

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

**APGAR ALTERNATİFİ OLARAK DOĞUM ÖNCESİ  
SINIFLANDIRMA YAKLAŞIMLARI**

**YÜKSEK LİSANS TEZİ  
Barış Doruk GÜNGÖR**

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK  
MÜHENDİSLİĞİ**  
**Enstitü Bilim Dalı : ELEKTRİK**  
**Tez Danışmanı : Doç. Dr. Mehmet Recep BOZKURT**

**Mayıs 2015**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

APGAR ALTERNATİFİ OLARAK DOĞUM ÖNCESİ  
SINIFLANDIRMA YAKLAŞIMLARI

YÜKSEK LİSANS TEZİ

Barış Doruk GÜNGÖR

Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK  
MÜHENDİSLİĞİ  
Enstitü Bilim Dalı : ELEKTRİK

Bu tez 03 / 06 /2015 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.

  
Doç. Dr. Mehmet Recep  
BOZKURT  
Jüri Başkanı

  
Yrd. Doç. Dr. Halil  
YİĞİT  
Üye

  
Yrd. Doç. Dr. Nükhet  
SAZAK  
Üye

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Barış Doruk GÜNGÖR

14.05.2015

## TEŐEKKÜR

Tez alıőmamda bilgileriyle yolumu aydınlatan ve her karőılaőtığım problemde telaőla yanına gittiğimde sıcak gülümsemesi ve sakin tavrıyla beni karőılayan, yaőadığım zorluklarda bana anlayıő gösteren danıőman hocam Sayın Do. Dr. Mehmet Recep BOZKURT'a, alıőmamın her adımımda maddi ve manevi desteęini benden esirgemeyen ve en zor zamanlarımda tereddüt etmeden yardımına koőan hem hocam hem de ok kıymetli arkadaőım Sayın Arő. Gör. Muhammed Kürőad UAR'a ve bütün hayatını benim mutluluęuma adayın, beni yetiőtirmek için kendi hayatından vazgeen baőarımdaki en büyük hak sahibi sevgili annem Sayın Hasibe AYHAN'a teőekkürlerimi ve minnetlerimi sunarım.

# İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER .....	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vii
ŞEKİLLER LİSTESİ .....	ix
TABLolar LİSTESİ .....	x
ÖZET.....	xii
SUMMARY .....	xiii
BÖLÜM 1.	
GİRİŞ .....	1
BÖLÜM 2.	
APGAR SKORU.....	3
2.1. Giriş .....	3
2.2. Apgar Skorunu Belirleyen Kriterler .....	4
2.2.1. Deri rengi (Appearance/Complexion) .....	4
2.2.2. Kalp tepe atımı (Pulse rate) .....	5
2.2.3. Uyarıya cevap (Grimace).....	5
2.2.4. Kas tonusu (Activity).....	5
2.2.5. Solunum şekli (Respiratory effort) .....	5
BÖLÜM 3.	
MALZEME VE YÖNTEM.....	6
3.1. Verilerin Toplanması.....	6
3.1.1. Hasta kayıtlarının toplanmasında dikkat edilen unsurlar .....	6
3.2. FHR (Fetal Kalp Hızı) Sinyali .....	7
3.3. UC (Rahim Kasılması) Sinyali .....	8

3.4. FHR ve UC Sinyallerinden Çıkarılan Öznitelikler .....	8
3.4.1. Standart sapma.....	9
3.4.2. Maksimum değer .....	9
3.4.3. Skewness katsayısı .....	10
3.4.4. Kurtosis katsayısı.....	10
3.4.5. Şekil faktörü .....	10
3.4.6. Varyans .....	11
3.4.7. Hjorth aktivite parametresi .....	11
3.4.8. Hjorth karmaşıklık parametresi .....	11
3.4.9. Ortalama eğri uzunluğu .....	12
3.4.10. Ortalama teager enerjisi.....	12
3.5. Fizyolojik Verilerin Öznitelikleri.....	12
3.5.1. Fetüs bilgileri.....	12
3.5.1.1. Gebelik haftası .....	12
3.5.1.2. Bebeğin ağırlığı.....	12
3.5.1.3. Cinsiyet .....	12
3.5.2. Maternal risk faktörleri.....	12
3.5.2.1. Yaş.....	13
3.5.2.2. Gravidite .....	13
3.5.2.3. Parite .....	13
3.5.2.4. Diyabet.....	13
3.5.2.5. Hipertansiyon.....	13
3.5.2.6. Preeklampsi.....	13
3.5.2.7. Likit Prekoks.....	13
3.5.2.8. Hiperpreksi.....	13
3.5.2.9. Mekonyum .....	13
3.5.3. Doğum bilgileri.....	13
3.5.3.1. Prezantasyon .....	13
3.5.3.2. Uyarılmış doğum .....	13
3.5.3.3. Doğumun eyleminin 1. evresi .....	13
3.5.3.4. Doğumun eyleminin ilerlememe durumu .....	13
3.5.3.5. CK/KP.....	14
3.5.3.6. Doğumun eyleminin 2. evresi.....	13

3.5.3.7. Doğum tipi .....	14
<b>BÖLÜM 4.</b>	
<b>YAPAY SİNİR AĞLARI .....</b>	<b>16</b>
4.1. Giriş .....	16
4.2. Yapay Sinir Ağlarının Genel Yapısı .....	16
4.2.1. Girdi katmanı .....	18
4.2.2. Ara katman .....	19
4.2.3. Çıktı katmanı .....	19
4.3. Yapay Sinir Ağlarının sınıflandırılması .....	19
4.3.1. Yapay sinir ağı tiplerine göre .....	19
4.3.1.1. İleri beslemeli ağlar .....	19
4.3.1.2. Geri beslemeli ağlar .....	20
4.3.2. Yapay sinir ağının öğrenme yöntemine göre .....	20
4.3.2.1. Öğretmenli (yönlendirmeli) öğrenme .....	20
4.3.2.2. Öğretmensiz (yönlendirmesiz) öğrenme .....	20
4.3.3. Yapay sinir ağının katman sayısına göre .....	20
4.3.3.1. Tek katmanlı yapay sinir ağları .....	21
4.3.3.2. Çok katmanlı yapay sinir ağları .....	21
4.3.4. Yapay sinir ağının yapısına göre .....	21
4.3.4.1. Otoasosyatif yapay sinir ağları .....	21
4.3.4.2. Heteroasosyatif yapay sinir ağları .....	21
4.4. Yapay Sinir Ağının Eğitilmesi .....	21
<b>BÖLÜM 5.</b>	
<b>ANALİZ YÖNTEMİ .....</b>	<b>22</b>
5.1. SPSS Analizi .....	22
5.2. Normallik Testi .....	22
5.3. Shapiro-Wilk Tablosu .....	22
5.4. Mann-Whitney U Testi .....	22
5.5. Ensemble Sınıflandırma Yöntemi .....	23
5.6. Olasılıksal sinir ağları (PNN) .....	24
5.7. k En Yakın Komşu Sınıflandırma Algoritması (kNN) .....	24
5.8. Çok Katmanlı İleri Beslemeli Sinir Ağları (MLFFNN) .....	25

5.9. Radyal Tabanlı Fonksiyon Sinir Ağları (RBFNN) .....	25
BÖLÜM 6.	
UYGULAMA .....	29
BÖLÜM 7.	
SONUÇLAR .....	30
7.1. Fizyolojik Verileri Kullanılarak Sınıflandırma .....	30
7.1.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar .....	30
7.1.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar .....	32
7.1.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar .....	34
7.1.4. Olasılıksal sinir ağlarına göre sonuçlar .....	35
7.2. FHR Sinyali Kullanılarak Sınıflandırma .....	36
7.2.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar .....	36
7.2.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar .....	37
7.2.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar .....	39
7.2.4. Olasılıksal sinir ağlarına göre sonuçlar .....	41
7.3. UC Sinyali Kullanılarak Sınıflandırma .....	41
7.3.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar .....	42
7.3.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar .....	43
7.3.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar .....	45
7.3.4. Olasılıksal sinir ağlarına göre sonuçlar .....	46
7.4. FHR, UC sinyalleri ve fizyolojik veriler kullanılarak sınıflandırma .....	47
7.4.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar .....	47
7.4.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar .....	48
7.4.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar .....	50
7.4.4. Olasılıksal sinir ağlarına göre sonuçlar .....	51
7.5. Sonuçların Karşılaştırılması.....	52
7.6. SPSS Programına Göre Sonuçlar.....	53
KAYNAKLAR.....	61
ÖZGEÇMİŞ .....	62



## SİMGELER VE KISALTMALAR LİSTESİ

$A$	: Hjorth aktivite parametresi
$C$	: Hjorth karmaşıklık parametresi
$M$	: Hjorth hareketlilik parametresi
$N$	: Kitledeki gözlem sayısı
$\sigma$	: Kitle standart sapması
$\sigma^2$	: Kitle varyansı
$\gamma_1$	: Skewness katsayısı
$\gamma_2$	: Kurtosis katsayısı
$\mu$	: Kitle ortalaması
$\mu_3$	: Üçüncü ortalama etrafındaki moment
$\mu_4$	: Dördüncü ortalama etrafındaki moment
$X_i$	: Örnek değişkeni
$\bar{X}$	: Örnek ortalaması
$k$	: Eşik değeri
$O_2$	: Oksijen gazı
$pCO_2$	: Kan gazındaki karbondioksitin kısmi basıncı
$pO_2$	: Kan gazındaki oksijenin kısmi basıncı
$pH$	: Kan gazındaki hidrojen iyonu aktivitesi
BDcef	: Kan gazındaki bir değer
CK/KP	: Doğum eylemi esnasında saptanan bir değer
CL	: Ortalama eğri uzunluğu
CST	: Kontraksiyon stres testi
CTG	: Kardiyotokografi kaydı
CTU	: Czhec teknik üniversitesi
FIGO	: Uluslararası kadın hastalıkları ve doğum federasyonu
FHR	: Fetal kalp hızı sinyali

kNN	: k en yakın komşu sınıflandırma algoritması
MLFFNN	: Çok katmanlı ileri beslemeli sinir ağıları
NICU	: Yeni doğan yoğun bakım
NST	: Nonstres test
OCT	: Oksitosin testi
PNN	: Olasılıksal sinir ağıları
RBFNN	: Radyal tabanlı fonksiyon sinir ağıları
SPSS	: Sosyal bilimler için istatistik paketi
TE	: Teager enerjisi
UC	: Rahim kasılması sinyali
UHB	: Brno üniversite hastanesi
YSA	: Yapay sinir ağıları

## ŞEKİLLER LİSTESİ

Şekil 3.1. Elektronik fetal monitorizasyon.....	8
Şekil 4.1. Biyolojik sinir hücresi nöron yapısı.....	17
Şekil 4.2. Yapay sinir hücresi nöron yapısı.....	17
Şekil 4.3. Yapay sinir ağı katmanları.....	18
Şekil 5.1. Ensemble sınıflandırıcı akış diyagramı.....	23
Şekil 6.1. Örnek FHR sinyali.....	29
Şekil 6.2. Örnek UC sinyali.....	29
Şekil 6.3. Akış diyagramı.....	30
Şekil 7.1. MLFFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%22).....	34
Şekil 7.2. RBFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%22).....	35
Şekil 7.3. RBFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%40).....	36
Şekil 7.4. MLFFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%22)	39
Şekil 7.5. RBFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%22)...	41
Şekil 7.6. RBFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%34)...	41
Şekil 7.7. MLFFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%22)..	45
Şekil 7.8. RBFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%22).....	46
Şekil 7.9. RBFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%34).....	47
Şekil 7.10. MLFFNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik veriler için eğitim bilgileri (%22).....	50
Şekil 7.11. RBFNN sınıflandırıcıya göre FHR ve UC sinyalleri ile fizyolojik veriler için eğitim bilgileri (%22).....	51
Şekil 7.12. RBFNN sınıflandırıcıya göre FHR ve UC sinyalleri ile fizyolojik veriler için eğitim bilgileri (%37).....	52

## TABLolar LİSTESİ

Tablo 7.1.	Fizyolojik verilerden çıkartılan öznitelikler.....	31
Tablo 7.2.	kNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%22).....	32
Tablo 7.3.	kNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%21).....	32
Tablo 7.4.	MLFFNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%22).....	34
Tablo 7.5.	FHR sinyalinden çıkartılan öznitelikler .....	37
Tablo 7.6.	kNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%22).....	38
Tablo 7.7.	kNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%43).....	38
Tablo 7.8.	MLFFNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%22).....	40
Tablo 7.9.	UC sinyalinden çıkartılan öznitelikler .....	42
Tablo 7.10.	kNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%22).....	43
Tablo 7.11.	kNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%33).....	44
Tablo 7.12.	MLFFNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%22).....	45
Tablo 7.13.	kNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik verilerin eğitim ve test başarı oranları (%22) .....	48
Tablo 7.14.	MLFFNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik verilerin eğitim ve test sonuçları (%22).....	50
Tablo 7.15.	kNN sınıflandırıcıya göre giriş verilerine göre doğruluk oranları (%22).....	54

Tablo 7.16. FHR sinyallerinin ortalamaları, standart sapmaları ve p değerleri ....	58
Tablo 7.17. UC sinyallerinin ortalamaları, standart sapmaları ve p değerleri .....	59
Tablo 7.18. İstatistiki verilerin ortalamaları, standart sapmaları ve p değerleri....	60

## ÖZET

Anahtar kelimeler: Apgar Skoru, Kardiyotokografi, Fetal Kalp Hızı Sinyali, Rahim Kasılması Sinyali, Yapay Sinir Ağları, kNN En Yakın Komşu Sınıflandırma Algoritması, SPSS Analizi, Mann-Whitney U Testi

Hızlı ve etkin bir yöntem olan apgar skorlaması yeni doğan bebeklerin sağlıklı olup olmadığının anlaşılması için kullanılır. Bebeğe herhangi bir müdahalenin (resusitasyon veya entübasyon) yapılıp yapılmayacağına apgar skorlaması ve çeşitli fizyolojik verilerin incelenmesi sonucunda karar verilmektedir. Müdahale süresinin kısılması bebek için hayati önem taşımaktadır.

Bu çalışmada, anne ve fetüsten alınan fizyolojik veriler ile FHR (fetal kalp atım hızı) ve UC (rahim kasılması) sinyallerinden çıkartılan öznitelikler, yeni doğan bebeğe bir müdahale gerekip gerekmeyeceğinin doğumdan önce belirlenmesi için incelenmiş ve apgar skorlamasına yönelik çalışma yapılmıştır. Çalışmada müdahale gerekir ve müdahale gerekmez şeklinde iki sınıf kullanılmıştır. Veriler Mann-Whitney U testi kullanılarak analiz edilmiştir. Bu sınıflar istatistiksel veriler, FHR ve UC sinyalleri açısından karşılaştırılmış, elde edilen sonuçlara göre k en yakın komşu sınıflandırma algoritması kullanılarak bebekler müdahale gerekir ve müdahale gerekmez sınıflarına ayrılmıştır.

# **CLASSIFICATION METHODS AND CLASSIFICATION OF BIOELECTRIC SIGNALS**

## **SUMMARY**

Keywords: Apgar Score, Cardiotocography, Fetal Heart Rate (FHR), Uterine Contraction (UC), Neural networks, k-nearest neighbors algorithm, SPSS Analysis, Mann-Whitney U Test

Apgar scoring is a method which is a fast and a effective way of understanding whether newborn babies are healthy or not. Any intervention to the baby such as resuscitation or intubation is done, if necessary, after evaluating the Apgar score and examining various physiological data. Shortening the response time for medical support is vitally important for babies.

In this study, the physiological data gathered from mother and fetus along with the features extracted from FHR (fetal heart rate) and UC (uterus contraction) signals were examined in order to determine whether the newborn will have any immediate problems that will need medical support before the baby was actually born and a study towards Apgar scoring was made. There were two classes (intervention, non-intervention) used in this study. Data was analyzed by using Mann-Whitney U test. The classes were compared in terms of statistical data, FHR and UC signals and according to the obtained the results, intervention and non-intervention classes have been devoted using k nearest neighbor classification algorithm.

