eşik değerine göre yeni katsayılar belirlenir.  $C(j, k)$  dalgacık katsayıları olmak üzere,

$$d(C(j, k)) = \begin{cases} 1, & C(j, k) > T \\ 0 & \text{diğer} \end{cases} \quad (37)$$

Elde edilen eşiklenmiş katsayılar kullanılarak Ters Dalgacık Dönüşümü ile sinyal sentez edilmiş olur. Bu şekilde eşik değeri uygulandığı için sinyal üzerine binen gürültü azaltılmıştır [50]. Dalgacık Dönüşümü ile gürültü yok ederken eşik değeri belirlenmesi önemli bir problemdir. Farklı eşik değerlere göre farklı sonuçlar elde edilmektedir. Sinyal-gürültü oranı dikkate alınarak en uygun SNR değerini veren eşik değeri belirlenmiştir.

Uygulanacak eşik değeri metodunu belirlemek için aşamada literatürde kullanılan eşik değeri yöntemleri incelenmiştir.

Yumuşak (Soft) ve Keskin (Hard) Eşikleme olarak verilen eşitlikler denklem (38) ve denklem (39) da verilmiştir.

$$\text{Keskin eşik değeri} ; w_{th} = \begin{cases} w, & |w| \geq t \\ 0, & |w| < t \end{cases} \quad (38)$$

w dalgacık katsayısı, t eşik değeri;

$$\text{Yumuşak eşik değeri}; w_{ts} = \begin{cases} [sign(w)](|w| - t), & |w| \geq t \\ 0, & |w| < t \end{cases} \quad (39)$$


Diğer eşik değeri çeşitlerinin temel denklemleri denklem (40)'da sigma değeri de denklem (41)'de verilmiştir.

$$w_{th} = \sigma \sqrt{2 \log(n) / n} \quad (40)$$

$$\sigma = \frac{\text{median}(w)}{0.6745} \quad (41)$$

W dalgacık dönüşümü katsayıları, n toplam dalgacık katsayılarının toplam sayısıdır.

Global, Rigrsure, Heursure, minimax eşikleme değerleri temelinde bu denklemlerden türetilmişlerdir. Bu farklı eşikleme değerleri analiz edilmiştir. Analiz için SNR değerleri karşılaştırılmıştır. SNR hesaplama için öncelikle temizlenen sinyalin orijinal sinyalden farkı alınarak gürültü sinyali belirlenmiştir. Daha sonra sinyalin gürültü sinyaline oranı hesaplanarak SNR değeri hesaplanmıştır. Matlab'ta yer alan bu eşikleme yöntemleri kullanılarak gürültü azaltma işlemi sonucu elde edilen sinyal gürültü oranları karşılaştırılmıştır. Rahim EMG sinyallerine uygulanan eşikleme yöntemleri arasında Heursure ve Soft eşikleme değerlerinin SNR değerleri birbirine eşit çıkarken diğer yöntemlerden minimax eşikleme en yüksek SNR değerini vermiştir. Bu eşikleme yöntemine göre Şekil 23' te elde edilen sonuçlar verilmiştir.



**Şekil 23.** Gürültü Azaltma Öncesi ve Sonrası Rahim EMG Sinyali

Rahim EMG sinyalleri durağan olmayan bir karakteristiğe sahiptir ve bu sinyaller kayıt altına alınırken, rahim kaslarının sinyallerinden başka sinyal bileşenleri içerir. Bu bileşenler annenin EKG'si, elektrotlardan kaynaklanan gürültü ve ortamdaki elektromanyetik alandan kaynaklanabilir. Bu nedenle sinyalin içerdiği bu bileşenleri belirlemek kasılma ve foetal hareketlenmelerin kestirilmesinde önemli bir yere sahiptir. Belirlenen bu bileşenler dışında kalan kasılmalar analiz edilerek erken doğumu kestirmek daha kolay hale gelecektir. Örneğin bizim için öneme sahip olan olayları belirlemek için uygun filtreden geçirip hem embriyonun hem annenin EKG sinyal bileşenini içeriyorsa bu sinyalleri ayırt etmek erken doğum kasılmasını belirleme işleminden önce faydalı bir adım olacaktır. Rahim EMG sinyalinin içerebileceği başlıca sinyaller şunlardır:

- Kasılma
- Embriyo hareketleri
- Annenin veya bebeğin EKG'si
- Uzun süreli düşük frekanslı sinyaller

Kasılma sinyalleri 1 Hz'in altındaki, uzun süreli düşük frekanslı sinyaller ve embriyo hareketlerine bağlı elektriksel sinyaller de 0,5 Hz'in altındaki frekanslara sahiptir [51],[52].

Erken doğumun kestirilmesinde önemli bir yeri olan bu tip sinyaller dışındaki istenmeyen gürültülerden kurtulmak için bant geçiren filtre uygulanmıştır. Üstteki sinyallerin frekans aralıkları göz önünde bulundurularak ve aynı zamanda kaynaklardaki çalışmalarda kullanılan kesim frekansına sahip bant geçiren filtre kullanılmıştır. Uygulanan filtrenin kesim frekansı 3 Hz -0,1 Hz'dir.

Rahim EMG sinyallerinde kasılma ve foetal hareketlenme bölgelerinin tespit edilmesi; tüm sinyalin analiz edilmesi gerekliliğini ortadan kaldırarak aşırı veri işlenmesinden kaynaklanan işlem yükünden kurtulmayı sağlayacaktır. Bu amaçla bu bölgelerin otomatik olarak tespit edilmesine yönelik uygulanan algoritmalar ayrıntılı olarak verilmiştir.

## 5.2. Kasılma Tespiti için Uygulamalar

Filtrelenen sinyalin kasılma bölgeleri ve diğer foetal hareketlerinin zaman bölgesinde kestirilebilmesi için çeşitli analizler yapılmıştır. Bu analizler zaman bölgesinde sinyalin enerjisi veya farklı filtreler uygulanarak yapılmıştır.

Uygulanan filtreler daha önce EKG sinyallerinde QRS bölgesinin tespiti için kullanılmıştır. Sinyal üzerindeki kasılma bölgelerinin frekansında ve genliğinde değişimler meydana gelmektedir. Bu bölgeleri etiketlemek amacıyla uygulanan algoritmalar ve sonuçları aşağıda verilmiştir.

### 5.2.1. Algoritma 1

Bu algoritma Ahlstrom&Tompkins tarafından QRS tespiti amacıyla geliştirilen bir algoritmadır [53]. QRS bölgesi yani kalbin kasılıp gevşediği bölge sinyalin diğer bölgelerine göre daha çok eğimin, yüksek genliğin ve en keskin dalganın olduğu bölge denilebilir. Bu bilgi ve öngörü ile oluşturulan algoritma kasılma ve erken doğum için belirleyici sinyal aralıklarının tespit edilmesi için rahim EMG sinyaline uygulanmıştır. Uygulanan algoritmalar sonucu elde edilen sinyaller aşağıda yer almaktadır.  $x(n)$  rahim EMG sinyali olsun.

İlk olarak  $x(n)$  sinyalinin birinci dereceden türevi denklem (42) de verildiği gibi elde edilir.

$$y_0(n) = |x(n) - x(n - 2)| \quad (42)$$

İkinci dereceden türevi ise denklem (43) de verilmiştir.

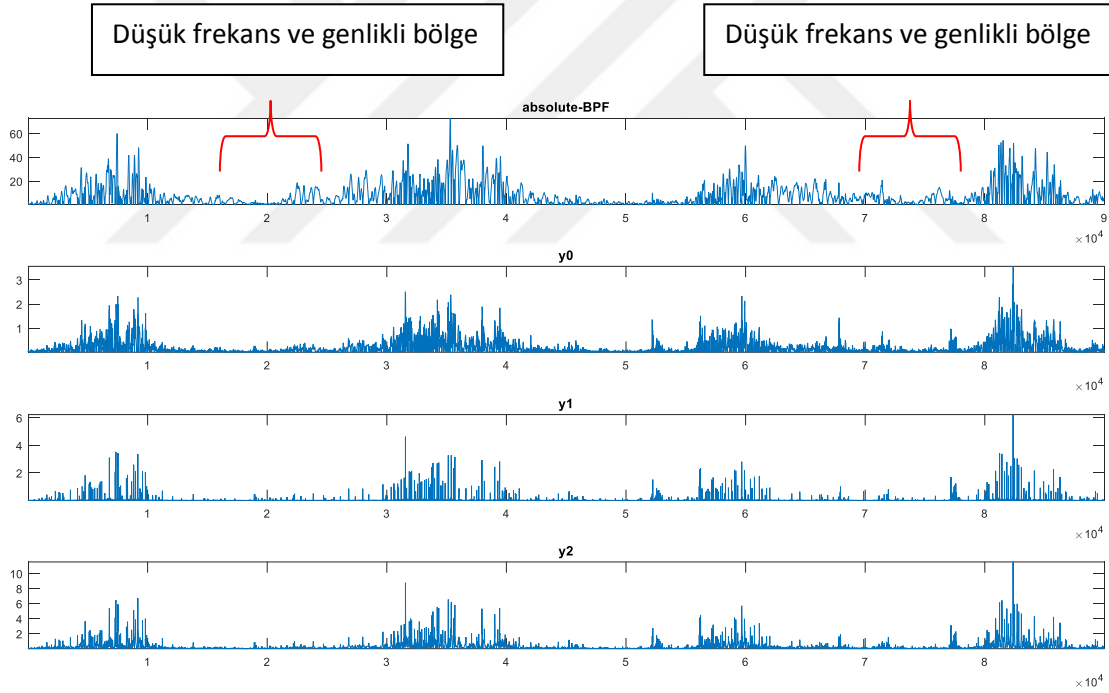
$$y_1(n) = |x(n) - 2x(n - 2) + x(n - 4)| \quad (43)$$

Birinci ve ikinci türevi belirli katsayılarla çarpılarak toplandığında elde edilen sinyal denklem (44) de yer almaktadır.

$$y_2(n) = 1.3y_0(n) + 1.1y_1(n) \quad (44)$$

Bu algoritmada türev operatörünün uygulanması ile sinyale yüksek geçirgen filtre uygulanır. Yüksek geçirgen filtreler genel olarak sinyalin keskin bölgelerinin çıkartılması amacıyla, alçak geçirgen filtreler ise sinyal üzerinde bulunan gürültü bileşenlerinden kurtulmak amacıyla uygulanmıştır [54]. Algoritma sonucu elde edilen sinyal, birinci ve ikinci türev sonuçları Şekil 24' te verilmiştir.

Filtrelenen sinyalin ilk ve ikinci türevden sonraki çıktıları ve algoritmanın son hali incelendiğinde türev almanın olayların meydana geldiği aralıkları daha da keskinleştirdiği görülmektedir. Yüksek frekanstaki bölgeler türev işlemi ile daha belirginleştirilmiştir.



**Şekil 24.** Sinyalin 1.ve 2. Türevleri

Bu algoritma sonucu elde edilen sinyalin zarfı alınarak bölgelerin aralıkları otomatik olarak belirlenebilir. Diğer algoritma QRS tespitinde kullanılan bir başka yöntemdir. Bu yöntem de diğeri gibi Ahlstrom&Tompkins tarafından EKG sinyallerinde QRS bölgesi tespiti için geliştirilmiştir [55],[53].



### 5.2.2. Algoritma 2


Bu yöntem önceki algoritmaya göre kasılma bölgesinin tespiti için daha başarılı sonuç vermiştir. Bu analiz yönteminde ilk olarak sinyalin birinci türevinin karesi değişken bir katsayı ile çarpılır. Bu katsayı sinyalin üzerinde taranan pencere uzunluğuna bağlı olarak her nokta için değişmektedir. Algoritmada ilk aşamada elde edilen sinyalin eşitliği denklem (45) de verilmiştir.

$$g_1(n) = \sum_{i=1}^N |x(n-i+1) - x(n-i)|^2 (N-i+1) \quad (45)$$

Türev alınırken aynı zamanda bir pencere kullanılır. N parametresi uygulanan pencerenin uzunluğudur. Bu pencerenin uzunluğu çok geniş ya da dar olmamalıdır. Dar olması çözümü ilk algoritmaya yaklaştırırken çok geniş olması da sinyal üzerinde gecikmeye sebep olur. Sonraki adım sinyal üzerindeki dalgalanmayı azaltmak amacıyla ortalama alıcı (Moving Avarage) filtre uygulamadır. Denklem (45) de elde edilen sinyale uygulanan filtre eşitliği denklem (46) da verilmiştir. M pencere aralığıdır.


$$g(n) = \frac{1}{M} \sum_{j=0}^{M-1} g_1(n-j) \quad (46)$$

Şekil 25 sinyale uygulanan her adımın çıktısını vermektedir.




