



**BİYOMEDİKAL İŞARETLERİN SINIFLANDIRILMASI İÇİN
AKILLI TEKNİKLERİN LABVIEW ORTAMINDA
GERÇEKLENMESİ**

Yük. Müh. Duygu KAYA

Doktora Tezi

**Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Mustafa TÜRK**

MAYIS-2018

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



**BİYOMEDİKAL İŞARETLERİN SINIFLANDIRILMASI İÇİN AKILLI
TEKNİKLERİN LABVIEW ORTAMINDA GERÇEKLENMESİ**

Yük. Müh. Duygu KAYA

Doktora Tezi

**Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Mustafa TÜRK**

MAYIS-2018

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

**BİYOMEDİKAL İŞARETLERİN SINIFLANDIRILMASI İÇİN AKILLI
TEKNİKLERİN LABVIEW ORTAMINDA GERÇEKLENMESİ**

DOKTORA TEZİ

Duygu KAYA

(131113203)

Tezin Enstitüye Verildiği Tarih : 10-04-2018

Tezin Savunulduğu Tarih : 08-05-2018

Tez Danışmanı : Doç. Dr. Mustafa TÜRK (Fırat Ü.)

Diğer Jüri Üyeleri: Prof. Dr. Yakup Demir (Fırat Ü.)

Doç. Dr. Taner TUNCER (Fırat Ü.)

Dr. Öğr. Üyesi M. Ali ARSERİM (Dicle Ü.)

Dr. Öğr. Üyesi Cafer BUDAK (Batman Ü.)

MAYIS-2018

ÖNSÖZ

Yürütülen bu tez çalışmasında, akıllı hesaplama teknikleri kullanılarak önerilen algoritmalarla farklı biyomedikal işaretlerin sınıflandırılması ile kişinin hasta-sağlıklı olduğuna dair durum tespiti için LabVIEW ortamında gerçekleştirilmiştir. Ayrıca kalp atış hızı tespiti ve kan basıncı tespiti de LabVIEW ortamında yapılmıştır.

Çalışmalarım süresince bana her konuda yardımcı olan, olabilecek sorunlara karşı farklı açılarla bakmamı sağlayan ve gelecekte iyi bir akademisyen olmam için tecrübelerinden faydalandığım danışmanım Sayın Doç. Dr. Mustafa TÜRK'e teşekkürlerimi sunarım.

Tez süresi boyunca gösterdikleri hoşgörü ve iyi niyetleri için tez izleme komitesi üyeleri Sayın Prof. Dr. Yakup DEMİR ve Sayın Doç. Dr. Taner TUNCER' e teşekkür ederim.

Ayrıca çalışmalarım süresince manevi desteğini esirgemeyen değerli eşim Dr. Öğretim Üyesi Turgay KAYA'ya, varlığı bende her zaman pozitif enerjiye dönüşen minik kızım Elçin'ime ve benim bugünlere gelmemi sağlayan anneme ve dedeme çok teşekkür ederim.

Duygu KAYA

ELAZIĞ-2018

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	I
İÇİNDEKİLER.....	II
ÖZET	V
SUMMARY	VII
ŞEKİLLER LİSTESİ	IX
TABLolar LİSTESİ	XI
KISALTMALAR LİSTESİ	XII
SEMBOLLER LİSTESİ	XIII
1. GİRİŞ	I
1.1. Genel Bakış	I
1.2. Literatür Özeti	3
1.3. Problemin Tanımlanması ve Tezin Amacı	6
1.4. Tezin Yapısı	7
2. BİYOMEDİKAL İŞARETLER.....	9
2.1. Giriş.....	9
2.2. Elektriksel Kökenli İşaretler	10
2.2.1. ElektroKardiyoGram (EKG).....	10
2.2.2. ElektroEnsefaloGram (EEG)	12
2.2.5. ElektroGastoGram (EGG).....	14
2.3. Elektriksel Kökenli Olmayan İşaretler.....	16
2.3.1. Göğüs Kanseri.....	17
2.3.2. Kan Basıncı	18
3. SİNYAL ANALİZ METOTLARI.....	19
3.1. Giriş.....	19
3.2. Fourier Dönüşümü	19
3.3. Dalgacık ve Dalgacık Dönüşümü	20
3.3.1. Dalgacık Dönüşümü Yöntemleri	22
3.3.1.1. Sürekli Dalgacık Dönüşümü (SDD)	22
3.3.1.2. Ayırık Dalgacık Dönüşümü (ADD).....	23
3.4. Spektral Kestirim Yöntemleri	24
3.4.1. Sonlu Süreli İşaretlerin Spektral Kestirimi	24