## BÖLÜM 1. GİRİŞ

Doğumdan hemen sonra bebeklerin ilk değerlendirmeleri çok önemlidir. Bebeğin ya da annenin sağlığını etkileyebilecek olumsuz durumların ve risklerin saptanarak erken önlemlerin alınması için gebelerin ve fetüsün sürekli kontrol altında tutulması gerekmektedir. Önceleri annenin olası hastalıklarının önlenmesi ve tedavisi birincil amaçken, günümüzde aynı ölçüde fetüse de önem verilmektedir. Fetüsün, gerektiğinde bir 'hasta' olarak değerlendirilmesi anlayışı giderek yerleşmekte ve fetüs haklarından söz edilmektedir [1] [2]. Doğum eyleminden sonra yeni doğan bebeğe herhangi bir müdahalenin gerekli olup olmadığı saniyelik zaman dilimlerinde belirlenmelidir. Bu amaçla bebeklere doğum sonrasında bir müdahale gerekip gerekmeyeceğinin doğum anından önce bilinmesi büyük bir avantaj oluşturacaktır. Fakat fetüse ait anomalilerin tespit edilmesi oldukça zordur. Aslında yanlış alarm olabilen birçok belirti nedeniyle gebeler elektronik fetal monitorizasyon ile izlenmektedir. Ancak fetal monitorizasyonun sıklıkla tekrar edilmesi anne ve bebek açısından sağlıklı bulunmamaktadır. Fetüsün iyilik halini saptamak için ultrason, NST, CST, OCT, doppler ölçümleri, amniyon sıvısının ölçümü, biyofizik profil gibi testler yapılmaktadır. Doğum eylemi gerçekleştikten sonra ise yeni doğan bebeğin iyilik halini tespit etmek için genel bulgular üzerinden puanlama yapılarak değerlendirme yapılmaktadır.

Yeni doğan bebekler için kullanılan puanlama yöntemi ise Apgar Skoru adını taşımaktadır [3]. Yeni doğan bebeğe bir müdahale gerekip gerekmediğine apgar skorlamasına bakılarak karar verilebilir. Bu çalışmada, bebeğe müdahale gerekip gerekmeyeceğinin bebek doğmadan önce, bazı fizyolojik veriler, FHR ve UC sinyalleri aracılığı ile belirlenmesi amaçlanmaktadır. Bu sayede müdahale gerektirebilecek durumlar apgar skorlaması yapılmadan önce saptanarak müdahale zamanı minimuma indirilecek ve bebeğin fiziksel bir hasar görmesi



engellenebilecektir. Çalışma sonucunda, bebek doğmadan önce çıkarılan müdahale gerekir ya da müdahale gerekmez sonucu bebek doğduktan sonra yapılan apgar skorlaması ile karşılaştırılarak sistemin verimliliği kontrol edilmiş olacaktır.

Doğum eyleminde fetal durumun tespiti çok önemlidir. Fetal ve erken neonatal ölümü en aza indirmek için erken dönemde asfiksi teşhisi yapılmalıdır. Fetal hipoksinin (vücuttaki oksijen düzeyinin düşmesi) belirlenmesi fetal asfiksiye (oksijen yetersizliği) bağlı fetal ölümlerin azaltılmasında önem taşımaktadır [4] [5] [6] [7]. Resusitasyon gerektiren fetal asidoz (asit zehirlenmesi), asfiksi ve hipoksi gibi hastalıkların önceden belirlenmesinde ve birinci trimester spontan düşüklerin teşhisinde FHR sinyalinin kullanımıyla alakalı çalışmalar vardır [8] [9] [10] [11] [12]. Ancak birden fazla zaman serisini aynı anda içeren veri setlerinin fizyolojik araştırmalarda kullanılmasına az rastlanmaktadır. FHR ve UC sinyallerinin fizyolojik veriler ile birlikte incelenerek apgar skorunu belirlemede kullanılması ise yeni bir yaklaşımdır.

## **BÖLÜM 2. APGAR SKORU**

Apgar skoru, doğumdan hemen sonra yeni doğan bebeklerin hızlı ve öz bir şekilde sağlıklarını değerlendirmek için kullanılan basit ve tekrarlanabilir bir yöntemdir.

### **2.1. Giriş**

Apgar skorlaması, obstetrik anestezinin bebekler üzerindeki etkisinin tespit edilmesi için Dr. Virginia Apgar tarafından 1953 yılında geliştirilmiştir ve bebeğin fiziksel sağlığı açısından önemli olduğu kadar nörolojik gelişimi açısından da önemlidir. Bu değerlendirme yöntemi Dr. Virginia Apgar tarafından geliştirildiği için Apgar Skoru adını almıştır. Ayrıca apgar skorunu oluşturan 5 kriterin İngilizce isimlerinin baş harfleri bakronomik olarak APGAR kelimesini oluşturmaktadır. Bunlar; deri rengi (Appearance), kalp tepe atımı (Pulse rate), uyarıya cevap (Grimace), kas tonusu (Activity) ve solunum (Respiratory effort) kriterleridir.

Fetal durum değerlendirmesinde NST, CST, OCT, amnios sıvı indeksi, doppler, umbilikal kort ve kordon kan gazları analizi gibi yöntemlerin yanı sıra apgar skoru sıklıkla kullanılmaktadır [2] [13] [14] [15]. Bebeğe doğumdan hemen sonra 1. ve 5. dakikalarda olmak üzere iki kez apgar skorlaması yapılmaktadır [16]. Genellikle doğum eylemi sırasında oluşan oksijenizasyon yetersizliğini ve buna bağlı olarak entübasyon (solunum desteği) gerekip gerekmediğine 1. dakika apgar skoruna bakılarak karar verilir. Yeni doğana resusitasyon (temel yaşam desteği, yaşama döndürme) işlemi gerekip gerekmediğine 5. dakika apgar skoruna bakılarak karar verilir. Ayrıca 5. dakika apgar skorlaması yeni doğanın ilerideki sinir sistemi gelişimine yönelik fikir edinmeyi sağlamaktadır. Gerekli görüldüğü hallerde her 5 dakikada bir apgar testi tekrarlanabilir. Apgar skorlamasına göre 8 ve üzeri değerler

normal iken 7 ve altındaki deęerlerde gerekli görüldüğünde bebeęe resusitasyon veya entübasyon gibi müdahalelerde bulunulur [17] [18].

## **2.2. Apgar Skorunu Belirleyen Kriterler**

Apgar skorlaması 5 kriterden oluşur:

Kalp tepe atımı

Solunum şekli

Kas tonusu

Deri rengi

Uyarıya cevap

Her bir kriter 0-2 puan skalası aralığında deęerlendirilir ve 5 deęerin toplamı bebeęin 0-10 puan aralığındaki apgar skorunu belirler.

Her bir kriter farklı açılardan yeni doğan bebeęi deęerlendirdiği için her kritere aynı önem verilmemelidir. Örneęin solunum şekli ile deri rengi eşit önem taşımamaktadır [19].

### **2.2.1. Deri rengi (Appearance/Complexion)**

Genellikle yeni doğan bebekler, yüksek oksijen taşıma kapasitelerine rağmen düşük oksijen aldıkları için siyanotiktirler (derinin ve mukozanın mavi renk alma durumu). Birçok çocuk mükemmel havalandırma ve oksijen takviyesine rağmen birkaç dakikalığına siyanotik el ve ayak belirtileri gösterebilmektedir. Puanlama aşamasında, bebeęin elleri, ayakları ve vücudu pembe olduğunda 2, vücut pembe iken akrosiyanoz (el ve ayakların siyanoz hali) olduğunda 1, bebeęin her yerinde morarma ve soluk renk olduğunda ise 0 puan verilir [3].

En az önem verilen kriterdir çünkü cilt rengi solunum ve kalp tepe atımı ile ilişkilidir. Yeni doğan bebeklerin çok az bir kısmı pembe renklidir [20]. Deri rengi oldukça sübjektif bir kriter olduğu için en az güvenilir kriter olarak deęerlendirilir.

### **2.2.2. Kalp tepe atımı (Pulse rate)**

Bebeğin kalp atım hızı 100 ve üzerinde ise 2, 100'ün altında ise 1, kalp atışı görülüyor ise 0 puan verilir [3].

Teşhis ve belirti açısından en fazla önem gerektiren kriterdir. Kalp tepe atımı epigastriuma ve prekordiumdan da belirlenebilir.

### **2.2.3. Uyarıya cevap (Grimace)**

Yeni doğan bebek, orofarenksi veya burun deliklerine yumuşak kauçuk bir kateter ile aspirasyon (bebeğin ağız ve burnunun mekanik olarak temizlenmesi) yapıldığında ağlama, hapşırma, öksürme ya da kendini çekme tepkilerinden birini veriyorsa 2, yüzünü buruşturuyor ya da kuvvetsiz ağlıyorsa 1, tepki vermiyorsa 0 puan verilir [3].

### **2.2.4. Kas tonusu (Activity)**

Vücut kuvveti iyi olan ve kendiliğinden kollarını ve bacaklarını gererek uzatan bebeklere 2, biraz kıvrılabilenlere 1, direnç gösteremeyenlere ise 0 puan verilir [3].

### **2.2.5. Solunum şekli (Respiratory effort)**

Yeni doğan bebeğin oksijenizasyon durumuna göre değerlendirme yapılır. Doğumdan sonraki 60 saniye içerisinde nefes durması (apne) olanlara 0, zayıf ve düzensiz nefes alanlara 1, normal solunum yapan ve kuvvetlice ağlayan bebeklere 2 puan verilir [3].

## **BÖLÜM 3. MALZEME VE YÖNTEM**

### **3.1. Verilerin Toplanması**

Çalışmada kullanılan veri tabanı, Çek Teknik Üniversitesi (CTU) ve Brno Üniversite Hastanesinden (UHB) 2010 ve 2012 yılları arasında toplanan 9164 kaydın içinden dikkatlice seçilen 132 kardiyotokografi (CTG) kaydını içermektedir ve bütün kayıtlar Physionet'ten alınmıştır [21]. İlgili CTG verileri, doğumdan 90 dakika önce kaydedilmeye başlanmış olan ve en fazla 90 dakika uzunluğundaki kayıtlardan oluşmaktadır. Her bir CTG kaydı, 4 Hz de örneklenen fetal kalp atım hızı (FHR) ve rahim kasılması (UC) sinyalini içermektedir.

CTG verileri 9 kadın doğum uzmanı tarafından her bir sinyal için değişebilirlik ve güvenilirliğe bakılarak ve sinyallerin açıklamalarına bağlı kalınarak (Çek Cumhuriyetinde kullanılan FIGO yönergeleri izlenerek) değerlendirilmiştir.

#### **3.1.1. Hasta kayıtlarının toplanmasında dikkat edilen unsurlar**

Mümkün olduğunca homojen bir dizi oluşturabilmek için sadece aşağıdaki ölçütleri sağlayan hasta kayıtları kullanılmıştır.

Tekil gebelik

Gebelik süresi > 36 hafta

Gelişimsel kusurları önceden bilinmeyen

2. seviye doğum sancısı süresi  $\leq$  30 dakika

FHR sinyalinin kalitesi (FHR verileri uygun olduğundaki kayıt yüzdesi) > her 30 dakikalık zaman diliminin %50'si

Umbilikal arterden (göbek arteri) alınan kan gazı analizi olanlar

Vajinal (normal) doğum çokluğu (yalnız 46 tane sezaryen ameliyatlđ doğum içerir)

Bütün kayıtlardan toplanan ek parametreler;

Anne verileri; annenin yaşı, annenin doğum sayısı ve annenin hamilelik sayısı

Doğum verileri; doğum tipi (vajinal doğum ve sezaryen doğum), doğum süresi, sıvı mekonyum, ölçüm tipi (ultrason ya da direkt kafatası elektrotu)

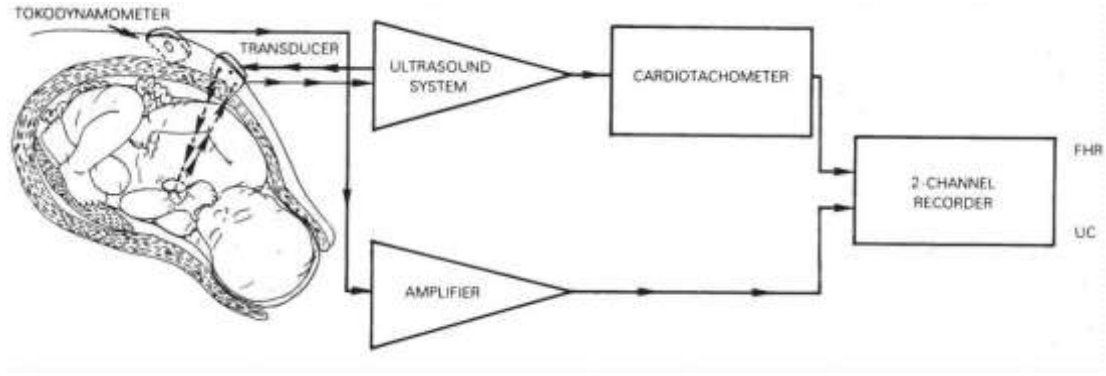
Fetüs verileri; cinsiyet ve doğum ağırlığı

Yeni doğan bebeğin verileri; göbeğe yakın artelyel kan örneğinin analizi (ph,  $pCO_2$ ,  $pO_2$ , baz açığı ve hesaplanan BDecf), apgar skorlaması, neonatolojik değerlendirme ( $O_2$  ihtiyacı, kasılma nöbetleri, yeni doğan yoğun bakım ünitesine (NICU) giriş) [15] [20]

### 3.2. FHR (Fetal Kalp Hızı) Sinyali

Anne karnındaki bebeğin durumunu takip etmek için gebe kadının karnına yerleştirilen cihazlar ile gebelik döneminde ve doğum eylemi sırasında kalp hızını ölçme işlemine fetal monitorizasyon denir. Fetoskop, doppler, elektronik fetal monitorizasyon, internal fetal monitorizasyon ve telemetrik monitorizasyon fetal kalp hızı ölçme işleminde kullanılan metotlardır. Anne nabzının fetal kalp atımlarından ayıran ve kalp atım hızını 50-210 skalası arasında gösteren metotlar tercih edilir. Bu ölçüm sonunda elde edilen sinyale FHR (fetal kalp hızı) sinyali adı verilir.

Çalışmada FHR ve UC sinyallerini birlikte değerlendirme olanağı sağladığı için elektronik fetal monitorizasyon kullanılmıştır. Fetal monitorizasyonun çalışma prensibi Şekil 3.1'de gösterilmiştir. Fetal kalp atımları dış uygulamada doppler prensibine bağlı çalışan ultrason probu ile ölçülür. İç uygulamada ise fetal EKG'yi çeken fetüsün saçlı derisine takılan spiral elektrot kullanılır. İç uygulama ile fetüs ve anne nabzı birbirine karıştırılmadan ölçülebilir [22]. Periyodik ve epizodik değişikliklerin dışındaki zamanlarda ortalama kalp atım hızı 10 dakikalık gözlemde en az 2 dakika sürmeli ve 110-160 arasında olmalıdır. Kalp atım hızındaki düzensiz büyüklükte ve sıklıkta olan değişikliklerin normali 5-25 arasındadır [23].



Şekil 3.1. Elektronik fetal monitorizasyon

### 3.3. UC (Rahim Kasılması) Sinyali

Rahim düz kaslarının kısalıp sıkışması yani kasılmasıyla meydana gelen olaya uterus kasılması (uterine contraction) adı verilir. Bu olay sonucunda elde edilen sinyale ise UC sinyali adı verilmektedir. Doğum veya doğum başlangıcını tespit etmek için rahim monitörü kullanılır. Bu monitör rahim sıcaklığı, rahim içi basınç ve rahim EMG'sini saptamayı sağlamaktadır [24]. Uterin aktiviteleri de fetal kalp atımları gibi elektronik fetal monitorizasyon ile takip edilmektedir. Rahim kasılmaları dış uygulamada uterin aktivite üzerine yapılan basıyı ölçen toko probu ile ölçülür. İç uygulamada ise uterusu yerleştirilen ve gerçek basıncı ölçen basınçölçer bir prob kullanılır. Dış uygulama uterin aktivite hakkında bağıl bilgi verir. İç uygulama ise uterusun bazal tonusu, kontraksiyonların kuvveti ve süresini doğru gösterilir. Uterin kasılmalarının senkronizasyon yöntemleri ile analiz edilmesi hastalık teşhisinde kullanılabilir [25]. Ancak maternal ve fetal enfeksiyon riski vardır.

### 3.4. FHR ve UC Sinyallerinden Çıkarılan Öznitelikler

Çalışmada kullanılan veriler doğumdan 90 dakika önce kaydedilmeye başlanmıştır. 4 Hz'de örneklenmiş olan FHR ve UC sinyallerinden zaman uzayında 10 adet öznitelik çıkarılmıştır. Bu öznitelikler Mann-Whitney U testi ile test edilerek aralarında anlamlı bir farkın olup olmadığı tespit edilmeye çalışılmıştır. FHR ve UC sinyallerinden zaman uzayında çıkarılan öznitelikler aşağıda belirtilmiştir.