Şekil 25. Ağırlıklandırılmış ve Kare Alıcı Filtre ve Ortalama Alıcı Filtre sonuçları

İncelendiğinde algoritma 2' nin sonucu takograf kaydı ile benzerlik gösterdiği görülmektedir. Şekil 26' da verilen sinyallerde keskin sinyal bölgelerinin eşik enerjisinin alınıp bu enerji sinyaline uygulanan eşik değeri sonucu bölgelerin başlangıç ve bitiş noktaları belirlenmiştir. Grafik üzerindeki iki kasılma ayrı olarak gösterilmiştir.



Şekil 26. (a) Enerji Sinyali (b) Algoritmaya Göre Elde Edilen Kasılma bölgeleri

Eşik değeri enerji sinyalinin ortalama değeri ile ilgili katsayı çarpılarak belirlenir. İki algoritma sonuçları Şekil 27' de karşılaştırılmıştır. İlk ve sonraki algoritma sonuçları karşılaştırıldığında sonraki algoritma sonucunda kasılma bölgelerini daha keskin olarak verdiği aşağıdaki şekil incelendiğinde görülmektedir.



Şekil 27. Algoritma sonuçlarını karşılaştırma

Kasılma noktalarının otomatik olarak belirlenmesi için incelenen bir diğer yöntem Teager-Kaiser Enerji Operatörüdür. Sinyal enerji analiz yöntemi olan Teager Enerji Operatörü ile sinyalin enerjisi incelenmiştir.

### 5.2.3. Teager Enerji Operatörü

Teager enerji operatörü bir sinyalin anlık enerjisi değerlendirmektedir. Bu algoritma ile sinyal üzerinde zaman bölgesine bağlı olarak değişim noktalarını tespit etmek mümkündür.


Sürekli zaman sinyali olan  $x(t)$  olsun, Teager-Kaiser Operatörü uygulanırsa matematiksel gösterimi şu şekildedir [56]. Denklem (47) ve (48)'de sırasıyla sürekli ve zaman sinyalleri için Teager operatörü denklemleri verilmiştir.

$$\varphi(x(t)) = \left(\frac{dx(t)}{dt}\right)^2 - x(t) \frac{d^2x(t)}{dt^2} \quad (47)$$

Sinyal kesikli olduğunda ise;

$$\varphi(x(n)) = x(n)^2 - x(n+1)x(n-1) \quad (48)$$


Şekil 28' de Teager sonucu verilmiştir. Bu algoritmanın sinyalde kasılma veya önemli bölgeler olarak belirtilen bölgeleri daha keskin olarak öne çıkardığı görülmektedir.



**Şekil 28.** Teager Enerji Operatörü sonucu

Teager Enerji operatörü de sinyalin frekans ve genlik bakımından değişiklik gösterdiği bölgeleri belirleyebilmek açısından kullanışlı bir algoritmadır. Bu operatör Dalgacık Dönüşümü, Kısa Zamanlı Fourier Dönüşümü gibi bir dönüşüm olarak düşünülebilir. Daha önceki çalışmalarda uyku mili (spindle) bölgelerinin tespit edilmesinde kullanılmıştır [57].

Teager-Enerji Operatörü kasılma bölgesinin tespitinde kullanılabilir bir algoritmadır. Daha önce biyolojik sinyallerin enerji analizlerinde iyi sonuçlar veren algoritma 2 ve Teager Enerji Operatörü karşılaştırıldığında iki algoritmanın da kasılma noktalarını belirlemede birbirine benzer yaklaşım ortaya koyduğu görülmektedir. Şekil 29'da verilen grafikte her iki sonuç da çizdirilmiştir.




**Şekil 29.** Teager Enerji ve Algoritma 2 Sonuçları Karşılaştırma

Teager enerji analiz yöntemi Dalgacık Dönüşümüne de uygulanmıştır. Bu işlemde daha hızlı sonuç elde edilmiştir. Ayrıca Dalgacık Dönüşümü ile sinyal alt ve üst frekans bantlarına ayırdığı için ve bu işlemde zaman bilgisi korunduğu için yararlı bir uygulama olduğu görülmüştür.

#### 5.2.4. Dalgacık Dönüşümü ve Teager Enerji Dönüşümü

Veri setinde bulunan sinyallerin analizi için kullanılan bir diğer yöntem Dalgacık Dönüşümü ile Teager-Kaiser Enerji analizidir. Bu yöntemde Dalgacık Dönüşümü ile 5'inci seviyeden Dalgacık Dönüşümü sonucuna Teager Enerji uygulanmıştır. Bu şekilde 5'inci seviyeden elde edilen sinyalin Teager Enerjisi hesaplanmıştır. Şekil 30'da verilen

grafiklerde Teager sonucu ve dalgacık dönüşümünden sonra elde edilen sonuçlar karşılaştırılmıştır.



**Şekil 30.** Dalgacık Dönüşümünden Sonra Teager Enerji Analizine Teager Enerji Analizi

Elde edilen enerjiye eşik değer uygulanarak sinyalin keskin bölgelerini belirlemek mümkündür. Bu işlem dalgacık dönüşümü uygulamadan yapıldığında sonuç elde etmek için uzun süre beklemek gerekmektedir. Ayrıca dalgacık paket dönüşümü ile üst seviyelerde bulunan sinyal bileşenleri ayrıştırıldığı için daha yumuşak bir sonuç elde edilmektedir. Dalgacık Dönüşümü kullanılarak daha etkin sonuçta, daha kısa sürede ulaşılmaktadır.

Rahim EMG sinyallerine uygulanan bu ön işleme yöntemlerinin arayüzde uygulamaları mevcuttur. Bu yöntemlerin kullanımı sinyal işleme ve analizi arayüzü bölümünde detaylı olarak açıklanmıştır.

Kayıtlı sinyallere ait ön bilgilerin, yani rahimden kaynaklı önemli olayların sınıflandırılması amacıyla öznitelikler çıkarılmıştır. Öznitelik belirleme bölümünde anlatılan özniteliklerin bir kısmı sınıflandırma amacıyla çıkarılmıştır. Sınıflandırmada kullanılmayan fakat arayüzde ileride olabilecek çalışmalarda kullanılmak üzere istenilen sinyalin arayüzde bulunan seçenekler yardımıyla bu özniteliklerin çıkartılması mümkündür. Sınıflandırmada kullanılan öznitelikler; toplam güç, tepe genliği, süresi, sıfırdan geçiş oranı, RMS, Güç Spektral Yoğunluk Tepe Genliği, Güç Spektral Yoğunluk Tepe Frekansı, standart sapma, varyans, ortalama, zamanda terslenebilirlik ve örnek entropisidir. Arayüzde bu parametrelere ek olarak kullanıcının analiz ederken kullanabileceği ek öznitelikler de bulunmaktadır. Dalgacık Dönüşümü ayrışım ve detay katsayıları, dalgacık paket dönüşümü katsayıları, Lyapunov üsteli öznitelikleri de

kullanılmaktadır. Bu şekilde arayüzde kullanıcı sinyali analiz ederken zaman, frekans ve istatistiksel tabanlı analiz edebilecektir.

Çıkarılan özniteliklerin sayısı, boyut indirgeme yöntemi olan FDA ile düşürülmüştür. Boyut indirgeme ile seçilen boyutta en ayırt edici öznitelikler kullanılarak sınıflandırma yapıldığı için sınıflandırma performansı artmıştır.

En yakın uzaklık sınıflandırıcı yöntemi ile boyut indirgeme yapılmadan sınıflandırma performansı %34,1 iken boyut indirgeme yöntemi ile özniteliklerin boyutu 3'e indirgenmiştir. Bu şekilde sınıflandırma performansı %65,34 olarak elde edilmiştir.

Doğrusal bir sınıflandırıcı olan en yakın uzaklık algoritmasının sonucunu iyileştirmek amacıyla iyileştirme işlemi uygulanmıştır. Sınıflandırma performansını arttıran iyileştirme uygulaması hakkında detaylı bilgi verilmiştir.

### 5.3. En Yakın Uzaklık Sınıflandırıcı İçin Ağırlık Düzeltme

Sınıflandırmada kullanılan ağırlıklar eğitim setindeki verilerin ortalaması ile belirlenip test setindeki verilerin bu ağırlıklara olan uzaklıkları kıyaslanarak en yakın sınıfa atama yapılır. Bu ağırlık değerlerinin sınıflandırma performansı üzerinde etkili olduğundan dolayı, sınıflandırma doğruluk oranını yükseltmek amacıyla bu ağırlıkların daha anlamlı seçilmesi amaçlanmıştır.

Bunun için eğitim ve test setine ek olarak yeni bir set tanımlanmaktadır. Bu set kullanılarak eğitim setinden elde edilen ağırlıklar, yani özniteliklerin ortak ifadesi bu düzeltme seti ile tekrar düzenlenir.

Toplamda veri setinden eğitim seti, düzeltme seti ve test seti olmak üzere üç ayrı veri seti oluşturulmuştur. En yakın uzaklık algoritmasının iyileştirilmesi aşağıda verilen basamaklarla planlanmıştır:

$x_1, x_2, \dots, x_e$  Eğitim seti;

$x_1, x_2, \dots, x_o$  Düzeltme seti;

$x_1, x_2, \dots, x_t$  Test seti olsun.

**Adım1:** Eğitim setindeki her sınıfın ağırlıklarını ortalama değer olarak hesapla

$w_1, w_2, w_3$  Eğitim setindeki sınıf tanımlayan özniteliklerin ortalaması;

**Adım2:** Düzeltme setindeki her veri için 2-a) - 2-b) adımlarını uygula,

**2-a)** Sınıfı bilinen  $x_o$  verisi  $w_2$  (d) sınıfına ait olsun (d doğru sınıf),

Öğrenme adımını  $\eta$  belirle

**2-b)**  $x_o$  verisinin  $g_1 = ||x_o - w_1||$ ,

$$g_2 = ||x_o - w_2||$$

$$g_3 = ||x_o - w_3||$$

**2-c)** Uzaklıklar arasından en küçük olanı bul ve sonuç sınıfını gerçek sınıfla karşılaştır

**2-d)** Doğru sınıf değil ise  $w_h = w_h - \eta(x_o - w_h)$ ;

Doğru sınıf ise  $w_h = w_h + \eta(x_o - w_h)$

**Adım3:** Test setindeki her bir verinin güncellenmiş ağırlıklara uzaklıklarını hesapla

**Adım4:** Uzaklığı en küçük hangi sınıfa ait ağırlık ise veriyi o sınıfa ata.

**Adım5:** Testi bitir.

Bu algorithmada adım 2' de ağırlıkların iyileştirilmesi yapılır. Uygulanan iyileştirme yordamı sonucu en yakın uzaklık sınıflandırıcının başarı performans oranı %70 olarak bulunmuştur. Sınıflara ait ağırlıkların iyileştirilmesi başarı oranını %65'ten %70 'e çıkarmıştır.

#### **5.4. Yapay Sinir Ağları ve En Yakın Uzaklık Sınıflandırıcı Sonuçları**

İzlanda verisinde bulunan veri setinde toplam 3 sınıf bulunmaktadır. İlk uygulamada en yakın uzaklık sınıflandırıcı algoritmasında eğitim seti ve test seti her sınıfa ait verilerin yarısı eğitim diğer yarısı da test setinde kullanılmıştır. Buna göre elde edilen sınıflandırma performansı %65' tir. Performansı arttırmak amacıyla en yakın uzaklık sınıflandırıcının ağırlıkları optimize edilerek test seti test edilmiştir. Genel doğruluk oranı hesaplanırken eğitim seti, düzeltme seti, test seti olmak üzere 3 kısma ayrılmıştır. Uygulanan iyileştirme yöntemi sonucunda elde edilen sınıflandırma başarı oranı %70 olarak kaydedilmiştir. İleri beslemeli yapay sinir ağları ve en yakın uzaklık sınıflandırıcı yöntemlerinin sonuçları Tablo.1'de verilmiştir.