3.4.1.1.	Deterministik İşaretlerin Enerji Yoğunluk Spektrumunun Hesaplanması.....	25
3.4.1.2.	Rastgele İşaretlerin Güç Spektrum Kestirimi	25
3.4.2.	Güç Spektrum Kestirimi İçin Parametrik Olmayan Yöntemler.....	26
3.4.2.1.	Bartlett Yöntemi (Periyodogramların Ortalanması)	26
3.4.2.2.	Welch Yöntemi (Değiştirilmiş Periyodogramların Ortalanması)	26
3.4.2.3.	Blackman ve Tukey Yöntemi (Periyodogramların Yumuşatılması)	27
3.4.3.	Güç Spektrum Kestirimi için Parametrik Yöntemler.....	27
4.	AKILLI HESAPLAMA YÖNTEMLERİ.....	29
4.1.	Yapay Sinir Ağları (YSA).....	29
4.1.1.	Yapay Sinir Ağının Ana Öğeleri.....	30
4.2.	Yapay Sinir Ağlarının Yapısı.....	33
4.3.	Yapay Sinir Ağlarında Öğrenme	34
4.4.	YSA'nın Sınıflandırılması	34
4.4.1.	Yapılarına Göre YSA'lar	34
4.4.2.	Öğrenme Algoritmalarına Göre YSA'lar.....	35
4.4.3.	Katman Sayılarına Göre YSA'lar	35
4.5.	Makine Öğrenmesi (MÖ).....	37
4.5.1.	Denetimli Öğrenme Algoritmaları	37
4.5.1.1.	Destek Vektör Makinesi (DVM)	38
4.5.1.1.1.	Doğrusal Olarak Ayrılabilen Veri Kümeleri İçin DVM	39
4.5.1.1.2.	Doğrusal Olarak Ayrılamayan Veri Kümeleri için DVM.....	42
4.5.1.2.	En Yakın Komşu Algoritması (k-NN)	45
4.5.2.	Denetimsiz Öğrenme Algoritmaları.....	45
4.5.3.	Boyut Azaltma Algoritmaları	46
4.5.3.1.	Temel Bileşenler Analizi (TBA).....	47
4.5.3.2.	Doğrusal Ayrıştırma Analizi (Linear Discriminant Analysis).....	53
4.5.3.3.	Çekirdek Temel Bileşen Analizi	57
4.6.	Akıllı Hesaplama Yöntemlerinin Uygulama Alanları	58
5.	LabVIEW.....	59
5.1.	LabVIEW (Sanal Enstrüman)	59
5.1.1.	Biyomedikal Araç Kiti	62
5.1.2.	İleri Sinyal İşleme Araç kiti	63
5.1.3.	Makine Öğrenmesi Araç Kiti.....	64
5.1.4.	İleri Çizim Araç Kiti	65