### 3.4.1. Standart sapma

Bir deęişkenin aldığı farklı deęerlerin ortalamadan artı (+) veya eksi (-) yöndeki sapmalarının ortalamasına standart sapma denir. Cebirsel farklara göre hesaplanır ancak cebirsel sapmalar toplamı sıfır çıkacağından Denklem (3.1)'deki gibi sapmaların kareleri kullanılır [26]. Standart sapma çeşitli deęişken dönüşümleri yapılarak örneklenmiş varsayılan ortalama ve varsayılan ortalama yöntemleri ya da aritmetik ortalama ve kareli ortalama ilişkisi ile de hesaplanabilir. Standart sapma hesaplanırken dağılımın bütün deęerleri dikkate alınır. Bir dağılımın yaygınlığını gösteren en önemli yaygınlık ölçülerinden biri olduğu için aritmetikte oldukça fazla kullanılır. Standart sapmanın büyümesi dağılımın yaygınlığını artırır ancak dağılımdaki deęerlerin aynı olması yaygınlığın olmadığını gösterir. Bir örneklem, bir olasılık dağılımı, bir ana kütle veya bir rassal deęişken için standart sapma her bir gözlem deęerinin ortalamadan sapmalarının toplamının gözlem sayısına bölünüp kareköküne alınmasıyla bulunur. Kütle standart sapması  $\sigma$ , kitledeki gözlem sayısı  $N$ , örnek deęişkeni  $X$ , örnek ortalaması ise  $\bar{X}$  ile gösterilir ve Denklem (3.2)'deki gibi hesaplanır [27] [28] [29] [30] [31].

$$\sum X_i - \bar{X} = 0 \quad (3.1)$$

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

### 3.4.2. Maksimum deęer

Maksimum deęer bir sinyalin ani deęerlerinin en büyüğüdür. Eğrinin en yüksek noktasına ulaşır tekrar inmeye başladığı noktadaki deęerlerdir. Sinüs dalgasında pozitif ve negatif maksimum deęerler arasındaki genlik deęeri tepeden tepeye gerilimdir [32] [31].



### 3.4.3. Skewness katsayısı

Çarpıklık katsayısı olarak da adlandırılır. Matematiksel olarak 3. moment ile hesaplanır. Bir rassal değişkenin olasılık dağılımının simetrik olamayışını yani verilerin normal dağılım gösterip göstermediğini ifade eder. Normal dağılımda çarpıklık katsayısı 0'dır ve dağılım simetriktir. Normal olmayan dağılım da aritmetik ortalama > medyan > mod ise sağa çarpıktır ya da pozitif kayışlıdır, aritmetik ortalama < medyan < mod ise sola çarpıktır ya da negatif kayışlıdır. Çarpıklık ölçüsü  $\pm 3$  ( $\pm 2$  de olabilir) aralığında değerler alması durumunda normal kabul edilmektedir.  $\gamma_1$  ile ifade edilir ve Denklem (3.3)'deki gibi hesaplanır [31] [33] [34] [35] [36] [37].

$$\gamma_1 = \frac{\mu_3}{\sigma_3} \quad (3.3)$$

### 3.4.4. Kurtosis katsayısı

Basıklık katsayısı olarak da bilinir ve verilerin normal dağılım gösterip göstermediğini ifade eder. Bir reel değerli rassal değişken için olasılık dağılımının maksimum değerinin keskinliğini tanımlar yani normal dağılım eğrisinin ne kadar dik ve ya basık olduğunu gösterir. Kurtosis katsayısı yükseklik derecesinin bir ölçüsüdür [38] [39]. Pozitif ise eğri normale göre daha diktir ve negatif ise eğri normale göre daha basıktır.  $\gamma_2$  ile ifade edilir ve Denklem (3.4)'deki gibi hesaplanır [31] [36] [37].

$$\gamma_2 = \frac{k_4}{k_2^2} = \frac{\mu_4}{\sigma_4} - 3 \quad (3.4)$$

### 3.4.5. Şekil faktörü

Bir nesnenin boyutlarından bağımsız ancak şekline bağımlı bir değerdir. Genel olarak parçacığın biçimi parçacığın yöneliminden bağımsız, boyutsuz bütün geometrik şekiller için şekil faktörü ile ölçülür. Küresellik en yaygın kullanılan şekil faktörüdür. Katı parçacıklar ve ilgili küre arasındaki sapmayı açıklamak için kullanılır [40].

### 3.4.6. Varyans

Varyans bir rassal deęişken, bir olasılık daęılımı veya örneklem için hesaplanabilir. İstatistiksel yayılımın bütün deęerlerinin uzaklıklarının karelerinin ortalamasıdır. Standart sapmanın karesidir ve birimi karesel olduęu için yaygınlık ölçüsü olarak kullanılmaz. Uygulamadan çok teoride kullanılır.  $\sigma^2$  ile gösterilir ve Denklem (3.5)'deki gibi hesaplanır [26] [27] [28] [31] [41] [42] [43].

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (X_i - \mu)^2 \quad (3.5)$$

### 3.4.7. Hjorth aktivite parametresi

Normalize edilmiş eęim açıklayıcı olarak da bilenen Hjorth parametreleri hesaplanırken işaretin birinci ve ikinci türevlerinden faydalanılmaktadır [44]. İşaretin ortalama enerjisine eşittir [45]. Ele aldığımız bir özellik vektörünün varyansı  $\sigma_0$ ,  $i$ 'nci türevde  $\sigma_i$  olsun. Bu durumda Hjorth aktivite parametresi Denklem (3.6)'deki gibi hesaplanır [46] [47].

$$A = \sigma_0^2 \quad (3.6)$$

### 3.4.8. Hjorth karmaşıklık parametresi

Hjorth karmaşıklık parametresi işaretin bant genişliğinin kestirimidir [48]. Bu durumda Hjorth karmaşıklık parametresi Denklem (3.7)'deki gibi hesaplanır [46] [47].

$$C = \sqrt{(\sigma_2/\sigma_1)^2 - (\sigma_1/\sigma_0)^2} \quad (3.7)$$

### 3.4.9. Ortalama eğri uzunluğu

Fraktal boyuttan türetilmiş bir özneliktir. Bu nedenle fraktal boyutta daha iyi sonuç vermektedir. Ortalama eğri uzunluğu Denklem (3.8)'deki gibi hesaplanır [45] [49] [50].

$$CL = \frac{1}{N} \sum_{t=2}^N |x[t] - x[t-1]| \quad (3.8)$$

### 3.4.10. Ortalama teager enerjisi

Teager-Kaiser tarafından geliştirilmiş bir enerji operatörüdür. Bir ayrık-zaman sinyalinin gerçek enerjisini ölçmek için kullanılan doğrusal olmayan bir operatördür. Teager enerjisi Denklem (3.9)'daki gibi hesaplanabilir [45] [51] [52] [53] [54] [55].

$$TE = \frac{1}{N} \sum_{t=3}^N (x[t-1]^2 - x[t]x[t-2]) \quad (3.9)$$

## 3.5. Fizyolojik Verilerin Öznelikleri

### 3.5.1. Fetüs bilgileri

Fetüsle ilgili bilgi edinmemizi sağlayan faktörlerdir. Tablo 3.1'de verilmiştir.

Tablo 3.1. Fetüs bilgileri

Faktör	Açıklama
Gebelik haftası	Hamileliğin kaçınca haftasında olduğunu yani doğum eylemi gerçekleşmeden önce bebeğin kaç haftalık olduğunu belirtir.
Bebeğin ağırlığı	Doğum eylemi gerçekleşmeden önce bebeğin gram olarak ağırlığını belirtir.
Cinsiyet	Bebeğin cinsiyetini belirtir.

### 3.5.2. Maternal risk faktörleri

Gebenin risk durumu ile ilgili bilgi edinmemizi sağlayan faktörlerdir. Tablo 3.1’de verilmiştir.

Tablo 3.2. Maternal risk faktörleri

Faktör	Açıklama
Yaş	Gebenin yaşını belirtir.
Gravidite	Gebenin daha önce kaç kez gebe kaldığını belirtir.
Parite	Gebenin doğumla sonuçlanan gebelik sayısını belirtir.
Diyabet	Gebenin diyabet durumunu belirtir. Diyabet kalıtsal ve çevresel faktörlerin etkisiyle kandaki glikoz seviyesinin yükselmesine bağlı olarak meydana gelen metabolik bozukluktur.
Hipertansiyon	Gebenin tansiyon durumunu belirtir. Hipertansiyon atardamardaki kan basıncının yükselmesiyle görülen kronik durumdur.
Preeklampsi	Gebenin tansiyon durumunu preeklampsi durumunu belirtir. Preeklampsi gebeliğin ikinci yarısında hipertansiyon, idrarda yüksek miktarda protein bulunması ve toksik etkilerle meydana gelen komplikasyondur.
Likit Prekoks	Gebenin tansiyon durumunu likit prekoks durumunu belirtir. Likit prekoks amniyon zarının vaktinden önce yırtılarak amniyon sıvısının vajinadan akıntı şeklinde boşalması durumudur.
Hiperpreksi	Gebenin tansiyon durumunu hiperpreksi durumunu belirtir. Hiperpreksi vücut ısısının yükselmesi durumudur.
Mekonyum	Fetüsün ilk dışkıdır. Anne karnındaki ilk dışkı fetüs için tehlikeli olabilmektedir [56].

### 3.5.3. Doğum bilgileri

Doğum eylemiyle ilgili bilgi almamızı sağlayan faktörlerdir. Tablo 3.3’de verilmiştir.

Tablo 3.3. Doğum bilgileri

Faktör	Açıklama
Prezantasyon	Doğum sırasında bebeğin geliş pozisyonunu belirtir. 2 türlü olabilmektedir. Bunlar; baş geliş ve makat gelişdir.
Uyarılmış doğum	Suni sancı (indüksiyon) veya ilaç gibi uyarıcılarla hamilenin uyarılmasıyla doğum eyleminin başlatılmasıdır.
Doğumun eyleminin 1. evresi	Kasılmaların başlamasıyla rahim ağzının açıldığı evredir. Doğum eyleminin en uzun evresi olarak değerlendirilir. Rahim ağzının açılması saatleri bulabilmektedir.
Doğumun eyleminin 2. Evresi	Bu evrede rahim ağzı açılır ve doğum eylemi başlamış olur.
Doğumun eyleminin ilerlememe durumu	Doğum eylemi esnasında evreler arasındaki ilerleme durumudur.

<b>CK/KP</b>	Doğum esnasında saptanan bir değerdir.
<b>Doğum tipi</b>	Doğumun normal doğum veya sezaryen doğum olması durumunu belirtir.

## **BÖLÜM 4. YAPAY SİNİR AĞLARI**


Teknolojideki gelişim önceleri yalnızca elektronik veri transferi ve karmaşık hesap işlemleri yapan bilgisayarların günümüzde olaylar hakkında karar verme ve olaylar arasındaki ilişkileri öğrenebilmesini sağlamaktadır. Bilgisayarların bu yeni işlevleri ilk olarak 1950’li yıllarda ortaya çıkan ve günümüze kadar gelişmeye devam eden “yapay zeka” çalışmaları olarak adlandırılabilir [57].

### **4.1. Giriş**

Yapay sinir ağları (YSA), insan beynindeki milyarlarca biyolojik sinir ağını matematiksel yapılarına göre taklit eden bilgi türetme, yeni bilgi oluşturma, keşfetme gibi yeteneklere sahip birbirine bağlı ve her biri kendi işlem elemanlarından oluşan paralel ve dağıtılmış bilgisayar sistemleridir [58]. Yapay sinir ağları lineer olmayan zaman serisi modellerine göre çok daha efektif bir alternatiftir.

### **4.2. Yapay Sinir Ağlarının Genel Yapısı**

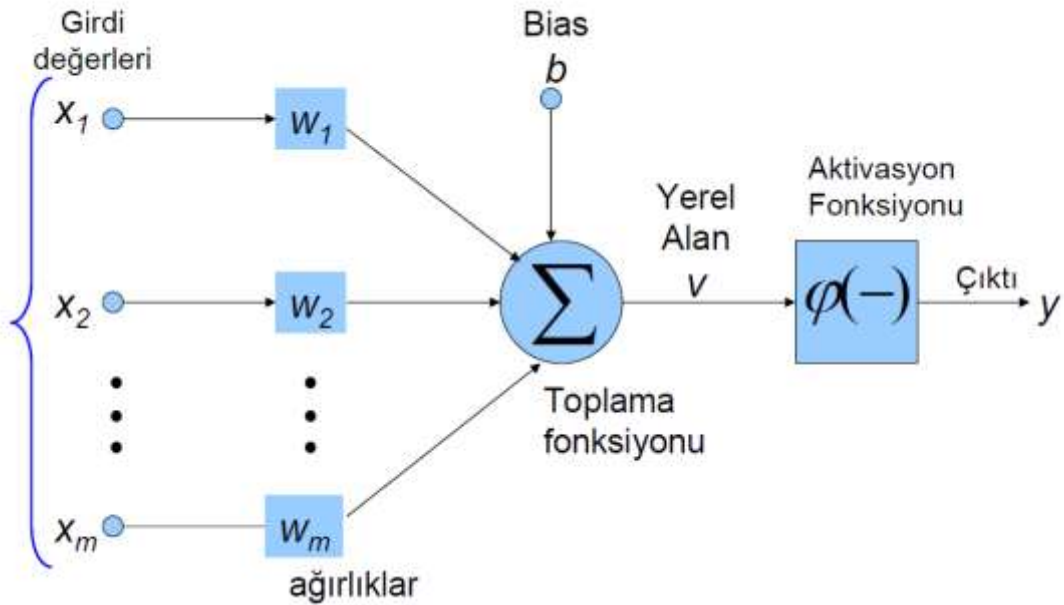
Yapay sinir ağları milyonlarca sinir hücresinin bir araya gelmesinden oluşan biyolojik sinir sistemi model alınarak oluşturulmuştur. Şekil 4.1’de temel nöron yapısı görülmektedir.



Şekil 4.1. Biyolojik sinir hücresi nöron yapısı

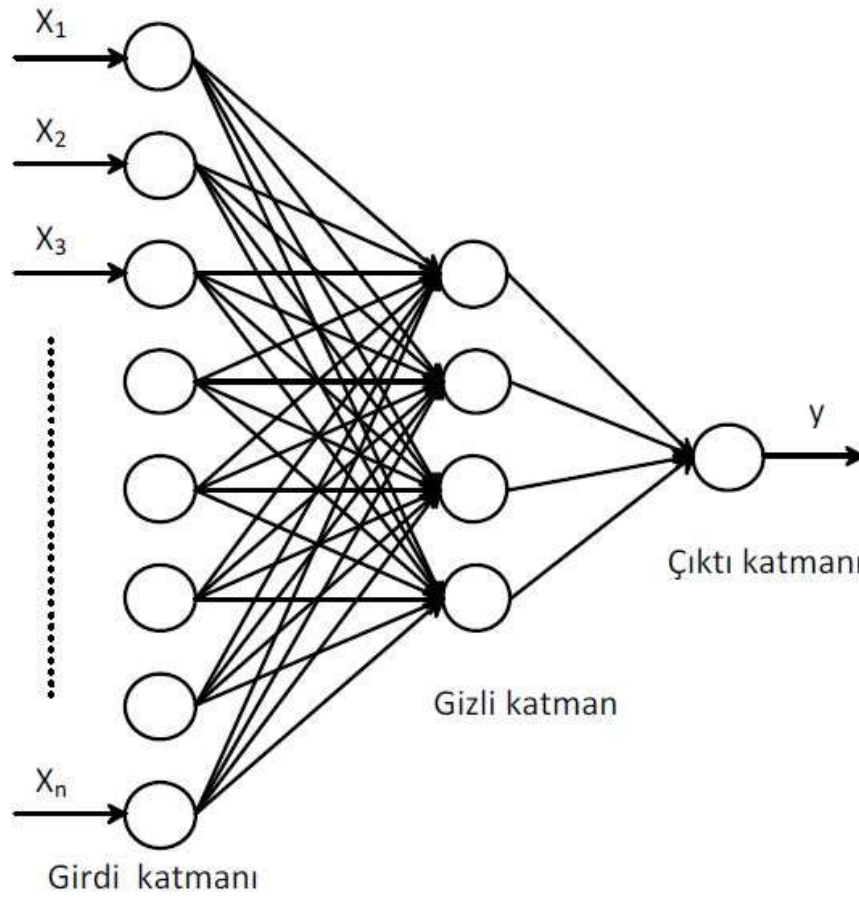
Yapay sinir ağları yapay sinir hücreleri ve bunların bağlantılarından oluştuğu için farklı mimariler arasında bile bir benzerlik söz konusudur.

Biyolojik sinir sisteminde sinir sistemine iletilen uyarı sinir sisteminde değerlendirildikten sonra efektörler aracılığı ile tepkiye dönüşür. Yapay sinir ağları da benzer şekilde çalışır. Şekil 4.2’de örnek bir yapay nöron gösterilmiştir.



Şekil 4.2. Yapay sinir hücresi nöron yapısı

Yapay nöronlar biyolojik nöronlara kıyasla oldukça ilkel olduğundan beyinin yoğun bağlantılı ve komplike yapısına günümüz dijital bilgisayar teknolojisiyle bile yaklaşmak çok zordur. Yapay sinir hücreleri katmanlar halinde öbikleşerek yapay sinir ağını oluştururlar [59]. Benzer özellikteki hücreler bir araya gelerek Şekil 4.3'deki gibi katmanları oluştururlar.