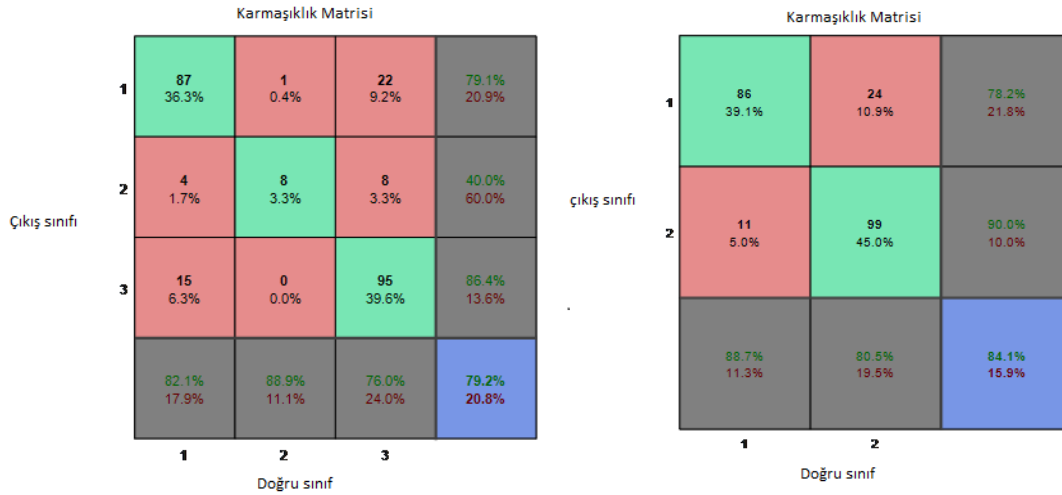
İleri beslemeli yapay sinir ağları sınıflandırma sonucunda elde edilen Şekil 31' de verilen karışıklık matrisleri incelendiğinde 3. sınıf olan Kasılma sınıfının doğruluk oranı,

genel doğruluk oranından daha yüksek olup %86.4' tür. En düşük doğruluk oranı ikinci sınıf yani muhtemel kasılma sınıfına aittir.

**Tablo 1-Sınıflandırıcı Sonuçları**

İleri Beslemeli yapay sinir ağı	Genel:%79.2, Kasılma: %86.4
İyileştirilmiş En Yakın Uzaklık Sınıflandırıcı	%70
En yakın uzaklık sınıflandırıcı	%65
K-en yakın uzaklık Sınıflandırıcı	%73

İleri beslemeli yapay sinir ağları sınıflandırma sonucunda elde edilen Şekil 31'de verilen karmaşıklık matrisleri incelendiğinde 3. sınıf olan Kasılma sınıfının doğruluk oranı, genel doğruluk oranından daha yüksek olup %86.4' tür. En düşük doğruluk oranı ikinci sınıf yani muhtemel kasılma sınıfına aittir. Muhtemel kasılma tam olarak hangi sınıfa ait olduğu bilinmeyen foetal hareketler veya kasılma olarak düşünülebilir. Bu sınıf çıkarılıp iki sınıf üzerinden ileri besleme yapay sinir ağları ile sınıflandırma yapıldığında genel doğruluk oranı %84.1, kasılma sınıfının doğruluk oranı ise %90 ' dır. Kasılma tespiti için yapılan bu çalışmalar sonucu yüksek performansta sınıflandırma yapılmıştır.



**Şekil 31. Karmaşıklık Matrisleri**

İleri beslemeli yapay sinir ağları ile 16 kanallı veriler için sonuçlara farklı kanalların performans üzerindeki etkisi de incelenmiştir. 3 sınıf kullanılarak yapılan sınıflandırma




işlemlerinde elde edilen sonuçlar Tablo-2’de verilmiştir. Tablo-2 elde edilirken 11 adet öznitelik kullanılmıştır. Bu öznitelikler; toplam güç, tepe genliği, süresi, sıfırdan toplam geçiş oranı, ortalamaların karekökü, Güç Spektral Yoğunluk Fonksiyonunun Tepe Genlik Değeri Ve Tepe Frekansı, standart sapma, ortalama, medyan ve varyans olmak üzere 11 adettir. Bu öznitelikler kullanılarak kanalların doğruluk oranlarına etkisi incelenmiştir. Tablo-2 de görüldüğü gibi genel doğruluk oranı en iyi 12' nci bipolar kanalda Kasılma sınıfı için en iyi değerler 1 ve 12' nci bipolar kanallardan elde edilmiştir. Renk dağılım ile her kanalın doğruluk oranları verilmiştir. Bu dağılıma göre en yüksek değer açık sarıdan en düşük değer koyu maviye doğru değişim göstermektedir.


Tablo 2- Bipolar Kanalların Genel ve Kasılma Sınıfı İçin Doğruluk Oranları

	Vb1	Vb2	Vb3	Vb4	Vb5	Vb6	Vb7	Vb8	Vb9	Vb10	Vb11	Vb12
Genel Doğruluk (%)	79.4	64.2	67.5	68.8	65.8	64.2	67.9	68.8	65	69	64.6	72.1
Kasılma Sınıfı (%)	86.4	60	70	70	66.4	60	68.2	68.2	75.5	70	62.7	80

Her bir bipolar kanalın doğruluk oranlarının dağılım matrisleri Şekil 32’de verilmiştir.



79.4	68.8	67.9	69
64.2	65.8	68.8	64.6
67.5	64.2	65	72.1



86.4	70	68.2	70
60	66.4	68.2	62.7
70	60	75.5	80

Şekil 32. Farklı Kanallara Ait Genel Doğruluk ve Kasılma Sınıfının Doğruluk Oranları

En yakın uzaklık sınıflandırıcı yönteminde ağırlıkların optimize edilmesi başarı performansını arttırmıştır. Bu çalışmada kasılma bölgelerinin kestirilmesi yönünde çalışmalar yapılmıştır. Doğrusal olmayan ileri beslemeli yapay sinir ağları ile yapılan çalışmada kasılmalar iyi performansta kestirilmiştir. Deneysel olarak yapılan sonuçlarda en iyi performansı veren yapay sinir ağlarının yapısal özellikleri deneysel yöntemler sonucu belirlenmiştir. Kullanılan yapay sinir ağının özellikleri Tablo 3' te verilmiştir.

Tablo 3- Yapay Sinir Ağı Özellikleri

En yüksek eğitim döngü sayısı	1000
Öğrenme adımı	0.01
Transfer fonksiyonu	Log-Sigmoid
Eğitim fonksiyonu	Geriye yayılım algoritması
Nöron Sayısı	20

Erken doğumun kestirilmesi için belirlenen kasılmaların hangi döneme ait olduğunun belirlenmesi gerekmektedir. Kasılma hamilelik döneminde, doğum anında, erken doğum ile sonuçlanmış bireyin hamilelik döneminde meydana gelebilir. Erken doğumu önceden kestirebilmek amacıyla erken doğum ile sonuçlanan hamilelik sinyallerini önceden kestirebilmek gerekir. Çalışmanın son aşamasında bu tip kasılmaları, normal doğum ile sonuçlanmış hamilelik sinyallerinden ayırt edebilmeye yönelik çalışmalar yapılmıştır.

#### 5.4.1. Erken Doğum, Normal doğum ve Hamilelik Sinyallerinin Sınıflandırılması

İzlanda veri setinde kısıtlı sayıdadabilen 3 erken doğum ile sonuçlanan hamilelik sinyallerinden dipnot bilgileri kullanılarak belirlenen kasılma bölgeleri çekilip, diğer sinyallerden normal doğum ile sonuçlanan hamilelik sinyallerinde meydana gelen kasılma bölgeleri ve normal doğum anındaki kasılma bölgeleri bir araya getirilmiştir.


Erken doğum ile sonuçlanan 3 kayıttan toplam sekiz adet erken doğum kasılma bölgesi çıkartılmıştır. Sınıflandırmada öğrenme önyargısını enaza indirmek amacıyla hamilelik

kasılmalarından da 11 adet veri seçilmiştir. Doğum anında oluşan kasılma verilerinden de sınırlı sayıda olduğu için 4 adet seçilmiştir. Bu kasılma bölgeleri kullanılarak erken doğum ile sonuçlanan sınıf birinci sınıf ve diğer iki sınıf kullanılarak elde edilen genel doğruluk oranı %82.6'dır. Birinci sınıfın doğruluk oranı ise %75 olarak elde edilmiştir.


#### **5.4.2. Farklı Kanallar Üzerinden Yapılan Sınıflandırmalar**

Çoklu monopolar kanallar ile kayıt edilen sinyaller analiz edilirken farklı kanallar seçilebilir. Seçilen kanalın sınıflandırma veya analiz sonucunda elde edilen performans değeri üzerinde etkisi vardır. Öyle ki performans sonucu analiz edilen kanala göre değişebilmektedir. Kaynaklarda yapay sinir ağı kullanılarak elde edilen sonuçlara göre 4x4 elektrot diziliminde yeralan 10' uncu bipolar kanal en yüksek sınıflandırma performansı verirken 7' nci bipolar kanal en düşük performansı vermektedir [58]. Bu çalışmanın devamı olarak aynı öznelikler kullanılarak başka bir yapay sinir ağı olan Radyal Tabanlı Yapay Sinir Ağı kullanıldığında düşük ve yüksek performans gösteren kanallar değişmektedir [5]. Diğer bir çalışmada frekansa dayalı öznelikler tüm bipolar kanallardan ayrı ayrı elde edilmiştir. Elde edilen kanalların kasılma sinyallerini en iyi doğruluk oranı ile sınıflandıran kanalın 5. bipolar kanal olduğu görülmüştür [59]. Erken doğum ve normal doğum kasılmalarını sınıflandırmaya yönelik ilk sınıflandırma işlemi 1'inci bipolar kanal üzerinden yapılmıştır. Sınıflandırmada kullanılan ileri beslemeli yapay sinir ağının özellikleri Tablo 3' te verilen özellikler ile aynıdır. 20 nörondan oluşan yapay sinir ağında erken doğum, hamilelik ve normal doğum kasılmalarından sırasıyla 4, 6 ve 2 olmak üzere toplam 12 adet veri eğitim için kullanılmıştır. Analiz için ayrılmış olan diğer veriler de test verisi olarak kullanılmıştır.

Daha önce belirtildiği gibi 12 adet bipolar kanal bulunmaktadır. Elektrotlar üzerinde uzlamsal farklılığı gözlemleyebilmek için diğer kanallar üzerinden de sınıflandırma doğruluk oranlarına bakılmıştır. Şekil 33'de doğruluk oranlarının bipolar kanallara göre değişimi verilmiştir. Sayısal değerler de grafiğin hemen yanında matris olarak verilmiştir. En düşük değerden yani koyu maviden, en yüksek değer açık sarıya doğru performans değerleri dağılımı görülmektedir. Bu kanalların sayısal değerleri de Tablo-4' te verilmiştir.



82.6	60.9	82.6	87
65.2	60.9	91.3	73.9
82.6	65.2	65	82.6



75	87.5	87.5	75
87.5	50	75	62.5
62.5	75	75	87.5

**Şekil 33.** Genel Doğruluk ve Erken Doğum Sınıfına Ait Doğruluk Oranlarının Kanallara Göre Dağılımı

**Tablo 4-** Bipolar Kanalların Genel ve Erken Doğum Sınıfı İçin Doğruluk Oranları


	Vb1	Vb2	Vb3	Vb4	Vb5	Vb6	Vb7	Vb8	Vb9	Vb10	Vb11	Vb12
Genel Doğruluk (%)	82.6	65.2	82.6	60.9	60.9	65.2	82.6	91.3	65	87	73.9	82.6
Erken Doğum (%)	75	87.5	62.5	87.5	50	75	87.5	75	75	75	62.5	87.5

Veri setinin kapsamlı olması durumunda doğruluk oranları daha da iyileşecektir. Bu sonuçlara göre erken doğum sınıfının doğruluk performansını en iyi veren bipolar kanallar 2, 4, 7 ve 12'dir. Genel doğruluk için en iyi performansı gösteren kanal 8'inci bipolar kanal olmuştur.

Erken doğum kestirimi için kanallara göre performansı değerlendirildikten sonra erken doğum ile sonuçlanan hamilelik sinyallerinde meydana gelen kasılmalara ait özniteliklerin zamanla değişimi de incelenmiştir.


#### 5.4.3. Zaman-Öznitelik Değişimi

Erken doğum yapan iki farklı kadından sırasıyla iki ve dört defa kayıt alınmıştır. Birinci kadının kaydında iki kez meydana gelen kasılma bölgesine ait özniteliklerin değişimi belirlenmiştir. Şekil 34' te aynı katılımcının aynı gün aynı kaydın iki farklı kasılmanın öznitelik değerleri görülmektedir. İkinci kasılda altıncı öznitelik dışındaki diğer öznitelik değerlerinde azalma olduğu görülmektedir.




Şekil 34. Farklı Zamanlardaki Kasılma Öznitelik Değerleri

Bir diğer sinyal kaydında yeralan farklı öznitelikler Şekil 35' te verilmiştir. Birinci ve ikinci yani iki farklı zamanda kayıt edilen sinyallerde toplam üçer kez kasılma meydana gelmiştir. Bu iki farklı sinyal kaydında üçer farklı kasılmalara ait öznitelik değerleri incelendiğinde bazı özniteliklerin birinci kasılmaya göre artış veya azalış gösterdiği görülmektedir.