6.	DENEYSEL SONUÇLAR.....	66
6.1.	YSA ile Sınıflandırma Bloğu.....	67
6.2.	DVM ile Sınıflandırma Bloğu	68
6.3.	TBA ile Boyut Azaltma Bloğu	69
6.4.	DAA ile Boyut Azaltma Bloğu.....	71
6.5.	Kernel TBA ile Boyut Azaltma Bloğu.....	72
6.6.	LabVIEW Performans Analizi.....	74
6.6.1.	YSA ile Sınıflandırma.....	74
6.6.2.	TBA Uygulanmış Verinin DVM ile Sınıflandırılması.....	77
6.6.3.	DAA Uygulanmış Verinin DVM ile Sınıflandırılması	80
6.6.4.	Kernel TBA Uygulanmış Verinin DVM ile Sınıflandırılması.....	82
6.7.	Önerilen Yöntemler	84
6.7.1.	Göğüs Kanseri Verilerinin MÖ Algoritmaları ile Sınıflandırılması	84
6.7.1.1.	Seri TBA-DAA-DVM Modeli	86
6.7.1.2.	Paralel TBA-DAA-DVM Modeli	90
6.7.1.3.	Seri KTBA-DAA-DVM Modeli	93
6.7.1.4.	Paralel KTBA-DAA-DVM Modeli	97
6.7.2.	EEG İşaretlerinin MÖ Algoritmaları ile Sınıflandırılması	100
6.7.3.	EK Uygulamalar	102
6.7.3.1.	EKG İşaretlerinden Kalp Atış Hızı Tespiti	102
6.7.3.2.	Kan Basıncı Verilerinden Kan Basıncı Tespiti	103
7.	SONUÇLAR VE GELECEK ÇALIŞMALAR	105
7.1.	Sonuçlar	105
7.2.	Gelecek Çalışmalar	107
8.	KAYNAKLAR	109
	ÖZGEÇMİŞ.....	121

ÖZET

Bu tez çalışmasında, biyomedikal işaretler kullanılarak elde edilen veri kümesinden, kişinin hasta mı yoksa sağlıklı mı olduğunu tespit edebilmek için akıllı hesaplama yöntemleri kullanılarak yeni sınıflandırma algoritmaları geliştirilmiştir. Bu algoritmalar, literatürde kullanımı gittikçe yaygınlaşan ve bir görsel programlama dili olan LabVIEW programı kullanılarak geliştirilmiştir.

Gerçekleştirilen tez çalışması genel olarak iki kısımdan oluşmuştur. İlk kısımda LabVIEW'in çalışma performansı MATLAB ile karşılaştırılmıştır. Bunun için literatürde boyut azaltma algoritmalarıyla özellik seçimi yapmayı sağlayan; Temel Bileşen Analizi (TBA), Doğrusal Ayırıştırma Analizi (DAA) ve Kernel Temel Bileşen Analizi (KTBA) kullanılmıştır. Sınıflandırma algoritmalarından ise Destek Vektör Makinesi (DVM) kullanılmıştır. Sınıflandırma performanslarının her iki programlama dili için de yaklaşık aynı oranda çıkması, LabVIEW'in hem hızlı ve hem de kolay programlanabilir bir yapıya sahip olması ve bu tezde kullanılması önerilen modellerin daha önce LabVIEW ortamında yapılmamış olmasından dolayı tez çalışmasında LabVIEW programlama dili kullanılmıştır.

İkinci kısımda ise, farklı özellikteki verilerin DVM ile doğrusal bir şekilde ayrılabilmesine imkân sağlayan çekirdek fonksiyonunun seçim zorluğunu giderebilmek amacıyla, iki farklı sınıflandırma algoritması önerilmiştir. Doğrusal yolla ayırım yapılması mümkün olmayan veri örneklerini sınıflandırmak için çekirdek fonksiyonları kullanılmaktadır. Çekirdek fonksiyonları, doğrusal olmayan bir haritalama ile verileri daha yüksek boyutlu ve doğrusal olarak ayrılacakları bir özellik düzlemine aktarırlar. Farklı çekirdek fonksiyonlarının Makine Öğrenmesi (MÖ) algoritmalarında kullanımlarında, farklı sinyaller için sistemin başarısı da değişmektedir. Bu durum, her sinyal için farklı çekirdek fonksiyonu kullanılmasına neden olmaktadır. Fakat, sinyal analizi için bağımsız çekirdek fonksiyonu kullanımı ve iyi başarı oranı ile sınıflandırma yapılması arzu edilen bir durumdur.