Şekil 4.3. Yapay sinir ağı katmanları

#### 4.2.1. Girdi katmanı

Dış çevreden alınan bilgilerin ara katmana transfer edilmesini sağlayan sinirleri içerir. Her bir giriş için bir nöron vardır. Giriş katmanındaki değerler  $x$  vektörü ile ifade edilir [57] [58] [60] [61].



#### 4.2.2. Ara katman

Girdi katmanından gelen bilgilerin işlendiği katmandır. Gizli katman olarak da isimlendirilir. Bir yapay sinir ağında birden fazla ara katman olabilir. Girdiler toplanarak bağlantı ağırlıklarıyla çarpılır ve çıkış katmanına gönderilir. Ara katman her veri için bir nörona sahiptir. Giriş katmanından gelen  $x$  vektörünün nöron merkezine olan Euclidean mesafesini hesaplar ve Kernel fonksiyonunu uygular. Hesaplamalar sonucunda elde edilen değerler çıktı katmanına aktarılır [57] [58] [60] [61].

#### 4.2.3. Çıktı katmanı

Ara katmandan gelen verilerin işlendiği katmandır. Sistemin çıkışı Karar katmanı olarak da isimlendirilir. Girdi katmanından gelen veriler burada işlenerek en büyük ağırlıklı tahmin değerini çıktı sonu olarak üretilir. Sistemin çıkışı da kullanıcıya bu katmandaki nöronlar aracılığı ile iletilir [57] [58] [60] [61].

### 4.3. Yapay Sinir Ağlarının sınıflandırılması

#### 4.3.1. Yapay sinir ağı tiplerine göre

Yapay sinir ağları nöronlar arasındaki bağlantı yapısına göre ikiye ayrılmaktadır.

##### 4.3.1.1. İleri beslemeli ağlar

Verilerin girdi katmanından çıktı katmanına doğru yalnızca ileri yönde ilerlediği işlem elemanları arasında bir döngünün olmadığı ağ yapısıdır. Giriş verisine hızlı bir çıkış cevabı üretirler [58] [60].

#### 4.3.1.2. Geri beslemeli ağlar

Verilerin girdi ve çıktı katmanı arasında çift yönlü akışının sağlandığı ağ yapısıdır. Katmanlar arasında bir döngü söz konusudur. Döngü nedeniyle çıkış cevabı daha yavaş bir şekilde oluşur. Ağ çıktısı girdi olarak kullanılabilir [58] [60].

#### 4.3.2. Yapay sinir ağının öğrenme yöntemine göre

Yapay sinir ağları çevreden etkilenen yapılardır. Bu etkilenme yapay sinir ağlarının ağırlıklarında farklılıklara neden olabilir. Yapay sinir ağları bu farklılıkların sonucuna göre çıktı verirler. Öğrenme yapay sinir ağlarının en temel özelliğidir. Her yöntemin öğrenme kuralı farklılık gösterebilir. Temel olarak iki tip öğrenme yöntemi vardır.

##### 4.3.2.1. Öğretmenli (yönlendirmeli) öğrenme

Ağı eğitmek için giriş çıkış verilerinin kullanıldığı eğitim biçimidir. Kullanılan verilerin giriş ve çıkış değerlerinin bilinmesi gerekir. Giriş ve çıkış değerleri yapay sinir ağına verilir. Ağ giriş verilerini işler ve kendi çıkış verilerini oluşturur. Oluşturduğu çıkış verileri ile başlangıçta verilen çıkış değerlerini karşılaştırır. Bağlantılardaki ağırlıklar ağın performansını belirler. Belirtilen hata payının altına düşene kadar işlem ağ tarafından tekrarlanır [59] [60].

##### 4.3.2.2. Öğretmensiz (yönlendirmesiz) öğrenme

Giriş ve çıkış verileri bilinmeyen eğitim sürecinde kullanılır. Girdiler aynı zamanda çıktı olarak da kullanılır. Hem girdi hem de çıktı olarak kullanılan veriler arasındaki ilişkinin tanımlanması ağın eğitilmesi anlamına gelir [60].

#### 4.3.3. Yapay sinir ağının katman sayısına göre

Benzer yapay sinir hücrelerinin bir araya gelmesiyle katmanlar oluşmaktadır. Girdi, ara ve çıktı katmanları bu katmanlara örnektirler.

#### **4.3.3.1. Tek katmanlı yapay sinir ağıları**

Tek katmanlı yapay sinir ağıları girdi ve çıktı katmanlarından oluşurlar. Her ağıın birden fazla girdi ve çıktısı vardır. Çıktılar girdilere bağlanmaktadır. Ağıın çıktısının sıfır olmasını engellemek için bir eşik değeri vardır.

#### **4.3.3.2. Çok katmanlı yapay sinir ağıları**

Girdi ve çıktılar arasındaki ilişkilerin doğrusal olmadığı durumlarda kullanılır. Sınıflandırma, tanıma ve genelleme yapma konularında sık kullanılırlar. Bu yapıdaki yapay sinir ağıları Delta Öğrenme Kuralı'na göre öğrenme işlemini gerçekleştirmektedirler.

#### **4.3.4. Yapay sinir ağıının yapısına göre**

Nöronların işlevlerine göre farklılık göstermektedirler.

##### **4.3.4.1. Otoasosyatif yapay sinir ağıları**

Otoasosyatif ağ yapısında girdi nöronları aynı zamanda çıktı nöronları olarak görev yapmaktadırlar.

##### **4.3.4.2. Heteroasosyatif yapay sinir ağıları**

Heteroasosyatif ağ yapısında girdi ve çıktı nöronları farklı nöronlardır.

#### **4.4. Yapay Sinir Ağıının Eğitilmesi**

Her yapay sinir ağıında girdi ve çıktı nöronları bulunmaktadır. Bu nöronlar arasındaki bağlantıların ağırlık denilen sinaptik bağlantı kuvvetleri vardır. Sinaptik bağlantı kuvveti yani ağırlık nöronların kendi etkinlikleri oranında artar. Bilgi bu ağırlıklarda depolanmaktadır. Ağırlıkların bir işi yerine getirebilmek için organize edilmesine

öğrenme denmektedir. Yapay sinir hücreleri arasındaki ağırlıkların değiştirilmesiyle öğrenme gerçekleşmektedir [58].

## **BÖLÜM 5. ANALİZ YÖNTEMİ**

Çalışmada kullanılan veri seti tek grup ve iki sınıftan oluşmaktadır. Bu nedenle verilerin yapısına uygun analiz yöntemleri kullanılmıştır. SPSS analizi ile gruplar arasındaki anlamlılığa bakılmıştır.

### **5.1. SPSS Analizi**

Çalışmada kullanılan veriler sıralıdır ve bağımsız gruplardan oluşmaktadır fakat parametrik değildir. Bu nedenlerle çalışma SPSS (Statistical Package for the Social Sciences) programı kullanılarak yapılmıştır.

### **5.2. Normallik Testi**

İlk olarak veri setine normallik testi uygulanmıştır.

### **5.3. Shapiro-Wilk Tablosu**

Kullanılan veri sayısı 50'den fazla olduğu için Shapiro-Wilk tablosu incelenmiştir. Bunun sonucunda çalışmada kullanılan 26 veri için dağılımın normal dağılım olmadığı görülmüştür.

### **5.4. Mann-Whitney U Testi**

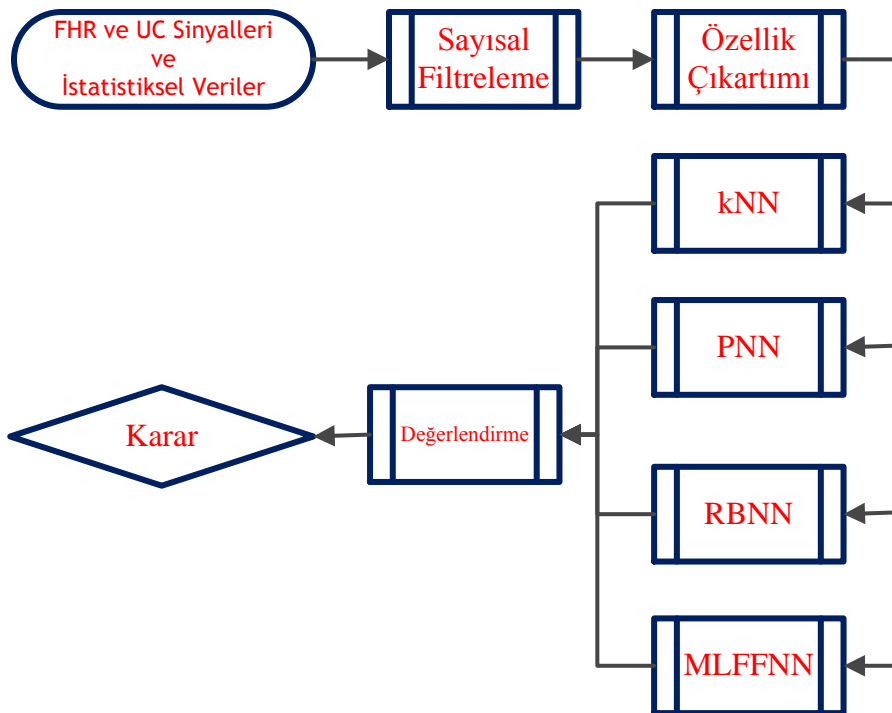
Apgar skoru sıralayıcı bir veri tipi olduğu için uygun analiz yöntemi olarak Mann-Whitney U testi seçilmiştir. Bu test parametrik olmayan istatistiksel bir test olup iki örneklemin aynı dağılımdan gelip gelmediğini incelemek için kullanılır. Bölüm 3.4'te FHR ve UC sinyallerinden çıkartılan öznitelikler ve Bölüm 3.5.'te anlatılan fizyolojik öznitelikler Mann-Whitney U testi ile test edilerek aralarında anlamlı bir

farkın olup olmadığı tespit edilmeye çalışılmıştır. Bu teste göre p değeri 0.05'ten küçük olan veriler istatistiksel olarak anlamlı iken 0.05'ten büyük olanlar istatistiksel olarak anlamsızdır [27].

### 5.5. Ensemble Sınıflandırma Yöntemi

Daha kesin ve güvenilir sonuçlar elde etmek amacıyla birden fazla sınıflandırma yönteminin bir arada kullanıldığı sınıflandırıcıya denir. Ensemble metodu genellikle performansı artırmak için kullanılır [62]. Kümeleme algoritmalarının sağlamlığını ve kalitesini arttırmak için de kullanılmaktadır [63].

Çalışmada kNN, PNN, RBFNN ve MLFFNN yapay sinir ağı modelleri birlikte kullanılarak ensemble sınıflandırıcıyı oluşturmuştur. Çalışmada kullanılan akış diyagramı Şekil 5.1'deki gibidir [64].



Şekil 5.1. Ensemble sınıflandırıcı akış diyagramı

İlk olarak her sınıflandırıcı için ayrı ayrı işlem yapılmış ardından bütün sınıflandırıcılar ensemble metoduna dahil edilmiştir. Her sınıflandırma yönteminin

çıkış verileri göz önünde bulundurularak en yüksek değerdeki çıkış verisi sistem çıkışı olarak verilmektedir [65].

### 5.6. Olasılıksal sinir ağları (PNN)

Olasılıksal yapay sinir ağlarında danışmanlı eğitim dizisi dağıtım işlemi için kullanılmaktadır. Ağırlıklı bir sınıflandırıcıdır. İstatistiksel bir algoritma olan Kernel Diskriminant Analizi'nin bir uygulamasıdır. Çok katmanlı ve ileri beslemeli bir yapıya sahiptirler. Giriş, model, toplama ve çıkış katmanlarından oluşmaktadırlar. Eğitim setindeki temsil sayısı arttıkça optimal sınıflandırıcıya yaklaşılmaktadır. Dolayısıyla nitelikli temsil sayısı arttıkça daha verimli bir sınıflandırıcı elde edilmektedir. Eğitim setine eklemeler ve çıkartmalar yapılabilmektedir. Hızlı bir eğitim prosesine sahip olmalarına karşın ağ yavaş yürütülmektedir. Bu sayede hatalı eğitim verileri tolere edilebilmektedir. Bu sınıflandırıcı tipinde yüksek belek ihtiyacı vardır. Eğitim setinin boyutu arttıkça Bayes Optimal Sınıflandırıcı tipine yakınsamaktadır. Giriş katmanından gelen verilerin benzerliğini tahmin etmeye çalışarak girdi vektörü için en uygun sınıfı belirlemektedir [58] [66] [67] [68].

### 5.7. k En Yakın Komşu Sınıflandırma Algoritması (kNN)

Sınıflandırma problemini benzerlik fonksiyonlarını kullanarak çözen kontrollü ve denetimli bir öğrenme algoritmasıdır. 1950'li yıllardan beri kullanılmaktadır. Parametrik olmayan bir sınıflandırma yöntemidir. Hassasiyet açısından çok başarılı olmasına rağmen özellik boyutunun oldukça yüksek olduğu bir sınıflandırma algoritmasıdır. Gürültülü verilere kolay uygulanabilmekte ve veri sayısı arttıkça daha etkili sonuçlar vermektedir. Kullanılan veriler öğrenme kümesindeki veriler ile kıyaslanmaktadır. Belirlenen eşik değerine göre k bir sayıyı ifade etmek üzere en yakın k komşu sayısının ortalamasıyla sınıflandırma yapılmaktadır. Mesafe Öklid, Mahalanobis veya Manhattan mesafesine göre hesaplanmaktadır. Veriler vektörel olarak ifade edilmektedir. kNN uzaklığa bağlı bir algoritma olduğu için en iyi sonuçları elde etmek için hangi uzaklık tipinin ve özniteliklerin kullanılacağı dikkatli seçilmelidir. Çıkarılan özelliklere bakılarak verinin önceki verilere olan yakınlığına göre sınıflandırma yapılmaktadır. Sisteme yeni katılan verinin sistemde bulunan en

yakın  $k$  tane veriye uzaklığı hesaplanır. Bu verilerden en yakın olanlar sayıca fazla ve aynı gruba dahil ise yeni veride o gruba dahil edilmektedir. Ağ özelleştirerek performansın artması sağlanabilmektedir. Geniş örneklem aralığını hızlı öğrenmesine karşın lineer olmayan sınıflandırma zamanı uzun olabilmektedir [69]. Eğitim seti içerisindeki verilerin  $k$  ile isimlendirilen bir eşik değerine göre benzerliklerini hesaplayarak sınıflandırma yaptığı için eğitim verilerinin dağılımı sınıflandırıcıyı etkilemektedir [70]. En uygun  $k$  değeri deneme yanılma yöntemi ile bulunmaktadır [71].

### **5.8. Çok Katmanlı İleri Beslemeli Sinir Ağları (MLFFNN)**

Sayısal girdi setinin sayısal çıktı setine dönüşmesini sağlamaktadır. Üç katmandan oluşur. Ara katman ve çıkış katmanı arasında eğitim işlemi gerçekleşmektedir. Kullanılan veri yalnızca ara ve çıkış katmanında işlem görmektedir. Çıkış nöronları sigmoid ve lineer yapıya sahiptirler. Birkaç yüz ağırlığa kadar hızlı bir eğitim metodu olan Levenberg-Marquardt geri yayılım algoritması kullanılır [72].

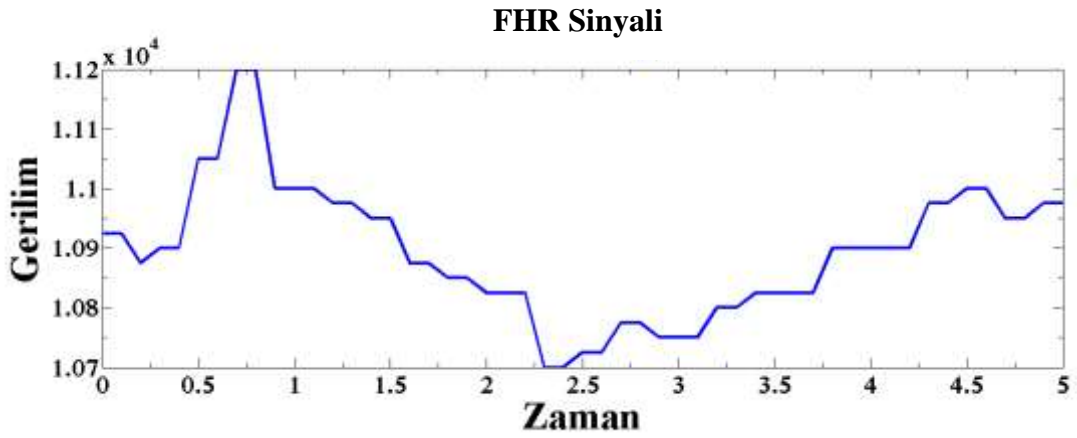
### **5.9. Radyal Tabanlı Fonksiyon Sinir Ağları (RBFNN)**

Makine öğrenmesinde zaman serisi tahmini, sınıflandırma ve regrasyon gibi alanlarda oldukça verimli olarak kullanılan, kestirim yeteneği gelişmiş ileri beslemeli bir yapay sinir ağıdır. Basit topolojik bir yapıya sahiptir. Ağ tasarlanırken önce parametre olarak nöronların genişlikleri ve merkezleri hesaplanmakta ardından yerel ve küresel algoritmalar ile çıkış ağırlıkları hesaplanmaktadır. Her bir nöron karakteristik bir cevabı vardır. Mühendislik uygulamaları ve tıbbi tanı alanlarında kullanılmaya elverişli bir yapıya sahiptir [73] [74] [75].