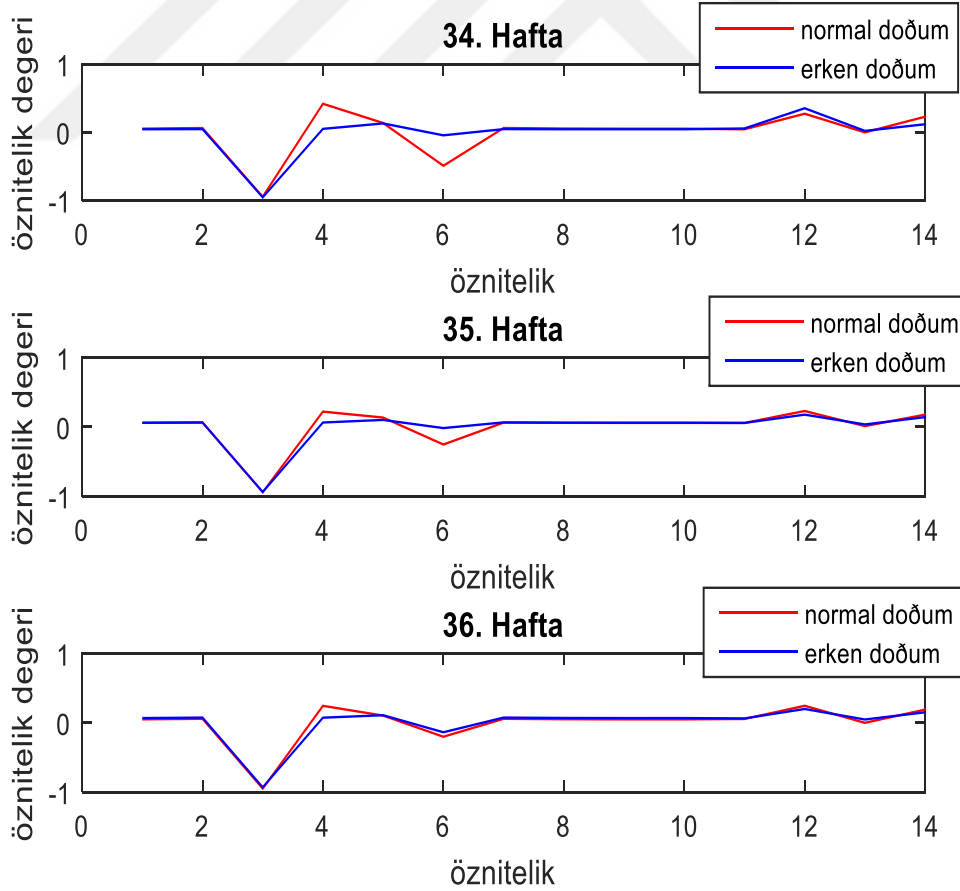
Şekil 35. İki Farklı Sinyalde Meydana Gelen Kasılmalar

Şekil 34 ve 35' te yer alan grafiklerde erken doğum ile sonuçlanan hamilelik kasılmalarına ait özniteliklerin değerleri görülmektedir. Normal doğum ile sonuçlanan hamilelik sinyallerine ait özniteliklerin değerleri aşağıdaki şekilde yer almaktadır. Ayrıca bu grafiklerdeki öznitelikler sırasıyla sıfırdan geçiş oranı, karelerin ortalama karekökü, GYS Fonksiyonunun Tepe Genliği, GYS Fonksiyonunun Tepe Frekansı, standart sapma, varyans, ortalama ve medyandır. Bu grafiklerin normal doğum ile sonuçlanan hamilelik kasılmalarına ait özniteliklerin yer aldığı Şekil 36' daki grafik ile karşılaştırılması iki farklı sınıfa ait özniteliklerin zamandaki değişimi hakkında bilgi vermektedir.



Şekil 36. Normal Doğuma Ait Öznitelik Değerleri

Bu grafikler incelendiğinde erken doğuma ait özniteliklerde 3' üncü ve 6' ncı özniteliklerin ayırt edici olduğu görülmektedir. Erken doğum ile normal doğum öznitelik değerleri karşılaştırıldığında 6' ncı öznitelik değerlerinin farklı oranda değişim gösterdiği gözlemsel olarak söylenebilir. Ayrıca 4' üncü öznitelikten 5' inciye geçişte erken doğum verilerinde artış görülürken normal doğum verilerinde azalış olduğu görülmektedir. Zaman öznitelik değişimleri farklı kanallar üzerinde de incelenmiştir. İnceleme sonucunda birinci kanaldan elde edilen sonuçlara benzer sonuçlar elde edilmiştir. Bu çalışmanın devamında 34, 35 ve 36' ncı haftaya ait olan erken doğum hamilelik ve normal doğum hamilelik sinyallerinde meydana gelen değişikliği analiz edebilmek için bu haftalarda meydana gelen her iki sınıfa ait çeşitli kasılmaların öznitelik değerleri karşılaştırılmıştır. Şekil 37' de yer alan grafikte sonuçlar yer almaktadır. Bu grafiğe göre erken doğum ve normal doğuma ait 6' ncı öznitelik değerleri arasındaki fark değeri 34' üncü haftadan 36' ncı haftaya gelene kadar azalmaktadır.



Şekil 37. Haftalara Göre Öznitelik Değerleri

Bu sonuçlara dayanarak, erken doğum ile sonuçlanan ve normal doğum ile sonuçlanan hamilelik sinyallerine ait kasılmaların 4, 6 ve 12' nci öznitelikleri çıkartılarak iki sınıfa ait veriler kullanılmıştır. Bu öznitelikler sırasıyla, sıfırdan geçiş oranı, Güç Yoğunluk Fonksiyonunun Tepe Genliği ve ortalamadır. Bu kez elde edilen genel doğruluk oranı %93.5, erken doğum sınıfına ait genel doğruluk oranı %87.5 olarak elde edilmiştir.





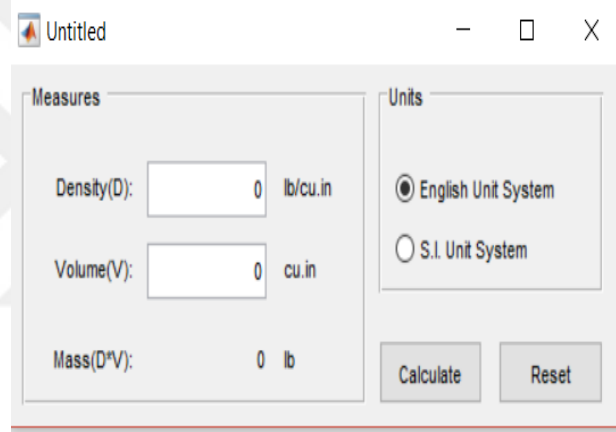
## 6. MATLAB'TA SINYAL İŞLEME VE ANALIZI İÇİN GRAFİKSEL KULLANICI ARAYÜZÜ (GUI)

EMG sinyallerini analiz etmek ve analiz sonuçlarını gözlemleyebilmek için Matlab'ta sinyal analiz arayüzü oluşturuldu. Arayüzün anlatımına geçmeden önce Matlab'ta GUI araç çubuğu ve detayları verilmiştir. GUI' nin açılımı Graphical User Interface 'dir.

### 6.1. Giriş

Uygulamada bulunan nesnelerin kullanılması veya kullanıcı ile program arasında etkileşim sağlayan grafiksel programlama arayüzüdür.

Radyo butonları, kaydırıcılar, grafikler, değişken kutucukları GUI nesnelere aittir. Şekil 38' de yoğunluk ve hacmi girilen bir cismin kütlesini hesaplamaya yarayan örnek bir arayüz yer alıyor.




Şekil 38. Örnek Matlab Arayüzü

### 6.2. Matlab Ortamında Arayüz Oluşturma


“Guide” araç çubuğu ile kullanıcı kolaylıkla arayüz oluşturabilir. Arayüze, yapılacak çalışmanın gereğine göre arayüz nesnelere eklenir ve nesnelerin görsel özellikleri bu araç ile daha hızlı ve kolay değiştirilebilir.

Komut satırına “*guide*” girilerek Şekil 39' da görüldüğü gibi GUIDE aracı çağrılır. Örnek arayüz uygulamaları ile yeni arayüz için boş arayüz taslağı yer almaktadır. Yeni arayüz tasarımı için Blank GUI seçeneği seçilir.



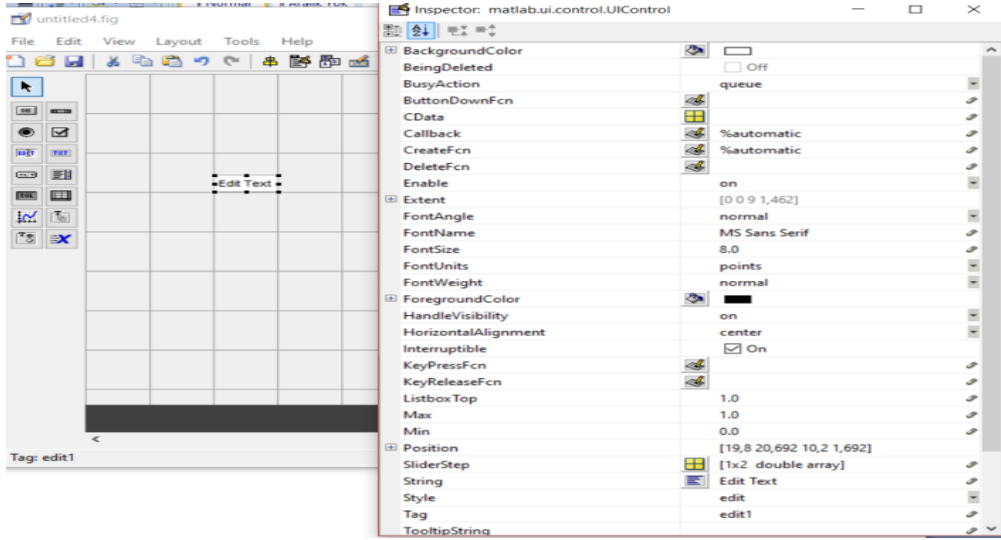
**Şekil 39.** Matlab'ta GUIDE Aracı

Açılan sayfaya arayüzde olması istenen arayüz nesneleri Şekil 39' da görüldüğü sürükleyip bırak işlemi ile eklenir.



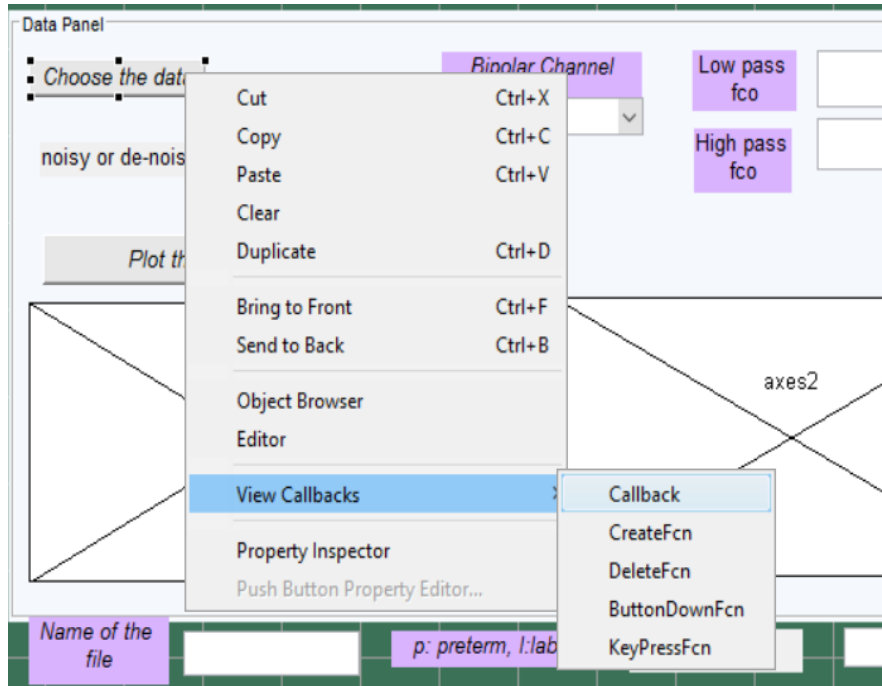
**Şekil 40.** Nesneleri Arayüze Ekleme

Buraya eklenen nesnelere görsel, boyut veya konumunda istenildiği gibi değişiklik yapılabilir. Şekil 41' de görüldüğü gibi nesnelere istenilen değişiklikler yapılabilmektedir. Çalışma alanının boyutunda ve renginde de değişiklik yapmak mümkündür.