Bu amaçla tez çalışmasında, LabVIEW ortamında farklı çekirdek fonksiyonlarının analizleri için mevcut akıllı hesaplama yöntemlerinin iyi özelliklerini bir arada tutacak şekilde seri TBA-DAA-DVM (Temel Bileşen Analizi-Doğrusal Ayırıştırma Analizi-Destek Vektör Makinesi), paralel TBA-DAA-DVM, seri KTBA-DAA-DVM (Kernel Temel

Bileşen Analizi-Doğrusal Ayırıştırma Analizi-Destek Vektör Makinesi) ve paralel KTBA-DAA-DVM yöntemleri önerilmiştir. Önerilen yöntemler kullanılarak, göğüs kanseri verileri ve EEG işaretleri için performans analizleri yapılmıştır. Ayrıca, geliştirilen sistemin doğruluğunu test etmek ve modellerin ezber bir eğitim yapmadığını göstermek amacıyla, eğitim verileri için hem holdout hem de çapraz doğrulama yöntemleri kullanılarak sınıflandırma performansları incelenmiştir. Elde edilen sonuçların yakın çıkması, geliştirilen sistemin ezber bir eğitim yapmadığını göstermiştir. Bu yöntemlerle sınıflandırma doğruluğu elde edilen sisteme, eğitim ve test aşamasında hiç kullanılmamış yeni bir veri girildiğinde, bu verinin hasta bir kişiye mi yoksa sağlıklı bir kişiye mi ait olduğu hakkında seçim yapabilmektedir.

Bu tez çalışmasıyla, herhangi bir biyomedikal işarete (Elektroensefalografi-EEG, göğüs kanseri) ait verinin sağlıklı-hasta ayrımının yapılması ve sınıflandırılması için kolay ve etkili bir yöntem, farklı bir programlama diliyle sunulmuştur. Ayrıca, bu tez çalışmasında sınıflandırma haricinde; Elektrokardiyogram (EKG) verilerinden kalp atım hızı tespiti ve kan basıncı verilerinden de tansiyon tespiti yapılmıştır. EKG verilerinden elde edilen sonuçlar Amerikan Kalp Derneği standartlarına göre, kan basıncı verileri için elde edilen sonuçlar ise Dünya Sağlık Örgütü Uluslararası Hipertansiyon Komitesi standartlarına göre yorumlanmıştır. Bu tez kapsamında, LabVIEW ortamında gerçekleştirilen algoritmalar ve yeni bir veri için elde edilecek durum tespiti, literatüre yenilikçi bir katkı sağlamıştır.

Anahtar Kelimeler: Biyomedikal işaretler, Dalgacık Dönüşümü, Fourier Dönüşümü, Akıllı Hesaplama Yöntemleri, Denetimli Öğrenme Algoritmaları, Boyut Azaltma Algoritmaları, LabVIEW

SUMMARY

REALIZATION OF INTELLIGENT TECHNIQUES FOR CLASSIFICATION OF BIOMEDICAL SIGNALS IN THE LABVIEW

In this thesis study, new classification algorithms have been developed by using intelligent calculation methods to find out whether the patient is healthy or not from the dataset obtained using biomedical signals. These algorithms have been developed using the LabVIEW program, a language of visual programming that has become increasingly popular in the literature.