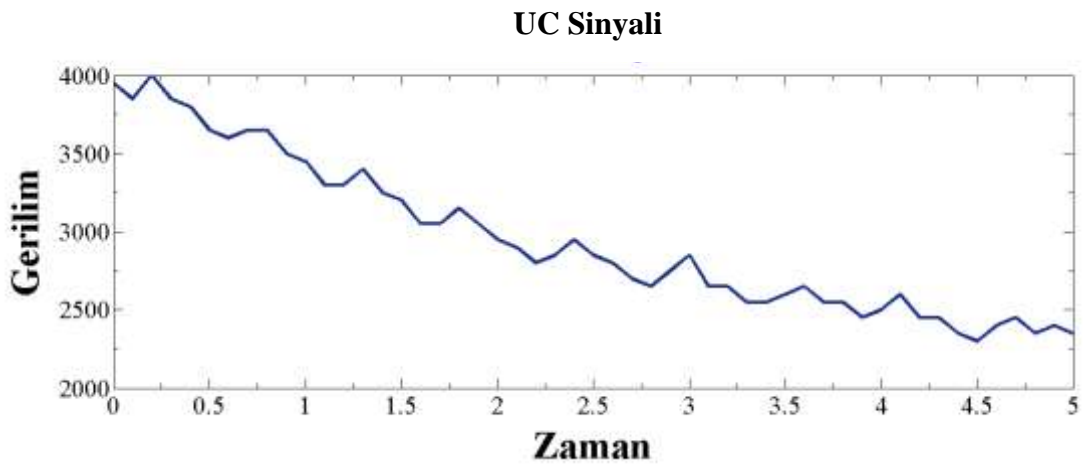


## BÖLÜM 6. UYGULAMA

Çalışmada veri setinden tek tek indirilen hastalara ait 550 CTG kaydı kullanılmıştır [21]. Her bir hasta için elde ettiğimiz fizyolojik veriler ve 4 Hz’de kaydedilmiş FHR (Şekil 6.1) ve UC (Şekil 6.2) sinyallerini analiz etmek için teknik hesaplamalarda yüksek performans gösteren bir dil olan MATLAB (Math Works, Inc., USA) yazılımı kullanılmıştır.

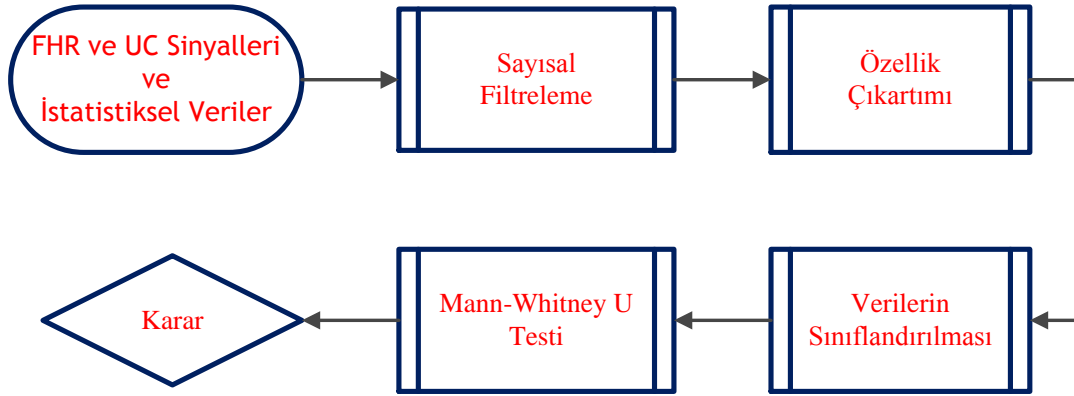


Şekil 6.1. Örnek FHR sinyali



Şekil 6.2. Örnek UC sinyali

Matlab ortamında işlem yapabilmek için veri setinden “.edf” ve “.dat” uzantılı olarak indirilen 550 hasta verisi FHR ve UC sinyalleri için ayrı ayrı edf converter programı aracılığıyla “.ascii” uzantılı dosyalara dönüştürülmüştür. Her bir hasta için matlab ortamında FHR ve UC sinyallerinden oluşan “.mat” uzantılı dosyalar oluşturulmuştur. Daha sonra 1. sütunu FHR ve 2. sütunu UC sinyallerinden oluşan Cell matrisi oluşturulmuştur. FHR ve UC sinyallerine ait Bölüm 3.4’te belirtilen öznitelikler yazılan Matlab kodları sayesinde çıkartılmıştır. FHR ve UC sinyallerinden çıkartılan özniteliklere Bölüm 3.5’te anlatılan fizyolojik veriler eklenerek sınıflandırma işlemine geçilmiştir. Uygulanan akış diyagramı Şekil 6.3’deki gibidir.



Şekil 6.3. Akış diyagramı

Elimizde bulunan verilerin %22’lik bir kısmı yapay sinir ağlarının test edilmesine ayrılmış kalan kısım ise ağı eğitilmesi için kullanılmıştır. Matlab’te kNN, PNN, RBFNN ve MLFFNN ile verilerin analizi yapılmıştır. Sonuç olarak bu uygulamaların tamamının başarı oranları incelenmiştir. Yapılan çalışmada ağlar ilk olarak eğitilmiş ardından test işlemi gerçekleştirilmiştir. Eğitim işlemi esnasında ağa yalnızca eğitim verileri gösterilmiştir [76]. Eğitim verileri bütün veriler içerisinde belli bir yüzde oranına göre rastgele seçilmiştir. Eğitim oranının %100’e yakın olmasıyla daha kesin test sonuçları elde edilmektedir [77]. Eğitim işlemi gerçekleştikten sonra ağa test verileri gösterilmiştir. Test verilerinin işlenmesinin ardından test başarı oranı hesaplanmıştır. Test başarı oranının hesaplanmasında Denklem (3.10)’daki doğruluk değeri kullanılmıştır.

$$\% \text{ Doğruluk Değeri} = \frac{\text{Doğru saptanan hasta sayısı}}{\text{Toplam hasta sayısı}} \times 100 \quad (3.10)$$

### 6.1. Fizyolojik Verileri Kullanılarak Sınıflandırma

Ağın eğitilmesi için hastalara ait verilerden yalnızca fizyolojik veriler kullanılmıştır. Eğitim veri setinde fizyolojik verilere ait çıkarılan 19 öznelik için sınıflandırma yapılmıştır. Tablo 6.1’de çıkartılan öznelikler belirtilmiştir.

Tablo 6.1. Fizyolojik verilerden çıkartılan öznelikler

	Fetüs Bilgileri	Öznelikler	Maternal Risk Faktörleri	Öznelikler	Doğum Bilgileri	Öznelikler
	Gebelik haftası	1	Yaş	1	Prezantasyon	1
	Bebeğin ağırlığı	1	Gravidite	1	Uyarılmış doğum	1
	Cinsiyet	1	Parite	1	1. evre	1
			Diyabet	1	Doğum ilerlemesi	1
			Hipertansiyon	1	CK/KP	1
			Preeklampsi	1	2. evre	1
			Likit Prekoks	1	Doğum tipi	1
			Hiperpreksi	1		
			Mekonyum	1		
Toplam		3		9		7
<b>Toplam öznelik sayısı</b>				<b>19</b>		

#### 6.1.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar

Bu uygulamada yalnızca fizyolojik verileri içeren toplam 132 anne ve fetüs kaydı kullanılmıştır. Bu 132 hastanın kayıtlarının %22’si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim için ayrılan 103 fetüsten 49 tanesine doğum eylemi sonrasında müdahale gerekirken 54 tanesine

müdahale gerekmemektedir. Test için ayrılan 29 fetüsten 17 tanesine doğum eylemi sonrasında müdahale gerekirken 12 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %62,0690 olarak hesaplanmıştır. Test için sınıflandırılan 29 bebekten 15 tanesine doğum sonrasında müdahale gerekirken 3 tanesine müdahale gerekmemektedir. 2 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 9 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 7.2’de incelenebilir.

Tablo 6.2. kNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	49	0	%100	15	2	%88,2352
<b>Müdahale Gerekmez</b>	0	54	%100	9	3	%25
<b>Ortalama</b>			<b>%100</b>			<b>%62,069</b>

Kayıtların %21’ini test için kullandığımızda fizyolojik veriler için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %67,8571 olarak hesaplanmıştır. Sonuçlar Tablo 6.3’te incelenebilir. Test için sınıflandırılan 28 bebekten 15 tanesine doğum sonrasında müdahale gerekirken 2 tanesine müdahale gerekmemektedir. 2 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 7 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır.

Tablo 6.3. kNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%21)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	49	0	%100	15	2	%88,24
<b>Müdahale Gerekmez</b>	0	54	%100	7	4	%36,36
<b>Ortalama</b>			<b>%100</b>			<b>%67,8571</b>

### 6.1.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar

Uygulamada yalnızca fizyolojik veriler kullanılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise test verisi olarak kullanılmıştır. 132 fetüsten 65 tanesine doğum eylemi sonrasında müdahale gerekirken 67 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %78,7810 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %78,7810, Test Başarı Oranı ise %55,4660 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.1'de görülmektedir. Test için sınıflandırılan 53 bebekten 33 tanesine doğum sonrasında müdahale gerekirken 20 tanesine müdahale gerekmemektedir. 17 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 6 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.4'te incelenebilir.



Şekil 6.4. MLFFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%22)


Tablo 6.4. MLFFNN sınıflandırıcıya göre fizyolojik verilerin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	40	4	%90,909	16	17	%48,4848
<b>Müdahale Gerekmez</b>	14	30	%68,1818	6	14	%70
<b>Ortalama</b>			<b>%78,781</b>			<b>%55,466</b>


### 6.1.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar

Fizyolojik veriler ile Radyal tabanlı fonksiyon sinir ağlarına göre uygulama yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise test verisi olarak kullanılmıştır. 29 hasta kaydı ağı test etmek için kullanılmış kalan 103 hasta kaydı da ağı eğitmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %41,3793 olarak hesaplanmıştır. Ağın performansı ile ilgili bilgiler Şekil 6.2'de görülmektedir.

Kayıtların %40'ı test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %62,2642 olarak hesaplanmıştır. Ağın performansı ile ilgili bilgiler Şekil 6.3'te görülmektedir.



Şekil 6.5. RBFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%22)



Şekil 6.6. RBFNN sınıflandırıcıya göre fizyolojik veriler için eğitim bilgileri (%40)

#### 6.1.4. Olasılıksal sinir ağlarına göre sonuçlar

Olasılıksal sinir ağları kullanılarak fizyolojik veriler için çalışma yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 29 hasta kaydı ağı test etmek için kullanılmış kalan 103 hasta kaydı da ağı eğitmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %58,6207 olarak hesaplanmıştır.

Kayıtların %38'i test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %66 olarak hesaplanmıştır.



## 6.2. FHR Sinyali Kullanılarak Sınıflandırma

Giriş veri setinde hastalara ait sadece FHR sinyaline ilişkin veriler kullanılmıştır. Eğitim veri setinde çıkarılan FHR sinyaline ilişkin verilere ait 10 öznelik için sınıflandırma yapılmıştır. Tablo 6.5'te çıkartılan öznelikler belirtilmiştir.

Tablo 6.5. FHR sinyalinden çıkartılan öznelikler

Öznelikler	Öznelik Sayısı
Standart sapma	1
Maksimum değer	1
Skewness katsayısı	1
Kurtosis katsayısı	1
Şekil faktörü	1
Varyans	1
Hjorth aktivite parametresi	1
Hjorth karmaşıklık parametresi	1
Ortalama eğri uzunluğu	1
Ortalama Teager enerjisi	1
<b>Toplam</b>	<b>10</b>

### 6.2.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar

Bu uygulamada yalnızca FHR sinyallerini içeren toplam 103 anne ve fetüs kaydı kullanılmıştır. Bu 103 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 fetüsten 49 tanesine doğum eylemi sonrasında müdahale gerekirken 54 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %55,1724 olarak hesaplanmıştır. Test için sınıflandırılan 29 bebekten 9 tanesine doğum sonrasında müdahale gerekirken 7 tanesine müdahale gerekmemektedir. 8 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 5 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.6'da incelenebilir.

Tablo 6.6. kNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	49	0	%100	9	8	%52,9411
<b>Müdahale Gerekmez</b>	0	54	%100	5	7	%58,3333
<b>Ortalama</b>			<b>%100</b>			<b>%55,1724</b>

Kayıtların %43'ü test için kullandığımızda fizyolojik veriler için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %67,8571 olarak hesaplanmıştır. Sonuçlar Tablo 6.7'de incelenebilir. Test için sınıflandırılan 57 bebekten 17 tanesine doğum sonrasında müdahale gerekirken 19 tanesine müdahale gerekmemektedir. 16 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 5 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır.

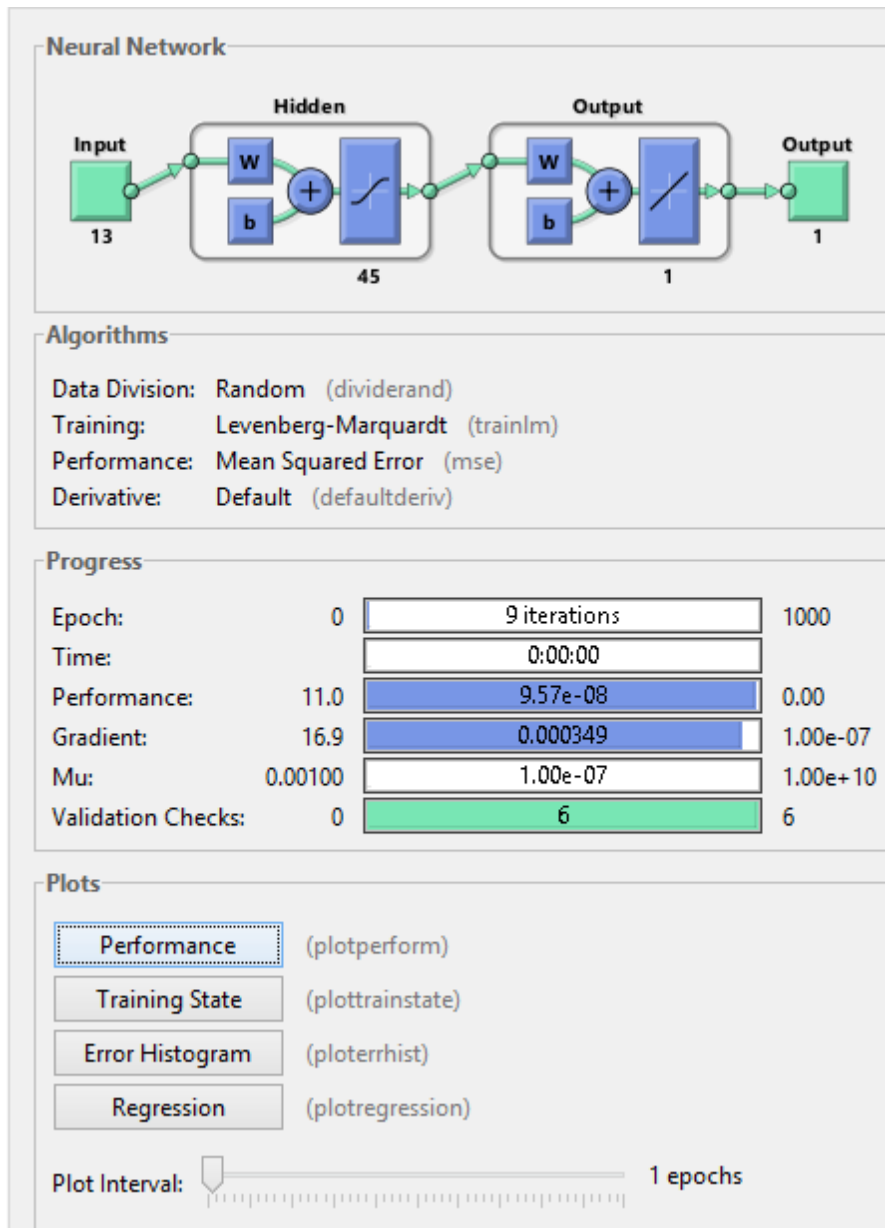
Tablo 6.7. kNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%43)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	33	0	%100	17	16	%51,52
<b>Müdahale Gerekmez</b>	0	42	%100	5	19	%79,17
<b>Ortalama</b>			<b>%100</b>			<b>%63,1579</b>

### 6.2.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar

Uygulamada yalnızca FHR sinyalleri kullanılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %71,8447 doğrulukla sonuçlandırmıştır.