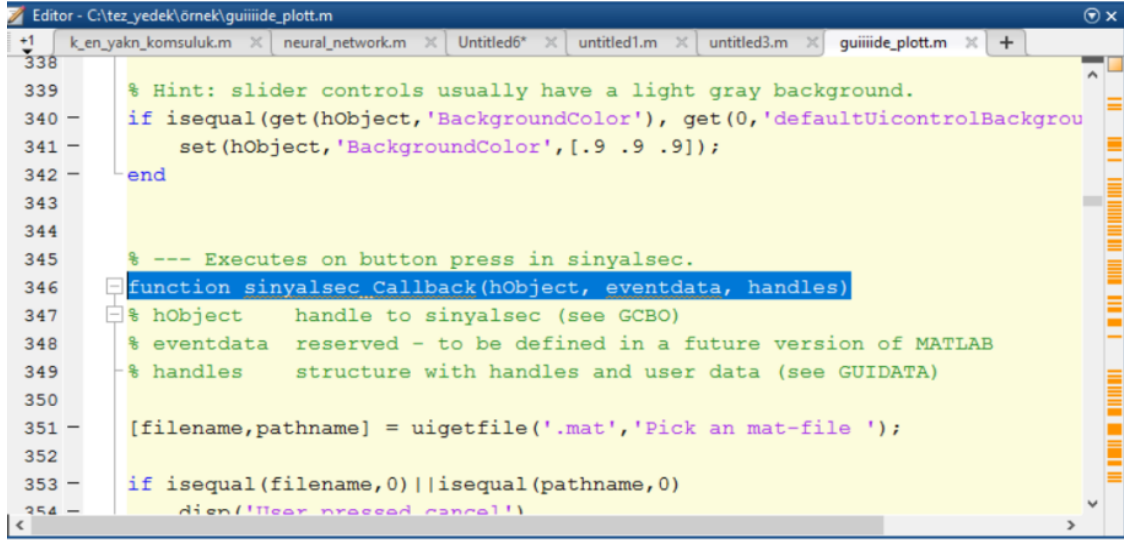
Şekil 41. Nesneleri Görselleştirme

Arayüze dışarıdan veriyi eklemek için 'Choosethedata' butonu kullanılır. Bu buton ile arayüze veri aktarılır. Veri aktarıldıktan sonra filtreleme ve gürültüden kurtulma işlemleri için veri panelinde 'Edittest' nesnesi ile 'slider' nesnesi yer almaktadır. Kullanıcı tarafından belirlenebilen parametreler arayüze bu nesnelere yardımıyla eklenir. Arayüze eklenen nesnelere bittikten sonra her nesne birbirinden bağımsız olarak programlanır. Şekil 42'de görüldüğü gibi arayüzden fonksiyon çağrılır. Arayüzün programlaması için 'ViewCallbacks/Callback' seçenekleri ile nesnenin fonksiyonuna ulaşılır. Her nesnenin ayrı fonksiyonu vardır. Bu ayrı fonksiyonlar kullanılarak arayüzdeki nesnelere programlanır.



Şekil 42. Arayüzden Programlamaya Geçiş

Şekil 43' te seçilen nesnenin fonksiyonu verilmiştir.



```
338
339 % Hint: slider controls usually have a light gray background.
340 if isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgrou
341     set(hObject,'BackgroundColor',[.9 .9 .9]);
342 end
343
344
345 % --- Executes on button press in sinyalsec.
346 function sinyalsec_Callback(hObject, eventdata, handles)
347 % hObject     handle to sinyalsec (see GCBO)
348 % eventdata   reserved - to be defined in a future version of MATLAB
349 % handles     structure with handles and user data (see GUIDATA)
350
351 [filename,pathname] = uigetfile('.mat','Pick an mat-file ');
352
353 if isequal(filename,0)||isequal(pathname,0)
354     disp('User pressed cancel!')
```

Şekil 43. Seçilen Nesnenin Fonksiyonu

Arayüz kullanıcı ile program arasında bir geçiştir. Değişkenlere göre farklı sonuçları incelemek daha kolay olacağı için yapılan analizleri yapabilmek ve sonuçlarını gözlemleyebilmek oldukça kolaydır.


### 6.3. EMG Sinyal İşleme ve Analiz Arayüzü

Oluşturulan arayüz analizin çeşidine göre panellere ayrılmıştır. Arayüz paneli Şekil 44' te verilmiştir. Veri paneli, enerji paneli, ilinti paneli, kasılma etiketleme paneli, dipnot paneli ve spektral analize geçiş gibi kısımlara ayrılmıştır. Bu paneller ve açıklamalı anlatımları sırasıyla verilmiştir.


Arayüzde bulunan her bir panel ile ilgili bilgi verilmiştir. İlk olarak Şekil 45' te veri paneli yer almaktadır.

#### 6.3.1. Veri Paneli

Veri panelinde ; veri seçme, bipolar kanal seçimi, band geçirgen filtre için kesim frekans değerleri, gürültü azaltma seçeneği ve bipolar sinyalin filtrelenmiş sonucunu gösteren figürler yer almaktadır. 'noisy or de-noised' seçeneğinde 'de-noised' seçilirse Dalgacık Paket Dönüşümü Eşik Değer Yöntemi ile gürültü azaltma işlemi uygulanır. Eğer 'noisy' seçilirse bipolar sinyale hiç bir işlem uygulanmadan filtreleme işlemi yapılır.




Şekil 44. Sinyal Analiz Arayüzü



Şekil 45. Veri Paneli

Filtreleme işlemi için kesim frekans değerlerinin girilmesi gerekmektedir. 0,1 - 3 Hz frekans aralığını geçiren band geçiren filtre uygulanmak istenirse "Low pass fco" ve "High pass fco" kutucuklarına sırasıyla 3 Hz ve 0,1 Hz girilir. "Bipolar Channel" seçeneğinden bipolar kanal seçimi yapılır. 12 adet bipolar kanal bulunmaktadır. 16 monopolar kanalların düşey olarak iki sinyallerin farkı alınarak bipolar sinyaller elde edilmiştir. "Name of file" kutucuğuna analiz için seçilen sinyalin adı yer almaktadır. Şekil 46'da "ice045\_p\_4of4m.mat" üzerine EMG sinyalinin 2. bipolar kanalından alınan sinyalin önce Dalgacık Dönüşümü Eşik Değer Yöntemi ile gürültüsü azaltılmıştır.

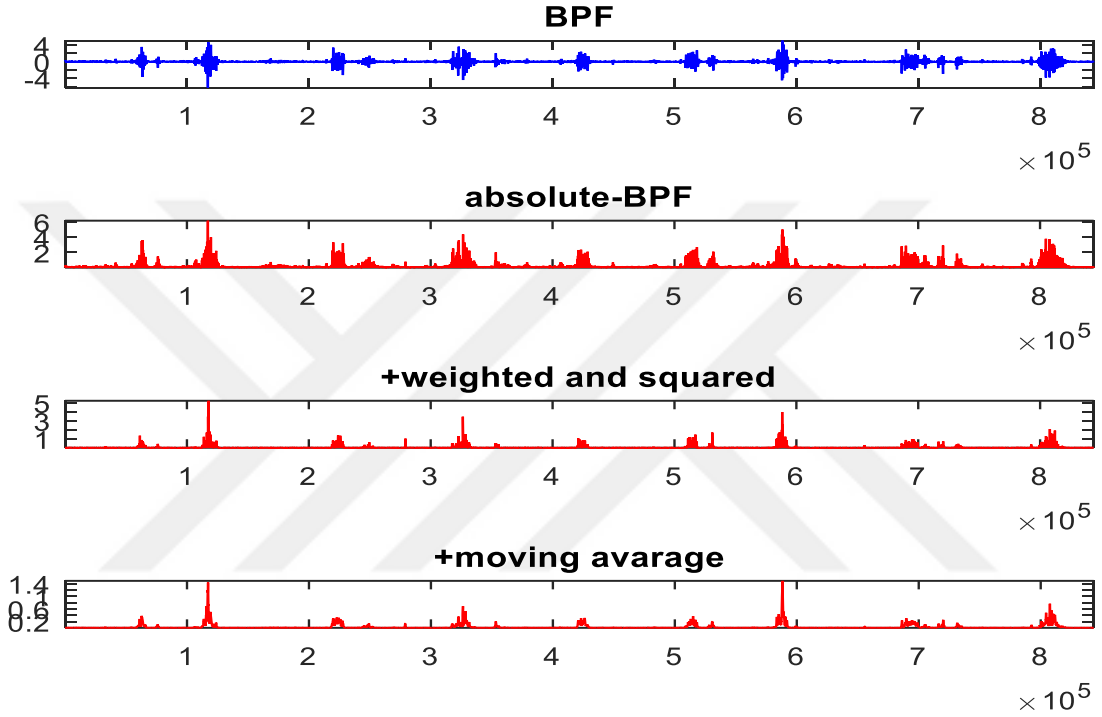


**Şekil 46.** EMG Sinyalin Arayüze Aktarılması

Arayüze girilen kesim frekansı değerlerine göre bant geçiren filtre uygulanmıştır. Gürültü yok etme ve filtreleme sonucu elde edilen sinyaller arayüzde bulunan figürlerde çizdirilmektedir.


"p:preterm ,l:labour" bilgisi analiz edilen sinyalin adında geçer. EMG sinyalinin doğum (l:labour) veya hamilelik (p:pregnancy) olduğunu göstermektedir. "Enter length" kutucuğu sinyalin sadece bir kısmı analiz edilmek istendiğinde verinin uzunluğunun girildiği kutucuktur. Bu kısım bazı sinyallerin analizinde gerekli olabilmektedir. Genelde hamilelik

sinyalleri 1 saat ve üzeri kayıtlardır. Bu sinyaller 200 Hz örnekleme frekansı ile kayıt edilmiştir. Veri kaybından kaçınmak için tekrar örneklenmemesi sonucu verinin analizi dakikaları almaktadır. Bu nedenle kullanıcı bu sinyallerin sadece bir kısmını analiz etmek istediğinde buraya uzunluk bilgisini girmesi yeterli olacaktır. "Plot Signals" butonu bunların yanında başka çizimler de vermektedir. Filtrelenen sinyale uygulanan kasılma etiketleme algoritması olarak uygulanan Ahlstrom&Tompkins QRS belirleme algoritması uygulanır. Şekil 47' de algoritmanın her adımında elde edilen sinyal birlikte verilmektedir.




**Şekil 47.** Kasılma Etiketleme için Uygulanan Algoritma 2 sonucu

Bu algoritma ile ilgili detaylı bilgi önceki bölümde detaylı olarak açıklanmıştır. Veri panelinde sinyalin analiz edildiği bir başka yöntem ise *Teager Enerji Operatörü* 'dür. Uygulanan bu algoritma yine sinyal üzerinde EMG sinyalinin normal durumda olmadığını gösteren bölgeleri (kasılma, foetal hareketlenme) belirlemeye yönelik bir algoritmadır. Dalgacık Dönüşümü-Teager Enerji panelinde bu yöntem sonuçlarını detaylı görmek mümkündür. Şekil 48' de algoritma 2 sonucunda elde edilen sinyalin Teager Enerjisi yer almaktadır.



**Şekil 48.** Teager Enerji Analiz Sonucu

Veri paneli diğer panellerin bilgi ve verisine ulaşarak bir başka çizim sonucunu daha kullanıcıya vermektedir. Şekil 49' da verilen *Annotation Paneli* 'den sinyal üzerinde uzman doktorlar ve kayıt sırasında gözlemlenen veriler ışığında sinyale ait önemli olayların kayıtları veri paneline aktarılarak filtrelenmiş ve kasılma belirleme algoritması uygulanan sinyal üzerine çizdirilmiştir.




**Şekil 49.** Dipnot Bilgileri fm: foetal hareket, C: kasılma

### 6.3.2. Enerji Paneli

Sinyal filtrelendikten sonra enerji analizi için kullanılan paneldir. Enerji panelinde yer alan “*Width of Window*” kutucuğu , sinyalin enerjisi hesaplanırken kullanılan pencerenin boyutunu ifade eder. Şekil 50' deki figürde görülen sinyal filtrelenmiş sinyalin 100 örnek için enerjisini göstermektedir.