The thesis work consists of two parts in general. In the first part, the performance of LabVIEW is compared with MATLAB. As the dimension reduction algorithms in the literature, Principal Component Analysis (PCA), Linear Discriminant Analysis (LDA) and Kernel Principal Component Analysis (KPCA) were used. Support Vector Machine (SVM) is used as classification algorithms. LabVIEW was chosen because the performance of the classifications is about the same for both programming languages. Because LabVIEW has both fast and easy programmable structure and the recommended models for use in thesis work have not been done in LabVIEW before, the LabVIEW programming language was used in this thesis work.

In the second part, two different classification algorithms have been proposed in order to reduce the selection difficulty of the kernel function which enables the different feature data to be separated linearly with SVM. The kernel functions are used to classify data samples that can not be distinguished linearly. By transferring the kernel functions to a non-linear mapping, the data is transformed into a dimension of features that can be separated into higher dimensional and linear dimensions. In the use of different kernel functions in Machine Learning (ML) algorithms, the success of the system for different signals also changes. This causes different kernel functions to be used for each signal. However, it is desirable to use the independent kernel function for signal analysis and to classify it with good success rate.

For this purpose, the serial PCA-LDA-SVM (Principal Component Analysis-Linear Discriminant Analysis-Support Vector Machine), parallel PCA-LDA-SVM, serial KPCA-LDA-SVM (Kernel Principal Component Analysis-Linear Discriminant Analysis-Support

Vector Machine) and parallel KPCA-LDA-SVM methods are proposed. Performance analyzes were performed for breast cancer data and EEG signals using the recommended methods. In addition, we used both holdout and cross validation methods to test the accuracy of the developed system and to show that the models did not make a memorizing. Closer results have shown that the developed system does not make a memorizing. With this method, when a new data which has never been used in the training and testing phase is entered into the system, the system can choose whether the data belongs to a patient or a healthy person.

With this thesis, an easy and effective method for the classification and classification of healthy-patients in any biomedical work (Electroencephalography-EEG, breast cancer) is presented in a different programming language. In addition, in this thesis study, except for classification, heart rate was determined from ECG data and blood pressure was determined from blood pressure data. The results obtained from ECG data were interpreted according to American Heart Association standards and the results obtained for blood pressure data according to the standards of the World Health Organization International Hypertension Committee. Within the scope of this thesis, the algorithms performed in the LabVIEW environment and the case-finding for new data provided an innovative contribution to the literature.

Key words: Biomedical signals, Wavelet Transform, Fourier Transform, Intelligent Computation Methods, Supervised Learning Algorithms, Dimension Reduction Algorithms, LabVIEW.

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 2.1.	Elektriksel kökenli ve elektriksel kökenli olmayan biyolojik işaretler	9
Şekil 2.2.	Normal EKG	11
Şekil 2.3.	Önerilen EEG bağlantısı	13
Şekil 2.4.	Ritim bozuklukları [74]	16
Şekil 3.1.	Dalga ve Dalgacık.....	21
Şekil 3.2.	S işaretinin alçak geçiren ve yüksek geçiren filtre ile filtrelenmesi	23
Şekil 3.3.	2.seviyeden dönüşüm.....	24
Şekil 3.4.	Periyodogramı alınmış işaret	25
Şekil 3.5.	EKG işaretinin güç spektrumu a) periyodogram b) welch periyodogramı.....	27
Şekil 4.1.	Sinir sisteminin blok gösterimi	30
Şekil 4.2.	Yapay sinir hücresinin yapısı.....	31
Şekil 4.3.	Etkinlik fonksiyonları a) lineer aktivasyon fonksiyonu, b) eşik aktivasyon fonksiyonu,	32
Şekil 4.4.	Yapay sinir ağı modeli.....	34
Şekil 4.5.	Perceptron.....	36
Şekil 4.6.	Çok katmanlı algılayıcı.....	36
Şekil 4.7.	Denetimli öğrenme algoritmalarının sıralı işlem blokları	38
Şekil 4.8.	Destek vektörlerinin ve optimal ayırıcı düzlemin gösterimi	39
Şekil 4.9.	Doğrusal ayrılabilen optimum ayırıcı hiperdüzlem.....	40
Şekil 4.10.	Doğrusal olmayan DVM.....	43
Şekil 4.11.	Giriş verisinin özellik düzlemine aktarımı	43
Şekil 4.12.	Denetimsiz öğrenme algoritmalarının sıralı işlem blokları	46
Şekil 4.13.	Boyut azaltma algoritmalarının sıralı işlem blokları	46
Şekil 4.14.	Gerçek veri seti	49
Şekil 4.15.	Ortalamasından çıkarılmış veri seti	50
Şekil 4.16.	Orijinal ve farkı alınmış veri seti	50
Şekil 4.17.	Normalize edilmiş veri ve öz vektörler	51
Şekil 4.18.	Öz vektörler kullanılarak türetilmiş veri seti	53
Şekil 4.19.	Gerçek veri seti	56
Şekil 4.20.	Dönüşüm sonrası elde edilen grafik	57
Şekil 5.1.	LabVIEW ön panel ve blok diyagramı	60
Şekil 5.2.	LabVIEW Kontrol ve fonksiyon paleti.....	61
Şekil 5.3.	Toplama Programı	61
Şekil 5.4.	Biyomedikal araç kiti.....	63
Şekil 5.5.	Biyomedikal tezgah	63
Şekil 5.6.	Sinyal işleme araç kiti.....	64
Şekil 5.7.	MÖ araç kiti	65