Uygulamanın sonucunda Eğitim Başarı Oranı %71,8447, Test Başarı Oranı ise %62,0690 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.4'de görülmektedir. Test için sınıflandırılan 29 bebekten 15 tanesine doğum sonrasında müdahale gerekirken 8 tanesine müdahale gerekmemektedir. 2 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 4 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.8'de incelenebilir.



Şekil 6.7. MLFFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%22)


Tablo 6.8. MLFFNN sınıflandırıcıya göre FHR sinyalinin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	47	3	%94	15	2	%88,2352
<b>Müdahale Gerekmez</b>	21	33	%61,1111	4	8	%70
<b>Ortalama</b>			<b>%71,8447</b>			<b>%62,069</b>


### 6.2.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar

FHR sinyali ile Radyal tabanlı fonksiyon sinir ağlarına göre uygulama yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağı eğitmek için kullanılmış kalan 29 hasta kaydı da ağı test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %40,5405 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.5'de görülmektedir.

Kayıtların %34'ü test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %73,3333 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.6'da görülmektedir.



Şekil 6.8. RBFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%22)



Şekil 6.9. RBFNN sınıflandırıcıya göre FHR sinyali için eğitim bilgileri (%34)

#### 6.2.4. Olasılıksal sinir ağlarına göre sonuçlar

Olasılıksal sinir ağları kullanılarak fizyolojik veriler için çalışma yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağı eğitmek için kullanılmış kalan 29 hasta kaydı da ağı test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %56,667 olarak hesaplanmıştır.

Kayıtların %40'i test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %62,264 olarak hesaplanmıştır.

#### 6.3. UC Sinyali Kullanılarak Sınıflandırma

Ağın eğitilmesi için anneden alınan UC sinyaline ilişkin veriler kullanılmıştır. Eğitim veri setinde çıkarılan FHR sinyali verilerine ait 10 öznitelik için sınıflandırma yapılmıştır. Tablo 6.9'da çıkartılan öznitelikler belirtilmiştir.

Tablo 6.9. UC sinyalinden çıkartılan öznitelikler

Öznitelikler	Öznitelik Sayısı
Standart sapma	1
Maksimum değer	1
Skewness katsayısı	1
Kurtosis katsayısı	1
Şekil faktörü	1
Varyans	1
Hjorth aktivite parametresi	1
Hjorth karmaşıklık parametresi	1
Ortalama eğri uzunluğu	1
Ortalama Teager enerjisi	1
<b>Toplam</b>	<b>10</b>

### 6.3.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar

Çalışmada UC sinyalinin içeren toplam 103 anne ve fetüs kaydı kullanılmıştır. Bu 103 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 fetüsten 49 tanesine doğum eylemi sonrasında müdahale gerekirken 54 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %44,8276 olarak hesaplanmıştır. Test için sınıflandırılan 29 bebekten 7 tanesine doğum sonrasında müdahale gerekirken 6 tanesine müdahale gerekmemektedir. 10 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 6 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.10'da incelenebilir.

Tablo 6.10. kNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	49	0	%100	7	10	%41,1764
<b>Müdahale Gerekmez</b>	0	54	%100	6	6	%50
<b>Ortalama</b>			<b>%100</b>			<b>%44,8276</b>

Kayıtların %33'ü test için kullandığımızda fizyolojik veriler için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %59,0909 olarak hesaplanmıştır. Sonuçlar Tablo 6.11'de incelenebilir. Test için sınıflandırılan 44 bebekten 11 tanesine doğum sonrasında müdahale gerekirken 15 tanesine müdahale gerekmemektedir. 11 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 7 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır.

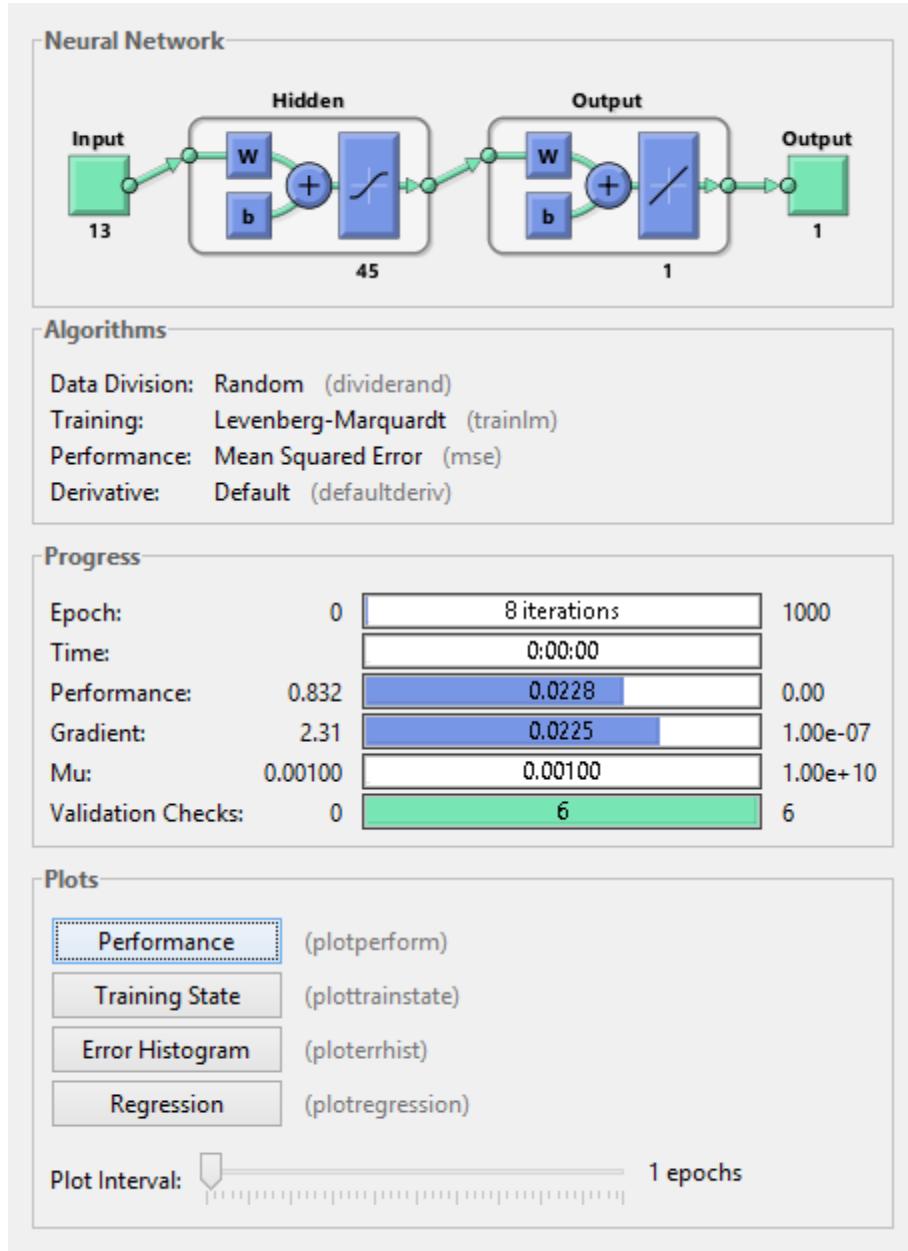
Tablo 6.11. kNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%33)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	44	0	%100	11	11	%50
<b>Müdahale Gerekmez</b>	0	44	%100	7	15	%68,18
<b>Ortalama</b>			<b>%100</b>			<b>%59,0909</b>

### 6.3.2. Çok katmanlı ileri beslemeli sinir ağlarına göre sonuçlar

Uygulamada yalnızca UC sinyalleri kullanılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %79,4118 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %79,4118, Test Başarı Oranı ise %66,6667 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.7'de görülmektedir. Test için sınıflandırılan 30 bebekten 10 tanesine doğum sonrasında müdahale gerekirken 10 tanesine müdahale gerekmemektedir. 7 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 3 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.12'de incelenebilir.





Şekil 6.10. MLFFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%22)


Tablo 6.12. MLFFNN sınıflandırıcıya göre UC sinyalinin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	37	12	%75,5102	10	7	%58,8235
<b>Müdahale Gerekmez</b>	9	44	%83,0188	3	10	%76,923
<b>Ortalama</b>			%79,4118			<b>%44,8276</b>

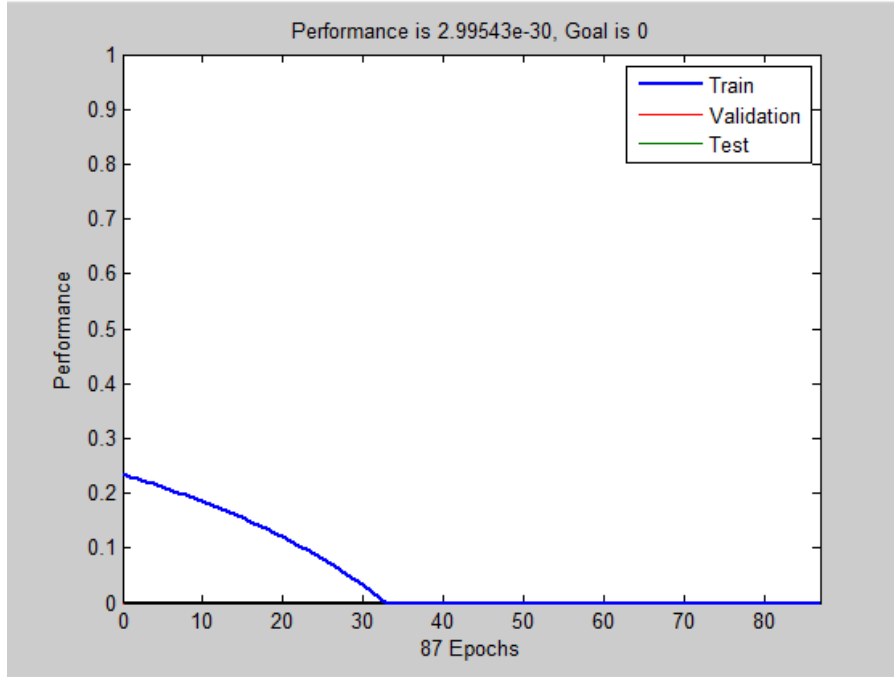
### 6.3.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar

UC sinyali ile Radyal tabanlı fonksiyon sinir ağlarına göre uygulama yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağı eğitmek için kullanılmış kalan 29 hasta kaydı da ağı test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağı bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %42,1053 olarak hesaplanmıştır. Bu sonuçların yalnızca FHR sinyalini kullanılarak yapılan sonuçlarla aynı olduğu görülmüştür. Ağı eğitilmesi ile ilgili bilgiler Şekil 6.8'de görülmektedir.

Kayıtların %36'ı test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %68,75 olarak hesaplanmıştır. Ağı eğitilmesi ile ilgili bilgiler Şekil 6.9'da görülmektedir.



Şekil 6.11. RBFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%22)



Şekil 6.12. RBFNN sınıflandırıcıya göre UC sinyali için eğitim bilgileri (%34)

#### 6.3.4. Olasılıksal sinir ağlarına göre sonuçlar

Olasılıksal sinir ağları kullanılarak fizyolojik veriler için çalışma yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağ eğitmek için kullanılmış kalan 29 hasta kaydı da ağ test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %57,895 olarak hesaplanmıştır.

Kayıtların %26'i test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %64,706 olarak hesaplanmıştır.

#### 6.4. FHR, UC sinyalleri ve fizyolojik veriler kullanılarak sınıflandırma

Giriş veri seti olarak fetüsten alınan FHR sinyali, anneden alınan UC sinyali ve anne ile bebeğin fizyolojik verileri kullanılmıştır. FHR sinyalinden 10, UC sinyalinden 10 ve fizyolojik verilerden 19 olmak üzere toplam 39 öznitelik çıkarılmıştır. Tablo 6.1, Tablo 6.5 ve Tablo 6.8’de çıkarılan öznitelikler ve sayıları belirtilmiştir.

##### 6.4.1. k en yakın komşu sınıflandırma algoritmasına göre sonuçlar

FHR, UC sinyallerini ve fizyolojik verileri içeren toplam 103 adet anne ve fetus CTG kaydı kullanılmıştır. Bu 103 hastanın kayıtlarının %22’si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır ve en yüksek başarı oranı elde edilmiştir. 103 fetüsten 49 tanesine doğum eylemi sonrasında müdahale gerekirken 54 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %72,4138 olarak hesaplanmıştır. Test için sınıflandırılan 29 bebekten 12 tanesine doğum sonrasında müdahale gerekirken 9 tanesine müdahale gerekmemektedir. 5 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 3 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.13’de incelenebilir.

Tablo 6.13. kNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik verilerin eğitim ve test başarı oranları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	49	0	%100	12	5	%70,5882
<b>Müdahale Gerekmez</b>	0	54	%100	3	9	%75
<b>Ortalama</b>			<b>%100</b>			<b>%72,4138</b>

#### 6.4.2. Çok katmanlı ileri beslemeli sinir ağılarına göre sonuçlar

Uygulamada FHR ve UC sinyallerine ek olarak fizyolojik verilerde kullanılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %83,4951 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %83,4951, Test Başarı Oranı ise %72,7273 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.10'da görülmektedir. Test için sınıflandırılan 29 bebekten 13 tanesine doğum sonrasında müdahale gerekirken 9 tanesine müdahale gerekmemektedir. 4 bebeğe müdahale gerektiği halde bebekler müdahale gerekmez olarak sınıflandırılmıştır. 3 bebeğe müdahale gerekmediği halde bebekler müdahale gerekir olarak sınıflandırılmıştır. Sonuçlar Tablo 6.14'te incelenebilir.



Şekil 6.13. MLFFNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik veriler için eğitim bilgileri (%22)


Tablo 6.14. MLFFNN sınıflandırıcıya göre FHR ve UC sinyali ile fizyolojik verilerin eğitim ve test sonuçları (%22)

	Eğitim			Test		
	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>Müdahale Gerekir</b>	43	6	%87,7551	13	4	%76,4705
<b>Müdahale Gerekmez</b>	10	44	%81,4814	3	9	%75
<b>Ortalama</b>			<b>%83,4951</b>			<b>%72,7273</b>


### 6.4.3. Radyal tabanlı fonksiyon sinir ağlarına göre sonuçlar

FHR ve UC sinyalleri ile fizyolojik veriler Radyal tabanlı fonksiyon sinir ağlarına uygulanmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağı eğitmek için kullanılmış kalan 29 hasta kaydı da ağı test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %43,3333 olarak hesaplanmıştır. Bu sonuçların yalnızca FHR ve UC sinyalleri kullanılarak yapılan sonuçlarla aynı olduğu görülmüştür. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.11'de görülmektedir.

Kayıtların %37'ı test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %67,3469 olarak hesaplanmıştır. Ağın eğitilmesi ile ilgili bilgiler Şekil 6.12'de görülmektedir.



Şekil 6.14. RBFNN sınıflandırıcıya göre FHR ve UC sinyalleri ile fizyolojik veriler için eğitim bilgileri (%22)



Şekil 6.15. RBFNN sınıflandırıcıya göre FHR ve UC sinyalleri ile fizyolojik veriler için eğitim bilgileri (%37)

#### 6.4.4. Olasılıksal sinir ağlarına göre sonuçlar

Olasılıksal sinir ağları kullanılarak fizyolojik veriler için çalışma yapılmıştır. Toplam 132 anne ve fetüs kaydı işleme alınmıştır. Bu 132 hastanın kayıtlarının %22'si test için ayrılmış kalan kısım ise eğitim verisi olarak kullanılmıştır. 103 hasta kaydı ağ eğitmek için kullanılmış kalan 29 hasta kaydı da ağ test etmek için kullanılmıştır. 132 fetüsten 66 tanesine doğum eylemi sonrasında müdahale gerekirken 66 tanesine müdahale gerekmemektedir. Eğitim işlemi sonucunda ağ bu sınıflandırmayı %100 doğrulukla sonuçlandırmıştır. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %59,46 olarak hesaplanmıştır.

Kayıtların %35'i test için ayrıldığında ise veri grubu için en yüksek başarı oranı elde edilmektedir. Uygulamanın sonucunda Eğitim Başarı Oranı %100, Test Başarı Oranı ise %71,739 olarak hesaplanmıştır.