Enerji panelinde bulunan bir diğere önemli grafik sonucu ise bipolar kanalların enerjisidir. Pencere boyutu belirlendikten sonra arayüz nesnesi olan "slider" ile zaman ekseninde ilerleyerek tüm bipolar kanalların enerjisini gösterir. Grafikte 3x4 matris olarak bipolar enerji kanalları 4x4 monopolar sinyallerden elde edilmiştir. Bu enerji matrisinde açık sarıdan koyu maviye doğru enerji azalmaktadır. Şekil 50' de yer alan enerji matrisi incelenirse 9' uncu bipolar kanalda en yüksek, 4' üncü kanalda ise en düşük enerji olduğu görülmektedir. Enerji matrisi zaman ilerledikçe değişmektedir. Bu şekilde kullanıcı ölçüm süresi boyunca rahim bölgesindeki enerji değişimi konusunda bilgi sahibi olabilecektir.



Şekil 50. Enerji Paneli

### 6.3.3. İlinti Paneli

Korelasyon panelinde enerji panelinde olduğu gibi seçilen kanalın ilintisini ve bipolar kanalların birbiri ile olan ilintisini incelenmektedir. Şekil 51' de korelasyon paneli verilmiştir.



**Şekil 51.** Korelasyon Paneli

Her kanalın kaydırma butonu değerine göre ilinti değerleri ve bu değerlere karşılık oluşturulan renk matrisi görülmektedir. Korelasyon değerleri en büyük değer açık sarıdan en küçük değer olan koyu maviye dağılım göstermektedir.

#### 6.3.4. Dipnot Paneli

Veri setinde bulunan sinyallerin uzman doktorlar ve sinyalin kaydı sırasında sinyal üzerindeki önemli olayların kaydına “*annotation*” yani dipnot denir. İzlanda veri setinin kayıtları sırasında bireyin hissettiği kasılma, bebeğin hareketi, pozisyon değişikliği gibi olaylar kaydedilmiştir. Sonraki aşamada Takograf cihazının kayıtları da uzmanlar tarafından incelenmiş ve EMG sinyalleri ile karşılaştırılmıştır. Karşılaştırma sonucu sinyal üzerindeki önemli olaylardan Takograf kayıtlarında da olanlar dipnot bilgisi olarak eklenmiştir [7]. Şekil 52' de verilen panelde analiz edilen sinyalin bilgileri verilmiştir.

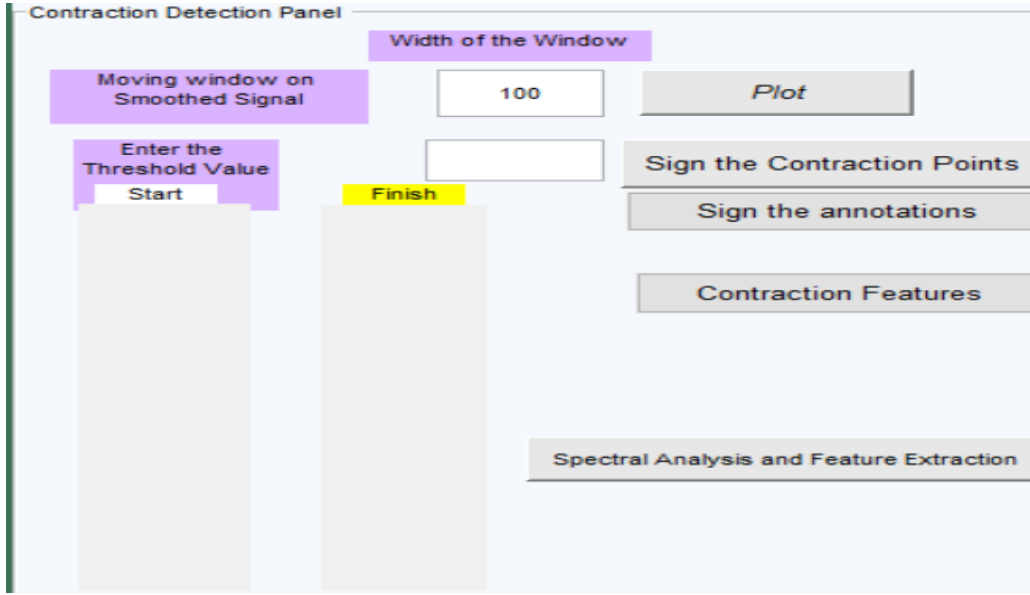
Annotation Panel	
Annotation Records	
60067	C
106020	fm
108002	C
216066	C
322073	fm
324029	C
418043	fm
420050	C
514051	fm
516033	C
574067	fm
576049	C
682030	fm
684012	C
804019	C

C - Contraction  
(c) - Possible contraction  
pm - Participant movement  
pos - Participant change of position  
em - Equipment manipulation  
fm - Foetal movement.


Şekil 52. Dipnot Paneli

### 6.3.5. Kasılma Belirleme Paneli

Veri panelinde elde edilen grafiklerden birisi uygulanan “*moving-squared*” algoritmasının adım adım uygulanması ve elde edilen sonuçlarıdır. Şekil 47' deki grafikte en altta bulunan sinyal ile birlikte filtrelenmiş sinyal de bu panele aktarılır. Enerji panelinde olduğu gibi sinyalin alanı için örnek sayısının girilmesi gerekmektedir. Sinyalin alanın grafiği "Plot" butonu ile elde edilir. Şekil 53'de verilen panelde alan hesaplanmasının sebebi kasılma gibi önemli olayların başlama ve bitiş noktalarının belirlenmesi için uygulanan bu algorithmada, önemli iki nokta arasındaki salınımları azaltmak ve bu bölgeleri daha belirgin hale getirmektir. Algoritma sonucunda kasılma gibi önemli olayların başlama ve bitiş noktaları eşik değeri yöntemi ile belirlenir. Kullanıcı bu eşik değeri grafikleri görsel olarak analiz edip uygun bir değeri girebileceği gibi hiç bir değeri girmediği durumda da varsayılan eşik değeri, alan sinyalinin ortalamasının 0,85 değeri ile çarpılmış sonucudur. Bu değeri arayüz oluşturulurken girilen değerler ve alınan deneysel sonuçlara bağlı olarak belirlenmiştir. Bu panelde belirlenen önemli başlama ve bitiş noktaları panelde ilgili yere yazdırılır. Ayrıca sinyal üzerinde de işaretlenir. Şekil 54' te bu noktalar sinyal üzerinde işaretlenmiştir. Kullanıcı isterse dipnot panelinden annotation noktalarını bu panele aktararak aynı grafik üzerine o noktaları da çizdirebilir. Bu şekilde algoritma ile belirlenen önemli olayların kaç tanesinin doğru tespit olduğunu görebilir.



Şekil 53. Kasılma Paneli




Şekil 54. Başlangıç (\*) ve Bitiş (o) Noktaları

Bu analiz sonuçlarının *annotation* noktaları karşılaştırılmak istenildiğinde Dipnot panelinden alınan değerler birlikte çizdirilir. Şekil 55' de görüldüğü gibi sonuçlar karşılaştırılabilir.

Veri panelinde yer alan veri uzunluk değeri 680000 girildiği için sonraki veriler analiz edilmemiştir. Başlama ve bitiş noktaları ekranda *start* ve *finish* başlıklarının altına kaydedilir.


Bu panelde frekans ve öznelilik analizi için *Spektral Analysis and Feature Extraction* butonu kullanılarak bir başka arayüze geçilir.



Şekil 55. Algoritma Sonuçları ile Dipnot Değerleri

#### 6.4. Spektral Analiz ve Öznitelik Çıkarma Arayüzü


Arayüzde bulunan paneller yardımı ile filtrelenmiş sinyalinin frekans ve Dalgacık Dönüşümü analizi yapılabilir. Şekil 56’da görüldüğü gibi bu arayüzde spektral yoğunluk analiz, öznitelik çıkarma, Dalgacık Dönüşümü panelleri bulunur.



Şekil 56. Spektral Analiz ve Öznitelik Çıkarma Arayüzü

#### 6.4.1. Yoğunluk Analiz Paneli

Bu panelde yer alan Güç Spektral Yoğunluk Fonksiyonu ve Fourier Dönüşümü fonksiyonu analizi butonları mevcuttur. Bu dönüşümler için diğer arayüzden filtrelenmiş sinyal bu arayüze aktarılır. Bu panelde hızlı Fourier Dönüşümü ve Güç Spektral Yoğunluk Fonksiyonları incelenebilir. Şekil 57' de verilen grafiklerde Güç Yoğunluk Foksiyonu ile Hızlı Fourier Dönüşümü verilmiştir.



Şekil 57. Hızlı Fourier Dönüşümü ve Güç Spektral Yoğunluk Fonksiyonu

#### 6.4.2. Öznitelik Çıkarımı Paneli

Bu panelde öznitelik çıkarımı yapılır. Algoritmanın belirlediği aralıklardan istenilen aralığın öznitelik değerleri hesaplanır. Şekil 58' de öznitelik paneli verilmiştir. İstenilen değerlerden ayrı olarak tüm öznitelikler hesaplanarak çalışma alanına kaydedilir. Bu panel yardımıyla kullanıcı doğrusal ve doğrusal olmayan özniteliklerin analizini de yapabilmektedir.

The screenshot shows a software interface for feature extraction. It has a title bar 'Feature Extraction'. Below the title bar, there is a section for entering start and finish points of the contraction, with 'start' and 'finish' labels and input boxes. To the right of this section is a button labeled 'Record All Features As a Matrix'. Below this, there are two sections for feature extraction: 'Linear Feature' and 'Nonlinear Feature'. Each section has a dropdown menu for selecting a feature type. The 'Linear Feature' dropdown is currently set to 'MeanFrequ...' and has a 'Calculate' button next to it. The 'Nonlinear Feature' dropdown is currently set to 'MeanFrequency' and also has a 'Calculate' button next to it. A 'Record All Features As a Matrix' button is also present at the bottom right of the panel.

Şekil 58. Öznitelik Paneli

Sinyali zaman ve frekans bölgesinde analiz etmek amacıyla Dalgacık Dönüşümü incelemesi yapılmıştır. Frekans bölgesi analizi için durağan sinyallere uygulanan Fourier Dönüşümü sinyal durağan değilse sorun haline gelmektedir. Dalgacık Dönüşümü hem zaman hem frekans bölgesinde analiz için çok faydalı bir yöntemdir.

### 6.4.3. Dalgacık Dönüşümü Paneli


Dalgacık dönüşümü panelinde bulunan arayüz nesneleri yardımıyla bu analizi kolaylıkla yapmak mümkündür. Kullanıcı Şekil 59' da görüldüğü gibi istenilen dalgacık fonksiyonunu seçerek fonksiyonu analiz edebilmektedir.

The image shows two panels from a software interface. The top panel, titled "Wavelet Transform Panel", contains a dropdown menu for "Wavelet Name" set to "haar", a text input for "Wavelet Dec. Level", and a button labeled "Discrete Wavelet Transform (one st...)". Below this is a button "Wave. Dec. of given level" and another button "approximation and detail plot" next to a text input labeled "Enter level of app. and detail.". The bottom panel, titled "Wavelet Packet Analysis", features a button "wavelet Packet", a text input for "packet level", and a button "Short-Time Fourier Transform". Below these is a button "Chosen Packet Coeffs." and a text input labeled "Enter Coeff as a vector ([a b])".

Şekil 59. Dalgacık Dönüşümü Paneli


Dalgacık Dönüşümü panelinde sinyalin kesikli olarak dalgacık dönüşümü yapılır. Dalgacık Dönüşümü için kullanılacak olan temel dalgacık fonksiyonları panelden seçilir. *Wavelet Name* nesnesi altında Matlab'ın kullandığı bu fonksiyonlardan bulunmaktadır. Bu fonksiyonlardan istenilen fonksiyon kullanılarak Dalgacık Dönüşümü yapabilmek mümkündür.

Dalgacık Dönüşümü katsayıları kullanılarak öznelik çıkarımı yapabilmek mümkündür. Şekil 60' da görüldüğü gibi Kesikli Dalgacık Dönüşümü yapmak için seçilen ana fonksiyon kullanılır.



Şekil 60. Temel Dalgacık Dönüşümü Fonksiyonları


Böylece bu kısımda sinyalin tek adım Dalgacık Dönüşümü elde edilir. Eğer daha yüksek seviyeden dalgacık dönüşümü yapılmak istenirse; istenilen seviye belirlenip arayüzde *WaveletDec. Level* adlı boşluğa girilir. Bu seviyeden elde edilen *yaklaşım* ve *detay* katsayıları incelemek için çizdirilebilir. Şekil 61' de verilen grafikte sinyalin birinci seviyeden elde edilen detay ve yaklaşım katsayıları yer almaktadır.




Şekil 61. Dalgacık Dönüşümü Katsayıları ve sinyalin tekrar elde edilmesi



Sinyal Ters Dalgacık Dönüşümü ile elde edildiğinde orijinal sinyal ile arasında bir miktar kayıp söz konusudur. Orijinal sinyal, sentez ve fark sinyali aşağıda yer almaktadır. Verilen şekilde sinyal önce katsayılarına ayrılıp daha sonra tekrar oluşturulmuştur. Arayüzde bulunan bir başka analiz sinyalin daha yüksek seviyelerde Dalgacık Dönüşümü uygulanmasıdır. Uygulama sonunda elde edilen yaklaşım ve detay katsayıları Şekil 62 ve 63' te verilen grafiklerde de görüldüğü gibi analiz yapabilmek mümkündür.




**Şekil 62.** Dalgacık Dönüşümü ile Sinyalin Sentezi ve Fark Sinyali



2. seviye

3. seviye



4. seviye

5. seviye

**Şekil 63.** Dalgacık Dönüşümü Ayrışım ve Yaklaşım katsayıları

Dalgacık Paket Dönüşümü analizi için dönüşüm seviyesine göre analiz yapılır. Arayüz yardımı ile istenilen seviyeden sinyalin Dalgacık ve Dalgacık Paket Dönüşümünü elde etmek mümkündür.

## 7. SONUÇLAR

Erken doğum insan hayatını kötü yönde etkileyen bir sağlık problemidir. Erken doğum riski taşıyan annenin doğumdan sonra hastanede kalması ve bebeğe ve anneye tedavinin özenli uygulanması gerekmektedir. Ayrıca bu bebeklerde ilerleyen yaşlarda normal zamanında doğmuş bebeklere göre daha fazla sağlık problemlerinin görülme olasılığı görmezden gelinmeyecek kadar yüksektir. İnsan hayatı söz konusu olduğu için bu sorunu önceden kestirebilmek gelecekte veya doğumdan hemen sonra kalıcı veya kalıcı olmayan pek çok soruna çözüm olacaktır.

Erken doğumkestirimi için günümüze kadar uygulanan yöntemler arasından EMG sinyalleri kullanım kolaylığı ve kestirim doğruluğu bakımından daha avantajlıdır. Cerrahi herhangi bir müdahale gerektirmeyen EMG sinyalleri ile erken doğum kestirimi son yıllarda kullanılmaya başlanmıştır. EMG sinyallerinin kullanım kolaylığı ve daha güvenilir sonuçlar vermesinden dolayı bu çalışmada erken doğum kestirimi için EMG yöntemi kullanılmıştır. Kullanılan EMG sinyalleri internette ulaşılabilen iki farklı rahim EMG veri setinden seçilmiştir. Bu veri setleri farklı elektrot dizilimleri kullanılarak elde edilmiştir. 4 ve 16 elektrot kullanılarak kaydedilen veri setlerinden 16 elektrotlu veri seti kullanılmıştır. Bu veri setinde normal doğum, normal doğum ile sonuçlanan hamilelik, erken doğum ile sonuçlanan hamilelik sinyalleri yer almaktadır. Bu veri setinde bulunan sinyallerin dipnot bilgileri kullanılarak rahimden kaynaklanan kasılma, bebek hareketi ve muhtemel kasılma olayları içinden kasılma olayı diğer olaylardan ayırt edilmiştir. Bu sınıflandırma işlemi için belirlenecek iki temel seçim bulunmaktadır. Bu iki önemli seçim sınıflandırıcı ve öznelik belirlemedir. Kapsamlı bir kaynak taramasından sonra yapılan çıkarım ve deneysel sonuçlara dayanarak sınıflandırıcı ve öznelikler belirlenmiştir. Rahim EMG sinyallerinin doğrusal ve durağan olmayan yapısı göz önünde bulundurularak çalışmanın ilk kısmında doğrusal olmayan sınıflandırıcı olan yapay sinir ağları ve en temel doğrusal sınıflandırıcılardan biri olan en yakın uzaklık sınıflandırıcı ile sınıflandırma yapılmış ve karşılaştırılmıştır. Beklenildiği gibi doğrusal olan sınıflandırıcı daha düşük performans göstermiştir. Bu düşük performans değeri doğrusal olmayan bir iyileştirme yöntemi kullanılarak iyileştirilmeye çalışılmıştır. Uygulanan iyileştirme algoritması ile performans yükseltilmiştir. Doğrusal olmayan sınıflandırıcı kullanılarak elde edilen genel sınıflandırıcı performansı %79.2 ve önemli sınıf olarak belirlenen kasılma sınıfına ait doğruluk oranı ise %86.4 olarak elde edilmiştir. Doğrusal olmayan sınıflandırıcı olarak ileri beslemeli yapay sinir ağları kullanılmıştır. Yapay sinir ağının parametrelerini belirlemek ve en iyi

performans sonuçlarına ulaşmak amacıyla deneysel çalışmalar yapılmıştır. Bu çalışmalar sonucu en iyi sonuçları veren öğrenme algoritması, nöron sayısı, transfer fonksiyonu, katman sayısı, öğrenme adımı gibi parametrelere ulaşılmıştır. İki katmanlı ileri beslemeli yapay sinir ağında 20 tane nöron kullanılmıştır. Transfer fonksiyonu olarak logaritmik-sigmoid fonksiyonu, öğrenme algoritması olarak geriye yayılım algoritması kullanılmıştır. Bu algoritma klasik geriye yayılım algoritmasından daha hızlı sonuç veren bir algoritmadır. Öznitelikler normalize edilerek ağı eğitimi yapılmıştır.

Doğrusal sınıflandırıcının performansı ise %65 olup söz edilen iyileştirme sonucu ise performans yükselerek %70 değerine ulaşmıştır. Kullanılan sınıflandırıcıda uzaklık metriği olarak Öklid uzaklık parametresi kullanılmıştır. Çalışmanın ilk aşaması olan bu kısımda bu sonuçlar 1' inci bipolar kanal üzerinden alınmıştır. Kanallar üzerinde farklılığı değerlendirmek için diğer 11 kanal için de sınıflandırma sonuçlarına bakılmıştır. 1' inci ve 12' nci kanallar en yüksek performans değerlerini vermiştir. Böylece çalışmanın ilk aşamasında veri setinde bulunan hamilelik, erken doğum ve normal doğum sinyalleri üzerinde yapılan çalışmalarda sinyallerin üzerinde meydana gelen rahimden kaynaklı önemli olaylar arasından kasılma olayı diğer olaylardan (bebek hareketi, muhtemel kasılma) yapay sinir ağı kullanılarak ayırt edilmiştir. Kasılma olayının ne zaman gerçekleştiğini tespit etmek demek erken doğum kestirimi yapabilmenin bir diğer yoludur. Yani kasılma olayının erken doğum veya normal doğum hamilelik dönemlerine ait olduğunu kestirmek erken doğum kestirimi için önemli bir adımdır.

Kasılma olayının hangi sınıfa ait olduğunu tespit edebilmek amacıyla çalışmanın ikinci aşamasını oluşturan bu kısımda ikinci kez ileri beslemeli yapay sinir ağı kullanılarak erken doğuma ait kasılmalar diğer kasılmalardan yüksek performansta sınıflandırılmıştır. Kullanılan ağı özellikleri önceki sinir ağının özellikleri ile aynı olarak belirlenmiştir. Erken doğum ve normal doğum ile sonuçlanan hamilelik sinyallerinde ve normal doğum anında meydana gelen kasılmalar ileri beslemeli yapay sinir ağı kullanılarak sınıflandırılmıştır. Sınıflandırmada 3 sınıfın (erken doğum ve normal doğum hamilelik kasılmaları, normal doğum kasılmaları) genel doğruluk oranı %82.6 erken doğum sınıfının doğruluk oranı ise %75 olarak elde edilmiştir. Veri setinin daha kapsamlı olması durumunda elde edilen performans sonuçları daha da iyileşecektir. Elde edilen bu sonuçlar 1' inci bipolar kanal üzerinden alınan sonuçlardır. İlk kısımda olduğu gibi bu kısımda da diğer kanalların doğruluk performansına etkisi üzerinde durulmuştur. Buna göre 12 bipolar kanal arasından en iyi sonuçları 2, 4, 7 ve 12' nci kanallar vermiştir. Bu şekilde

sınıflandırma performansının rahim yüzeyindeki bölgelere göre nasıl değiştiği gözlemlenmiştir.

Sınıflandırma performansının en iyi değere ulaşabilmesi için kullanılan yapay sinir ağı çeşidi ve özelliklerinin yanında enaz bu kadar önemli olan parametre de seçilen özneliklerdir. Bu öznelikler kaynak taramasında elde edilen bulgulara göre seçilmiştir. Buna ek olarak seçilen öznelik değerlerinin farklı kasılma türlerine göre değişiminin önemi araştırılmıştır. Böylece normal doğum ve erken doğum ile sonuçlanan hamilelik kasılmalarının öznelik değişimleri karşılaştırılarak zaman-öznelik değişimi incelenmiştir.

Bu çalışmalara ek olarak Matlab ortamında sinyal işleme ve analiz arayüzü oluşturulmuştur. Bu arayüzde sinyal ön işleme işlemleri, filtreleme, otomatik kasılma tespiti için uygulanan algoritmalar, algoritma sonuçlarının dipnot verileri ile karşılaştırılması, spektral analiz ve öznelik çıkarımı, dalgacık dönüşümü işlemleri yapabilmek mümkündür. Bu arayüzün ileride gerçekleşecek sinyal işleme çalışmalarına da faydalı olacağı düşünülmektedir.

Sonuç olarak erken doğumun kestirimi ileri beslemeli yapay sinir ağları ile yüksek performansta yapılmıştır. Elde edilen sonuçların performansının veri setinin daha kapsamlı olarak arttırılması ile daha da iyi bir seviyeye ulaşacağı düşünülmektedir.

## KAYNAKÇA

- [1] U. Crisis and H. Care, "Preterm Birth: Causes, Consequences and Prevention" , *Institute of Medicine*, pp. 1–4, February, **2009**.
- [2] K. Lindström, "Long-term Consequences of Preterm Birth: Swedish National Cohort Studies," *Karolinska Institutet*, **2011**.
- [3] R. E. Garfield, M. Lucovnik, and R. J. Kuon, "Diagnosis and Effective Management of Preterm Labor," *MGM Journal Medicine Science*, Vol.1, pp. 22–27, **2014** .
- [4] M. L, Z. Ovak, and E. G, "Use of Non-invasive Uterine Electromyography in the Diagnosis of Preterm Labour," *Facts, Views & Vision in Obstetrical & Gynecology*, pp. 38–44, **2012**.
- [5] B. Moslem, M.O. Diab, C. Marque, M. Khalil, "Classification of Multichannel Uterine EMG Signals," *33<sup>rd</sup> Annual International Conference of the IEEE*, pp. 2602–2605, **2011**.
- [6] W. L. Maner and R. E. Garfield, "Identification Of Human Term And Preterm Labor Using Artificial Neural Networks On Uterine Electromyography Data," *Annals of Biomedical Engineering*, vol. 35, no. 3, pp. 465–473, **2007**.
- [7] A. Alexandersson, T. Steingrimsdottir, J. Terrien, C. Marque, and B. Karlsson, "The Icelandic 16-electrode electrohysterogram database," *Nature Scientific Data*, vol. 2, no. April, p. 150017, **2015**.
- [8] K. Lim *et al.*, "Ultrasonographic Cervical Length Assessment in Predicting Preterm Birth in Singleton Pregnancies," *Journal of Obstetrics and Gynaecology Canada*, vol. 33, no. 5, pp. 486–499, **2011**.
- [9] M. Hassan, "Analysis of the Propagation of Uterine Electrical Activity Applied To Predict Preterm Labor," Phd. Thesis, Reykjavik University, France, **2015**.
- [10] G. Fele-Žorž, G. Kavšek, Ž. Novak-Antolič, and F. Jager, "A Comparison Of Various Linear And Non-Linear Signal Processing Techniques To Separate Uterine EMG Records Of Term And Pre-Term Delivery Groups," *Medical and Biological Engineering Computing*, vol. 46, no. 9, pp. 911–922, **2008**.
- [11] Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JF, Moody GB, Peng C-K, Stanley HE. PhysioBank, physioToolkit, and Physionet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101 (23):e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/cgi/content/full/101/23/e215>] **2000** (June 13)