## BÖLÜM 7. SONUÇLAR

Bu çalışmada doğum eyleminden önce fetüsten alınan FHR, anneden alınan UC ve hem anne hem de fetüsten alınan fizyolojik veriler üzerinden yapay sinir ağı sınıflandırma yöntemleri kullanılarak yeni doğan bebekler müdahale gerekir ve müdahale gerekmez sınıflarına ayırmaya çalışılmıştır. Doğumdan önce bebeğin sağlık durumunun tespit edilmesine yönelik yapılmış yeni bir yaklaşımdır. Fetal monitorizasyon ile FHR sinyallerinin incelenmesine yönelik çalışmalar bunmaktadır. FHR ve UC sinyallerinin birlikte analiz edilmesi farklı bir bakış açısıdır. Anılan sinyallere fizyolojik veriler de eklenerek daha önce çalışılmamış bir eğitim seti elde edilmiştir. Literatür çalışması sırasında doğumdan önce apgar skorunu belirlemeye yönelik bir çalışmaya rastlanmamıştır.

Hasta kayıtları içerisinde seçilen 132 hasta için kNN sınıflandırıcı sistemi ile analiz yapılmıştır. Sınıflandırıcı sisteminde kullanılması için öncelikle verilerden öznitelikleri elde etmek amacıyla Matlab kodları yazılmıştır. Yazılan özellik çıkartım fonksiyonu ile FHR ve UC sinyallerine ait öznitelikler çıkartılmış ve elde edilen bu öznitelikler fizyolojik verilere eklenerek sınıflandırıcı sisteminde kullanılan giriş veri seti elde edilmiştir.

Yapılan çalışmada ağlar ilk olarak eğitilmiş ardından test işlemi gerçekleştirilmiştir. Eğitim işlemi esnasında ağa yalnızca eğitim verileri gösterilmiştir [76]. Eğitim verileri bütün veriler içerisinde belli bir yüzde oranına göre rastgele seçilmiştir. Eğitim oranının %100'e yakın olmasıyla daha kesin test sonuçları elde edilmektedir [77]. Eğitim işlemi gerçekleştirildikten sonra ağa test verileri gösterilmiştir. Test verilerinin işlenmesinin ardından test başarı oranı hesaplanmıştır. Test başarı oranının hesaplanmasında Denklem (3.10)'daki doğruluk değeri kullanılmıştır.

Farklı veri grupları için test başarı oranları kıyaslanmıştır. Çıkarılan öznelikler ile SPSS analizi yapılmıştır. Öznelikler anlamlılık açısından incelenmiştir.

kNN, MLFFNN, PNN ve RBFNN sınıflandırıcıları kullanılarak farklı veri grupları için sınıflandırma yapılmıştır. Oluşturulan ağlar farklı veri grupları ile eğitilmiş ve sınıflandırma çıktıları incelenmiştir. Test için bütün verilerin %22'si kullanılmıştır. Ağlar ilk olarak FHR sinyali ile eğitilmiştir. Ardından UC sinyali ve fizyolojik verilerle eğitim gerçekleştirilmiştir. Son olarak ağların eğitimi için FHR, UC sinyalleri ve fizyolojik verilerin tamamı kullanılmıştır.

Tablo 6.15. kNN sınıflandırıcıya göre giriş verilerine göre doğruluk oranları (%22)

		Eğitim			Test		
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
UC Sinyali	Müdahale Gerekir	49	0	%100	7	10	%41,1764
	Müdahale Gerekmez	0	54	%100	6	6	%50
	Ortalama			%100			%44,8276
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
FHR Sinyali	Müdahale Gerekir	49	0	%100	9	8	%52,9411
	Müdahale Gerekmez	0	54	%100	5	7	%58,3333
	Ortalama			%100			%55,1724
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
Fizyolojik Veriler	Müdahale Gerekir	49	0	%100	15	2	%88,2352
	Müdahale Gerekmez	0	54	%100	9	3	%25
	Ortalama			%100			%62,0690
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
UC Sinyal eri ve Fizyolojik	Müdahale Gerekir	49	0	%100	12	5	%70,5882

	<b>Müdahale Gerekmez</b>	0	54	%100	3	9	%75
	<b>Ortalama</b>			%100			%72,4138

Tablo 6.15’te giriş verileri ile test doğruluk oranlarının değişimi görülmektedir. Ağa yalnızca UC sinyali verildiğinde %44,8276, yalnızca FHR sinyali verildiğinde %55,1724, fizyolojik veriler verildiğinde %62,0690 test doğruluk oranı elde edilmiştir. Son olarak ağa FHR ve UC sinyalleri ile fizyolojik veriler birlikte verilmiştir. Bu veri setinin başarı oranı %72,4138 ile 4 grup arasındaki en yüksek başarı oranıdır. Bu çalışmada tasarlanan kNN sınıflandırıcı ile doğumdan önce apgar skorunun belirlenmesine yönelik %72,4138 başarı elde edilmiştir. Apgar skorunun belirlenmesi için kullanıldığında, bebeklere doğum sonrasında bir müdahale gerekip gerekmeyeceğinin doğum anından önce bilinmesi açısından büyük kolaylık sağlayacaktır. Bu durum müdahale zamanını düşürerek fetal ve neonatal ölümleri minimuma indirecektir.

Tablo 6.16. MLFFNN sınıflandırıcıya göre giriş verilerine göre doğruluk oranları (%22)

		Eğitim			Test		
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>UC Sinyali</b>	<b>Müdahale Gerekir</b>	37	12	%75,5102	10	7	%58,8235
	<b>Müdahale Gerekmez</b>	9	44	%83,0188	3	10	%76,923
	<b>Ortalama</b>			%79,4118			%44,8276
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>FHR Sinyali</b>	<b>Müdahale Gerekir</b>	47	3	%94	15	2	%88,2352
	<b>Müdahale Gerekmez</b>	21	33	%61,1111	4	8	%70
	<b>Ortalama</b>			%71,8447			%62,069
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>Fizyolojik Veriler</b>	<b>Müdahale Gerekir</b>	40	4	%90,909	16	17	%48,4848
	<b>Müdahale Gerekmez</b>	14	30	%68,1818	6	14	%70

		Ortalama			%78,781			%55,466
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	
FHR ve UC Sinyalleri ve Fizyolojik Veriler	Müdahale Gerekir	43	6	%87,7551	13	4	%76,4705	
	Müdahale Gerekmez	10	44	%81,4814	3	9	%75	
	Ortalama			%83,4951			%72,7273	

Veri setimiz ileri beslemeli çok katmanlı sınıflandırıcıya uygulandığında elde edilen sonuçlar Tablo 6.16'da görülmektedir. Program yalnızca UC sinyallerine ait veriler ile koşturulduğunda %44,8276, FHR sinyaline ait veriler ile koşturulduğunda %62,069, fizyolojik veriler ile koşturulduğunda %55,466 bütün veriler birlikte kullanıldığında ise %72,7273 oranında başarı ile sonuçlanmıştır. Veriler birlikte kullanıldığında ayrı ayrı kullanıldıklarından daha fazla başarı oranına ulaşılmıştır.

Tablo 6.17. RBFNN sınıflandırıcıya göre giriş verilerine göre doğruluk oranları (%22)

		Eğitim			Test		
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
UC Sinyali	Ortalama	52	51	%100	12	17	%42,1053
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
FHR Sinyali	Ortalama	52	51	%100	17	12	%40,5405
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
Fizyolojik Veriler	Ortalama	50	50	%100	12	17	%41,3793
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
FHR ve UC Sinyalleri ve Fizyolojik Veriler	Ortalama	51	52	%100	13	16	%43,3333

Radyal tabanlı fonksiyon sinir ağlarına göre sınıflandırma yapıldığında başarı oranı oldukça düşmektedir. Sonuçlar Tablo 6.16’da görülmektedir. Veriler birlikte kullanıldığında ayrı ayrı kullanıldıklarından daha fazla başarı oranına ulaşılmasına rağmen en fazla %43,3333 başarı oranı ile sonuçlanmıştır.

Tablo 6.18. PNN sınıflandırıcıya göre giriş verilerine göre doğruluk oranları (%22)

		Eğitim			Test		
		Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı	Müdahale Gerekir	Müdahale Gerekmez	Doğruluk Oranı
<b>UC Sinyali</b>	<b>Ortalama</b>	52	51	% 100	16	13	%57,895
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>FHR Sinyali</b>	<b>Ortalama</b>	52	51	% 100	16	13	%56,667
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>Fizyolojik Veriler</b>	<b>Ortalama</b>	51	49	% 100	17	12	%58,6207
		<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>	<b>Müdahale Gerekir</b>	<b>Müdahale Gerekmez</b>	<b>Doğruluk Oranı</b>
<b>FHR ve UC Sinyalleri ve Fizyolojik Veriler</b>	<b>Ortalama</b>	52	51	% 100	17	12	%59,46

Tablo 6.18’de olasılıksak sinir ağlarına göre giriş verileri ile test doğruluk oranlarının değişimi görülmektedir.

Elde edilen sonuçlara göre kNN ve MLFFNN sınıflandırıcıları birbirine yakın başarı oranları elde ederken RBFNN ve PNN sınıflandırıcıları bu iki sınıflandırıcıya göre daha düşük başarı oranları elde etmiştir. Bütün veriler kullanıldığında elde edilen sonuçlar Tablo 6.19’da incelenebilir.

Tablo 6.19. Sınıflandırıcılara göre eğitim ve test başarı oranları

Sınıflandırıcı Tipi	Eğitim Başarı Oranı	Test Başarı Oranı
kNN	%100	%72,4138
MLFFNN	%83,4951	%72,7273
RBFNN	%100	%43,3333
PNN	%100	%59,46

### 7.1. SPSS Programına Göre Sonuçlar

Şekil 6.3'deki akış diyagramı doğrultusunda işlem adımları gerçekleştirilmiş ve Mann-Whitney U testine göre elde edilen sonuçlar Tablo 7.16, Tablo 7.17 ve Tablo 7.18'de verilmiştir [78].

FHR sinyallerine ait verilerin ortalamaları, standart sapmaları ve p değerleri Tablo 7.16'te gösterilmiştir.

Tablo 6.20. FHR sinyallerinin ortalamaları, standart sapmaları ve p değerleri

Öznitelikler	Müdahale Gerekir		Müdahale Gerekmez		P
	Ortalama	± Standart Sapma	Ortalama	± Standart Sapma	
1. Standart Sapma	5.66E+03	± 1.41E+03	5.77E+03	± 1.25E+03	0.665
2. Maksimum değer	19662.500	± 2500.7201	19532.955	± 2797.3413	0.652
3. Skewness katsayısı	-2.67E+00	± 2.57E+00	-2.48E+00	± 2.48E+00	0.665
4. Kurtosis katsayısı	2.42E+01	± 4.12E+01	2.13E+01	± 3.69E+01	0.633
Şekil faktörü	1.35E+02	± 1.40E+01	1.35E+02	± 1.35E+01	0.598
Varyans	3.39E+07	± 1.56E+07	3.48E+07	± 1.33E+07	0.665
Hjorth aktivite parametresi	3.39E+07	± 1.56E+07	3.48E+07	± 1.33E+07	0.665
8. Hjorth karmaşıklık parametresi	3.24E+00	± 1.17E+00	2.90E+00	± 9.73E-01	0.085
9. Ortalama Eğri uzunluğu	-2.37E+00	± 3.90E-01	-2.44E+00	± 4.61E-01	0.311
10. Ortalama teager enerjisi	1.32E+06	± 1.10E+06	1.39E+06	± 9.55E+05	0.328

UC sinyallerine ait verilerin ortalamaları, standart sapmaları ve p değerleri Tablo 7.17'te gösterilmiştir.

p değerleri açısından Tablo 7.16'da bulunan öznitelikler anlamlı bir farklılık oluşturmazken Tablo 7.17'te yalnızca 9. öznitelik anlamlı bir farklılık

oluşturmaktadır. p değerinin 0.05'ten küçük olması, bu özelliğin istatistiksel olarak anlamlı olduğu ve sınıflara ayırmada kullanılabileceği anlamına gelmektedir.

Tablo 6.21. UC sinyallerinin ortalamaları, standart sapmaları ve p değerleri

Öznitelikler	Müdahale Gerekir		Müdahale Gerekmez		P
	Ortalama	Standart Sapma	Ortalama	Standart Sapma	
1. Standart Sapma	2.47E+03	7.77E+02	2.44E+03	6.03E+02	0.877
2. Maksimum değer	9899.242	2794.9885	10020.455	2698.0189	0.822
3. Skewness katsayısı	-6.33E+00	5.12E+00	-6.61E+00	5.19E+00	0.806
4. Kurtosis katsayısı	1.21E+02	1.05E+02	1.22E+02	9.98E+01	0.799
5. Şekil faktörü	9.38E+01	2.24E+01	1.01E+02	6.31E+01	0.917
6. Varyans	6.72E+06	5.09E+06	6.33E+06	3.09E+06	0.877
7. Hjorth aktivite parametresi	6.72E+06	5.09E+06	6.33E+06	3.09E+06	0.877
8. Hjorth karmaşıklık parametresi	6.63E+00	2.29E+00	6.24E+00	1.95E+00	0.518
9. Ortalama Eğri uzunluğu	-1.89E+00	2.00E-01	-2.01E+00	2.23E-01	0.001
10. Ortalama teager enerjisi	1.25E+05	2.25E+05	8.58E+04	2.71E+04	0.193

Fetüs bilgileri, anneyle ilgili risk faktörleri ve doğum bilgileriyle alakalı verilerin ortalaması ile standart sapma ve p değerleri Tablo 7.18'da gösterilmiştir. Tablo 7.18'deki sonuçlar ışığında; 12, 13, 16 ve 25 numaralı özniteliklerin p değerlerinin 0.05'ten küçük olduğu görülmektedir. Dolayısı ile “müdahale gerekir” ve “müdahale gerekmez” diye adlandırılan iki sınıf bu öznitelikler bakımından farklı iki sınıf olarak ayırt edilebilmektedir.

Bu çalışma sonucunda çıkarılan 45 öznitelikten 26 tanesi SPSS analizinde kullanılmış ve bunların içinden 5 öznitelik istatistiki açıdan anlamlı bulunmuştur. Bu öznitelikler fetüs bilgileri, anneyle ilgili risk faktörleri ve doğum bilgileriyle alakalı öznitelik 12, 13, 16, 25 ve UC sinyali için çıkarılan öznitelik 9'dur. Bu öznitelikler bakımından iki sınıf arasında anlamlı bir farklılık vardır.

Tablo 6.22. İstatistiki verilerin ortalamaları, standart sapmaları ve p değerleri

Öznitelikler	Müdahale Gerekir			Müdahale Gerekmez			p
	Ortalama	±	Standart Sapma	Ortalama	±	Standart Sapma	
<b>Gebelik haftası</b>	39.788	±	1.1302	84.015	±	358.2072	0.702
<b>Bebeğin ağırlığı (g)</b>	3441.364	±	443.0589	3243.591	±	626.4837	0.044
<b>Cinsiyet</b>	1.348	±	0.4801	2.000	±	3.6585	0.013
<b>Yaş</b>	28.758	±	5.5666	30.091	±	5.9271	0.077
<b>Gravidite</b>	1.242	±	0.7455	1.530	±	1.0985	0.060
<b>Parite</b>	0.227	±	0.4573	0.591	±	0.7437	0.002
<b>Diyabet</b>	0.045	±	0.2099	0.091	±	0.2897	0.302
<b>Hipertansiyon</b>	0.091	±	0.2897	0.045	±	0.2099	0.302
<b>Preeklampsi</b>	0.076	±	0.2666	0.030	±	0.1727	0.246
<b>Likit Prekoks</b>	0.273	±	0.4488	0.288	±	0.4562	0.847
<b>Hiperpreksi</b>	0.000	±	0.0000	0.000	±	0.0000	1.000
<b>Mekonyum</b>	0.106	±	0.3103	0.030	±	0.1727	0.085
<b>Prezantasyon</b>	1.212	±	0.5411	1.167	±	0.5430	0.339
<b>Uyarılmış doğum</b>	0.333	±	0.4750	0.379	±	0.4888	0.587
<b>2. evre</b>	13.727	±	8.5459	8.545	±	7.5165	0.000
<b>Doğum tipi</b>	1.152	±	0.3613	1.197	±	0.4008	0.493

Sonraki çalışmalarda FHR ve UC sinyallerinden elde edilecek farklı özniteliklerle yeni analizler gerçekleştirilebilir. Öznitelik sayısının artması yapılan analizin doğruluk oranını arttıracaktır.