- [12] B. Moslem and M. Khalil, "Combining Multiple Support Vector Machines for Boosting the Classification Accuracy of Uterine EMG Signals," *2011 18th IEEE International Conference on Electronics, Circuits, and Systems, ICECS*, pp. 631–634, **2011**.
- [13] B. Moslem, M. Khalil, C. Marque, and M. O. Diab, "Energy Distribution Analysis of Uterine Electromyography Signals," *Journal of Medical and Biological Engineering*, vol. 30, no. 6, pp. 361–366, **2010**.
- [14] C. Marque, J. M. G. Duchene, S. Leclercq, G. S. Panczer, and J. Chaumont, "Uterine EHG Processing for Obstetrical Monitoring," *IEEE Transactions on Biomedical Engineering*, vol. BME-33, no. 12, pp. 1182–1187, **1986**.
- [15] B. Moslem, B. Karlsson, M. O. Diab, M. Khalil, and C. Marque, "Classification Performance Of The Frequency-Related Parameters Derived From Uterine EMG Signals," *Proceedings of the Mediterranean Electrotechnical Conference EMBS*, pp. 3371–3374, **2011**.
- [16] S.-Q. Shi, W. L. Maner, L. B. Mackay, and R. E. Garfield, "Identification Of Term And Preterm Labor In Rats Using Artificial Neural Networks On Uterine Electromyography Signals.," *American Journal Of Obstetrics And Gynecology*, vol. 198, no. 2, p. 235.e1-4, **2008**.
- [17] N. Lu, J Wang, I McDermott, S. Thornton, M. Vatish and H. Randeve, "Uterine Electromyography Signal Feature Extraction and Classification", *International Journal Modelling, Identification and Control*, Vol. 6, pp. 136–146., **2008**
- [18] C. M. E. Review article, "Accuracy of Frequency-Related Parameters of the Electrohysterogram for Predicting Preterm Delivery," *Obstetrical & Gynecological Survey*, Vol. 64, no. 8, **2009**.
- [19] M. O. Diab, B. Moslem, M. Khalil, and C. Marque, "Classification of uterine EMG signals by using normalized wavelet packet energy," *Proceedings of the Mediterranean Electrotechnical Conference - MELECON*, pp. 335–338, **2012**.
- [20] S. Arora, "A Novel Scheme to Classify EHG Signal for Term and Pre-Term Pregnancy Analysis," *International Journal of Computer Applications*, vol. 51, no. 18, pp. 37–41, **2012**.
- [21] P. Fergus, P. Cheung, A. Hussain, D. Al-jumeily, C. Dobbins, and S. Iram, "Prediction of Preterm Deliveries from EHG Signals Using Machine Learning," *Plos ONE*, vol. 8, no. 10, **2013**.
- [22] M. O. Diab, C. Marque, and M. A. Khalil, "Classification for Uterine EMG Signals : Comparison Between AR Model and Statistical Classification Method," *International Journal Of Computational Cognition*, vol. 5, no. 1, pp. 8–14, **2007**.

- [23] M. Hassan, "Analysis of the Propagation of Uterine Electrical Activity Applied To Predict Preterm Labor," Phd. Thesis, Reykjavik University, France, **2015**.
- [24] F. Jager, "A Comparison Of Various Linear And Non-Linear Signal Processing Techniques To Separate Uterine EMG Records Of Term And Pre-Term Delivery Groups," *Medical and Biological Engineering and Computing*, pp. 911–922, **2008**.
- [25] S. M. Naeem, A. F. Seddik, and M. A. Eldosoky, "New Technique Based On Uterine Electromyography Nonlinearity For Preterm Delivery Detection," *Journal of Engineering and Technology Research*, vol. 6, no. 7, p. 107–114, November 2014, **2014**.
- [26] D. Alamedine, M. Khalil, and C. Marque, "Parameters Extraction And Monitoring In Uterine EMG Signals. Detection Of Preterm Deliveries," *Irbm*, vol. 34, no. 4–5, pp. 322–325, **2013**.
- [27] B. Moslem, M. Hassan, M. Khalil, C. Marque, and M. O. Diab, "Monitoring The Progress Of Pregnancy And Detecting Labor Using Uterine Electromyography," *Proceedings of the 2009 International Symposium on Bioelectronics and Bioinformatics*, pp. 160–163, **2009**.
- [28] Y. Ye-Lin, G. Prats-Boluda, J. Alberola-Rubio, J. M. Bueno Barrachina, A. Perales, and J. Garcia-Casado, "Prediction Of Labor Using Non-Invasive Laplacian EHG Recordings," *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*, vol. 2013, pp. 7428–7431, **2013**.
- [29] M. O. Diab, "Classification Of Uterine EMG Signals Using Supervised Classification Method," *Journal of Biomedical Science and Engineering*, vol. 3, no. 9, pp. 837–842, **2010**.
- [30] P. Stoica, R. L. Moses, *Spectral Analysis of Signals*, 2005, Prentice-Hall.
- [31] S. B. and K. Mahdinejad, "Preterm Birth Detection Using EMG Signal Processing" *Life Science Journal*, vol. 10, pp. 25–30, **2013**.
- [32] S. Thongpanja, A. Phinyomark, P. Phukpattaranont, and C. Limsakul, "Mean And Median Frequency Of EMG Signal To Determine Muscle Force Based On Time Dependent Power Spectrum," *Elektronika ir Elektrotechnika*, vol. 19, no. 3, pp. 51–56, **2013**.
- [33] J. Yentes, K. K. Schmid, and D. Mcgrath, "The Appropriate Use of Approximate Entropy and Sample Entropy with Short Data Sets The Appropriate Use of Approximate Entropy and Sample Entropy with Short Data Sets," *Journal Articles, Paper 44.*, October, **2013**.



- [34] J. S. Richman and J. R. Moorman, "Physiological Time-Series Analysis Using Approximate Entropy And Sample Entropy.," *American Journal Of Physiology. Heart And Circulatory Physiology*, vol. 278, no. 6, pp. H2039–H2049, **2000**.
- [35] R. E. Garfield, W. L. Maner, L. B. MacKay, D. Schlembach, and G. R. Saade, "Comparing Uterine Electromyography Activity Of Antepartum Patients Versus Term Labor Patients," *American Journal of Obstetrics and Gynecology*, vol. 193, no. 1, pp. 23–29, **2005**.
- [36] S. M. S. Baghamoradi, M. Naji, and H. Aryadoost, "Evaluation of cepstral analysis of EHG signals to prediction of preterm labor," *18th Iranian Conference on Biomedical Engineering*, pp. 81–83, December, **2011**.
- [37] B. Moslem, M. Khalil, C. Marque, and M. O. Diab, "Complexity Analysis of the Uterine Electromyography," , *Annual International Conference of the IEEE Engineering in Medicine and Biology Society* , pp. 2802–2805, **2010**.
- [38] A. Diab, M. Hassan, C. Marque, and B. Karlsson, "Quantitative Performance Analysis Of Four Methods Of Evaluating Signal Nonlinearity: Application To Uterine EMG Signals," *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 1045–1048, **2012**.
- [39] A. Diab, M. Hassan, C. Marque, and B. Karlsson, "Performance Analysis Of Four Nonlinearity Analysis Methods Using A Model With Variable Complexity And Application To Uterine EMG Signals," *Medical Engineering and Physics*, vol. 36, no. 6, pp. 761–767, **2014**.
- [40] M. Hassan, J. Terrien, C. Marque, and B. Karlsson, "Comparison Between Approximate Entropy, Correntropy And Time Reversibility: Application To Uterine Electromyogram Signals," *Medical Engineering and Physics*, vol. 33, no. 8, pp. 980–986, **2011**.
- [41] N. Pamuk, "Dinamik Sistemlerde Kaotik Zaman Dizilerinin Tespiti," *BAÜ Fen Bilimleri Enstitüsü Dergisi*, vol. 15, no. 1, pp. 77–91, **2013**.
- [42] A. Diab, O. Falou, M. Hassan, B. Karlsson, and C. Marque, "Effect of filtering on the classification rate of nonlinear analysis methods applied to uterine EMG signals," *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, vol. 2015–Novem, pp. 4182–4185, **2015**.
- [43] D. Alamedine, A. Diab, C. Muszynski, B. Karlsson, M. Khalil, and C. Marque, "Selection Algorithm For Parameters To Characterize Uterine EHG Signals For The Detection Of Preterm Labor," *Signal, Image Video Process.*, vol. 8, no. 6, pp. 1169–1178, **2014**.
- [44] I. The MathWorks, "Wavelet Toolbox User's Guide," p. 698, **2015**.

- [45] C. M. Bishop, "Pattern Recognition and Machine Learning," Springer-Verlag New York, **2006**.
- [46] R. O. Duda, P. E. Hart, and D. G. Stork, "Pattern Classification," *New York: John Wiley, Section*. p. 680, **2001**.
- [47] C. M. Bishop, "Pattern Recognition and Machine Learning," Springer-Verlag New York, **2006**.
- [48] Minimum Distance Classifier, 2016, [https://www.cs.princeton.edu/courses/archive/fall08/cos436/Duda/PR\\_simp/min\\_dist.htm](https://www.cs.princeton.edu/courses/archive/fall08/cos436/Duda/PR_simp/min_dist.htm)
- [49] L. Fausset, *Fundamentals Of Neural Networks: Architectures, Algorithms, And Applications*, Prentice-Hall, **1994**
- [50] M. B. I. Raez, M. S. Hussain, F. Mohd-Yasin, M. Reaz, M. S. Hussain, and F. Mohd-Yasin, "Techniques of EMG signal analysis: detection, processing, classification and applications.," *Biological Procedures Online*, vol. 8, no. 1, pp. 11–35, **2006**.
- [51] M. Alfaouri and K. Daqrouq, "ECG signal denoising by wavelet transform thresholding," *American Journal of Applied Sciences*, vol. 5, no. 3, pp. 276–281, **2008**.
- [52] M. Chendeb, M. Khalil, D. Hewson, and J. Duchêne, "Classification of non stationary signals using multiscale decomposition," *Journal of Biomedical Science and Engineering*, vol. 3, February, pp. 193–199, **2010**.
- [53] M. Khalil and J. Duchene, "Uterine EMG analysis: a dynamic approach for change detection and classification," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 6, pp. 748–756, **2000**.
- [54] M. E. D. I. Cal, "B 1 Signal Analysis," pp. 1–2.
- [55] J. Pan and W. J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Transactions on Biomedical Engineering*, vol. BME-32, no. 3, pp. 230–236, **1985**.
- [56] J. Pan and W. J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Trans. bio-medical Eng. Eng.*, vol. BME-32, no. 3, pp. 230–236, 1985.
- [57] J. M. O'Toole, A. Temko, and N. Stevenson, "Assessing Instantaneous Energy In The EEG: A Non-Negative, Frequency-Weighted Energy Operator," *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*, vol. 2014, no. 3, pp. 3288–3291, **2014**.

- [58] J. Costa, M. Ortigueira, A. Batista, and T. Paiva, "Sleep Spindles Detection : a Mixed Method using STFT and WMSD," *International Journal of Bioelectromagnetism*, vol. 14, no. 4, pp. 229–233, **2012**..
- [59] B. Moslem, M. Diab, M. Khalil, and C. Marque, "Combining Data Fusion With Multiresolution Analysis For Improving The Classification Accuracy Of Uterine EMG Signals," *Eurasip Journal on Advances in Signal Processing*, pp. 1–9, **2012**.
- [60] B. Moslem, M. Khalil, M. O. Diab, A. Chkeir, and C. Marque, "A Multisensor Data Fusion Approach for Improving the Classification Accuracy of Uterine EMG Signals," *18th IEEE International Conference on Electronics, Circuits and Systems*, Mv, pp. 93–96, **2011**.



## ÖZGEÇMİŞ

### Kimlik Bilgileri

Adı Soyadı : Ayşe TAŞDÖĞEN

Doğum Yeri : Denizli

Medeni Hali : Bekar

E-posta : tasdogen.ayse@gmail.com

Adresi : Bahçelievler Mah. 319. Sok. No: 16/23 Gölbaşı/Ankara

### Eğitim

Lise : Buldan Ali TUNABOYLU Anadolu Lisesi Buldan / Denizli

Lisans : Ankara Üniversitesi Elektrik-Elektronik Mühendisliği

Yüksek Lisans: Hacettepe Üniversitesi Elektrik-Elektronik Mühendisliği

Doktora :

**Yabancı Dil ve Düzeyi** İngilizce, YDS 2014: 81.25

### İş Deneyimi:

Araştırma Görevlisi, Ankara Üniversitesi, Elektrik-Elektronik Mühendisliği

**Deneyim Alanları:** Sinyal İşleme, Matlab Sinyal İşleme Algoritma Geliştirme, Görüntü İşleme, Otomatik Kontrol, Arayüz Geliştirme, Matlab ve C++ Programlama

### Tezden Üretilmiş Projeler ve Bütçesi

### Tezden Üretilmiş Yayınlar

### Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