## KAYNAKLAR

- [1] N. Çiçek, C. Akyürek, Ç. Çelik ve A. Haberal, *Kadın Hastalıkları ve Doğum Bilgisi*, İstanbul, 2006.
- [2] N. Comart, *Elektronik Fetal Kalp Hızı Monitörizasyonu: Normal Monitör, Fetal Stres, Fetal Distres ile İlişkili Erken Neonatal Sonuçlar*, İstanbul, 2006.
- [3] V. Apgar, «A Proposal for a New Method of Evaluation of the Newborn Infant,» *Current Researches in Anesthesia and Analgesia*, July-August 1953.
- [4] P. Boylan, «Intrapartum fetal monitoring,» %1 içinde *Bailliere's Clinical Obstetrics and Gynaecology*, 1987.
- [5] L. C. Gilstrap, J. C. Hauth ve G. D. Hankins, «Second-Stage Fetal Heart Rate Abnormalities and Type of Neonatal Acidemia,» *Obstet Gynecol*, 1987.
- [6] H. Z. Z. Faridah, I. Nazimah ve S. W. Tham, «Second Stage Fetal Heart Rate Patterns and Neonatal Acid-Base Status,» *leJSME*, 2012.
- [7] P. J. Steer, F. Eigbe, T. J. Lissauer ve R. W. Beard, «Interrelationships among Abnormal Cardiotocograms in Labor, Meconium Staining of The Amniotic Fluid, Arterial Cord Blood pH, and Apgar Scores,» *Obstet Gynecol*, 1989.
- [8] H. Helgason, P. Abry, P. Gonçaves, C. Gharib, P. Gaucherand ve M. Doret, «Adaptive Multiscale Complexity Analysis of Fetal Heart Rate,» *IEEE Transactions on Biomedical Engineering*, cilt 58, no. 8, 2011.
- [9] M. Jezewski, R. Czabanski, J. Wrobel ve K. Horoba, «Analysis of Extracted Cardiotocographic Signal Features to Improve Automated Prediction of Fetal Outcome,» *Biocybernetics and Biomedical Engineering*, cilt 30, no. 4, pp. 29-47, 2010.
- [10] A. Georgieva, S. J. Payne, M. Moulden ve C. W. G. Redman, «Artificial Neural Networks Applied to Fetal Monitoring in Labour,» *Neural Computing and Applications*, no. 22, pp. 85-93, 2013.
- [11] V. Chudacek, J. Spilka, P. Janku, M. Koucky, L. Lhotska ve M. Huptych, «Automatic Evaluation of Intrapartum Fetal Heart Rate Recordings: a Comprehensive Analysis of Useful Features,» *IOPscience*, no. 32, pp. 1347-1360, 2011.

- [12] A. A. Sivaslıođlu, S. Dilbaz, B. Dilbaz, İ. Dölen, Ö. Özdeğirmenci ve A. Haberal, «Birinci Trimester Gebelerde Gestasyonel Kесе Hacmi, Embriyonik Kalp Atım Sayısı ve En Uzun Çapının Gebelik Prognozundaki Rölü,» *Kadın Doğum Dergisi*, pp. 181-183, 2004.
- [13] J. G. Aaroudse, H. J. Huisjes ve H. Gordon, «Fetal Subcutaneous Scalp pO<sub>2</sub> and Abnormal Heart Rate During Labor,» *Am J Obstet Gynecol*, 1988.
- [14] I. M. Fields, S. S. Entman ve F. H. Boehm, «Correlation of One Minute Apgar Score and The pH Value of Umbilical Arterial Blood,» *South Med J*, 1983.
- [15] R. L. Goldenberg, J. F. Huddlestone ve K. G. Nelson, «Apgar Score and Umbilical Arterial Ph in Preterm Newborns,» *Am J Obstet Gynecol*, no. 149, p. 651, 1984.
- [16] J. S. Drage ve C. Kennedey, «The Apgar Score as an İndex of Neonatal Mortality,» *Obstet Gynaecol*, 1964.
- [17] L. C. Gilstrap, M. C. Williams, K. J. Levono ve J. Burris, «Diagnosis of Birth Asphyxia on the Basis of Fetal pH, Apgar Scores and Newborn Cerebral Dysfunction,» *Am J Obstet Gynecol*, 1989.
- [18] E. A. Catlin, M. W. Carpenter, B. S. Brann, S. R. Mayfield, P. W. Shaul, M. Goldstein ve W. Oh, «The Apgar Score Revisited: Influence of Gestational Age.,» *J Pediatr*, cilt 8, no. 865, pp. 109-114, 1986.
- [19] K. B. Nelson ve J. H. Ellenberg, «Apgar Scores as Predictors of Chronic Neurologic Disability,» *Pediatrics*, no. 68, p. 36, 1981.
- [20] G. Can, O. Neyzi ve T. Ertuğrul, *Pediatrici*, İstanbul, 1989.
- [21] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. Ivanov, R. Mark, J. Mietus, G. Moody, C.-K. Peng ve H. Stanley, «The CTU-UHB Intrapartum Cardiotocography Database,» *PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals*, cilt 101, no. 23, pp. e215-e220, 2000.
- [22] T. P. Sartwelle, L. B. ve B. B. A., «Electronic Fetal Monitoring,» *The Journal of Legal Medicine*, no. 33, pp. 313-379, 2012.
- [23] A. Seyhun, «NST Ne Kadar Güvenilirdir,» Buca Kadın Doğum ve Çocuk Hastanesi, İzmir.
- [24] M. R. Harrison ve R. W. Jennings, «Monitoring Uterine Contractions by Radiotelemetric Transmission». United States of America Patent: US 5373852 A, 1994.
- [25] K. Agnieszka, E. Oczeretko, J. Swiatecka, M. Borowska ve T. Laudanski, «Uterine Constriction Signals-Application of the Linear Synchronization

Measures,» *European Journal of Obstetrics & Gynecology and Reproductive Biology*, no. 144S, pp. S61-S64, 2009.

- [26] Ş. Bülbül, Tanımlayıcı İstatistik, İstanbul: Der Yayınları, 2000.
- [27] M. Köseoğlu ve R. Yamak, Uygulamalı İstatistik ve Ekonometri, Trabzon: Celepler Matbaacılık, 2004.
- [28] N. Çömlekçi, Temel İstatistik İlke ve Teknikleri, Bilim Teknik Yayınevi, 1994.
- [29] J. M. Bland ve D. G. Altman, «Measurement Error,» *Biomedical Journal*, no. 312, 1996.
- [30] S. Gorard, «Revisiting a 90-Year-Old Debate: The Advantages of The Mean Deviation,» %1 içinde *British Educational Research Association Annual Conference*, 2004.
- [31] R. Alpar, Uygulamalı İstatistik ve Geçerlik-Güvenilirlik, Ankara: Detay Yayıncılık, 2012.
- [32] U. Arifoğlu, Elektrik-Elektronik Mühendisliğinin Temelleri Alternatif Akım Devreleri Cilt II, İstanbul: Alfa Basım Yayım Dağıtım, 2000.
- [33] R. A. Groeneveld ve G. Meeden, «Measuring Skewness and Kurtosi,» *The Statistician*, no. 33, pp. 391-399, 1984.
- [34] P. T. Hippel, «Mean, Median, and Skew: Correcting a Textbook Rule,» *Journal of Statistic Education*, no. 13, 2005.
- [35] S. Brown, *Measures of Shape: Skewness and Kurtosis*, Tompkins Cortland Community College, 2008.
- [36] Ç. Arıkan ve M. Özdemir, «Bazı Güç Kalitesi Bozunumlarının Belirlenmesinde Çarpıklık ve Basıklık Katsayıları İle Dalgacık Katsayılarından Enerji Yöntemiyle Özellik Çıkarımı Yönteminin Karşılaştırılması,» %1 içinde *V.ENERJİ VERİMLİLİĞİ VE KALİTESİ SEMPOZYUMU*, Kocaeli, 2013.
- [37] Ç. Arıkan ve M. Özdemir, «Güç Sistemlerinde Görülen Bazı Güç Kalitesi Bozunumlarının Belirlenmesinde Dalgacık Yaklaşımı Ve Çarpıklı-Basıklık Katsayıları,» %1 içinde *Elektrik Elektronik Bilgisayar Mühendisliği Sempozyumu*, Bursa, 2012.
- [38] Ç. Akıncı, T. Taşkın, S. Şeker ve H. Kaymaz, «Dalgacık Dönüşümü Kullanılarak Bir Yolcu Otobüsü Alternatörünün Sıcaklık Değişiminin İstatistiksel Analizi,» %1 içinde *Elektrik Elektronik Bilgisayar Mühendisliği Sempozyumu*, Bursa, 2006.

- [39] Ç. Kocaman ve M. Özdemir, «Çarpıklık Ve Basıklık Katsayılarının Güç Kalitesi Bozunumlarının Oluşum Yerine Göre Değişimi,» %1 içinde *Elektrik Elektronik Bilgisayar Mühendisliği Sempozyumu*, Bursa.
- [40] J. Fu, N. Li, L. Li, R. Luo ve Q. Zhou, *The Obtainment of Particle Shape Factor by the Combination of Experimental Data and Fluid-particle Reaction Model*, Powder Technology, 2015.
- [41] Y. Zhang, H. Wu ve L. Cheng, «Some New Deformation Formulas About Variance and Covariance,» %1 içinde *Proceedings of 4th International Conference on Modelling, Identification and Control*, 2012.
- [42] N. William, *Statistics for Engineers and Scientists*, 2006.
- [43] D. C. Montgomery ve G. C. Runger, *Applied Statistics and Probability for Engineers*, New York: John Wiley & Sons, 1994.
- [44] B. Hjorth, «EEG Analysis Based on Time Domain Properties,» *Electroencephalography and Clinical Neurophysiology*, no. 29, pp. 306-310, 1970.
- [45] E. Avşar, *Tek-Sınıf Destek Vektör Makineleri Kullanılarak Epileptik EEG İşaretlerinin Sınıflandırılması*, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, 2009.
- [46] M. Yıldız, *Uyku Evrelerinin EEG İşaretleri Kullanılarak Sınıflandırılmasında Yeni Bir Yaklaşım*, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2009.
- [47] K. Ramachandran ve C. Tsokos, *Mathematical Statistics with Applications in R*, Waltham, ABD: Elsevier, 2014.
- [48] M. Vourkas, G. Papadourakis ve S. Micheloyannis, «Use of ANN and,» *Ist International*, pp. 327-332, 2000.
- [49] A. B. Gardner, A. E. Krieger, G. Vachtsevanos ve B. Litt, «One-Class Novelty Detection for Seizure Analysis from Intracranial EEG,» *Journal of Machine Learning Research*, no. 7, pp. 1025-1044, 2006.
- [50] R. Esteller, J. Echauz, T. Tchong, B. Litt ve B. Pless, «Line Length: An Efficient Feature for Seizure Onset Detection,» %1 içinde *Proceedings of the 23rd Annual EMBS International Conference*, 2001.
- [51] M. J. Lipsey ve J. P. Havlicek, *On the Teager-Kaiser Energy Operator Low Frequency Error*, Norman: University of Oklahoma, School of Electric and Computer Engineering.
- [52] E. F. Velez, *Detection of Multi-tone Signals Based on Energy Operators*, Ontario: Northern Telecom Limited, Telecom Microelectronics Center.

- [53] R. Hamila, M. Renfors, T. Haverinen ve G. Gunnarsson, «Teager-Kaiser Operator Based Filtering,» Tampere University of Technology, Tampere.
- [54] E. Kvedalen, *Signal processing using the Teager Energy Operator and other nonlinear operators*, University of Oslo, Department of Informatics, 2003.
- [55] J. F. Kaiser, «On a Simple Algorithm to Calculate the ‘energy’ of a Signal.,» no. 1, pp. 381-384, 1990.
- [56] R. B. Holtzman ve C. V. Bonzat, «Perinatal Management of Meconium Staining of the Amniotic Fluid,» *Clinics in Perinatology*, no. 825, p. 16, 1989.
- [57] E. Öztemel, *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık, 2003.
- [58] Ç. Elmas, *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Ankara: Seçkin Yayıncılık, 2003.
- [59] M. K. Uçar, *SSR Verilerinin YSA ile İşlenerek Psikolojik Test Skorlarının Sınıflandırılması*, Sakarya: Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2013.
- [60] C. Hamzaçebi, *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamaları*, Bursa: Ekin Basım Yayın Dağıtım, 2011.
- [61] H. Yurtoğlu, *Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği*, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, 2005.
- [62] L. Rokach, «Ensemble Methods for Classifiers,» %1 içinde *Data Mining and Knowledge Discovery Handbook*, Springer US, 2005, pp. 957-980.
- [63] E. Dimitriadou, A. Weingessel ve K. Hornik, «A Cluster Ensembles Framework,» *Design and Application of Hybrid Intelligent Systems*, 2003.
- [64] L. Rokach, A. Schclar ve E. Itach, «Ensemble Methods for Multi-label Classification,» *Expert Systems with Applications*, no. 41, p. 16, 2014.
- [65] P. Wallisch, M. Lusignan, M. Benayoun, T. Baker, A. Dickey ve N. Hatsopoulos, *MATLAB for Neuroscientists (Second Edition): An Introduction to Scientific Computing in MATLAB*, ABD: Elsevier, 2014.
- [66] V. Cheung ve K. Cannons, *Probabilistic Neural Networks*, Manitoba, Canada: University of Manitoba, 2002.
- [67] D. F. Specht, «Probabilistic Neural Networks for Classification, Mapping, or Associative Memory,» %1 içinde *IEEE International Conference on Neural Networks*, 1998.
- [68] D. F. Specht, «Enhancements to Probabilistic Neural Networks,» %1 içinde *International Joint Conference on Neural Networks*, 1992.

- [69] Y. Cai ve X. Wang, «The Analysis and Optimization of KNN Algorithm Space-Time Efficiency for Chinese Text Categorization,» %1 içinde *Advances in Computer Science, Enviroment, Ecoinformatics and Education*, Wuhan, China, 2011.
- [70] G. J. Myatt, *Making Sence of Data: A Practical Guide to Exploratory Data Analysis and Data Mining*, Wiley, 2007.
- [71] F. Bulut ve M. F. Amasyalı, *En Yakın k Komşuluk Algoritmasında Örneklerle Bağlı Dinamik k Seçimi*, İstanbul.
- [72] J. Farajzadeh, A. F. Fard ve S. Lotfi, «Modeling of Monthly Rainfall and Runoff of Urmialake Basin Using Feed-Forward Neural Network and Time Series Analysis Model,» *Water Resources and Industry*, no. 7, pp. 38-48, 2014.
- [73] M. D. Perez-Godoy, A. J. Rivera, C. J. Carmona ve M. J. Jesus, «Training Algorithms for Radial Basis Function Networks to Tackle Learning Processes with Imbalanced Data-Sets,» *Applied Soft Computing*, no. 25, pp. 26-39, 2014.
- [74] J. Park ve I. Sandberg, «Universal Approximation Using Radial-Basis Function,» *Neural Computer*, no. 3, pp. 246-257, 1991.
- [75] O. Buchtala, M. Klimek ve B. Sick, «Evolutionary Optimization of Radial Basis Function Classifiers for Data Mining Applications,» *IEEE Transactions on Systems, Man, and Cybernetics*, cilt 35, no. IEEE, 2005.
- [76] H. Demuth, M. Beale ve M. Hagan, *Neural Network Toolbox User's Guide for Use with MATLAB*, Mathworks, Inc., 2007.
- [77] Ö. Özkan, *Sempatik Deri Cevabı İşaretinin Yapay Sinir Ağları ile Fibromiyalji Sendromunun Teşhisinde Kullanılması*, Sakarya: Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, 2012.
- [78] B. D. Güngör, M. K. Uçar ve F. Bozkurt, «Statistical Investigation of the Effects of Fetal Heart Rate (FHR) and Uterine Contractions (UC) Signals on Apgar,» *International Journal of Computer Applications*, no. 117, 2015.

## ÖZGEÇMİŞ

Barış Doruk GÜNGÖR, 18.04.1990 tarihinde Sakarya'da doğdu. İlk eğitimini İstanbul'da, orta ve lise eğitimini Sakarya'da tamamladı. 2007 yılında Şehit Üsteğmen Selçuk Esedođlu Anadolu Lisesi, Fen Bölümünden mezun oldu. 2007 yılında başladığı Sakarya Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünü 2012 yılında bitirdi. Aynı yıl Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisansa başladı. 2012 - 2013 yılları arasında İnci Gruba bađlı İnciler Endüstriyel Makine İmalat Sanayi ve Tic. Ltd. Şti 'de Ar-Ge mühendisi olarak çalıştı. Bu süre içerisinde şirketin yeni ürün projelerinin yanı sıra iş sağlığı ve güvenliği, verimlilik projeleri ve toplam kalite yönetimi projelerinde aktif rol aldı. 2013 yılından itibaren Kocaeli Üniversitesi, Biyomedikal Mühendisliği Bölümünde Araştırma Görevlisi olarak görev yapmaktadır.