Şekil 5.8.	İleri çizim araç kiti.....	65
Şekil 6.1.	YSA ile Sınıflandırma Bloğu.....	67
Şekil 6.2.	DVM ile sınıflandırma şeması 1.parça	68
Şekil 6.3.	DVM ile sınıflandırma şeması 2.parça	69
Şekil 6.4.	LabVIEW’de oluşturulan TBA şeması.....	70
Şekil 6.5.	LabVIEW’de oluşturulan DAA şeması	71
Şekil 6.6.	Gauss, polinomial, doğrusal çekirdek fonksiyonları uygulanmış 3 boyutlu grafikler.....	73
Şekil 6.7.	LabVIEW’de oluşturulan KTBA blok şeması.....	73
Şekil 6.8.	Eğitim ve test verilerinin 3 boyutlu dağılımları.....	75
Şekil 6.9.	Test verisinin 2 boyutlu dağılımı	75
Şekil 6.10.	Sınıflandırma sonrası histogram	76
Şekil 6.11.	Hata matrisi.....	76
Şekil 6.12.	ROC eğrisi	77
Şekil 6.13.	TBA-DVM sınıflandırılmasına ilişkin LabVIEW blok şeması.....	79
Şekil 6.14.	DAA-DVM sınıflandırılmasına ilişkin LabVIEW blok şeması	81
Şekil 6.15.	KTBA-DVM sınıflandırılmasına ilişkin LabVIEW blok şeması	83
Şekil 6.16.	Seri TBA-DAA-DVM modeline ait blok diagramı	87
Şekil 6.17.	Kullanılan test verisinin a) 3 boyutlu dağılımı b) iki boyutlu dağılımı	87
Şekil 6.18.	Seri TBA-DAA-DVM yapısına ait LabVIEW blok şeması	88
Şekil 6.19.	Gauss çekirdek fonksiyonu kullanılarak elde edilen histogram	89
Şekil 6.20.	Paralel TBA-DAA-DVM algoritma modeli	90
Şekil 6.21.	Paralel TBA-DAA-DVM modeline ait LabVIEW’de oluşturulan blok şeması.....	91
Şekil 6.22.	Kullanılan test verisinin a) 3 boyutlu dağılımı b)iki boyutlu dağılımı	92
Şekil 6.23.	Doğrusal çekirdek fonksiyonu kullanılarak elde edilen histogram	93
Şekil 6.24.	Seri KTBA-DAA-DVM algoritma yapısı	94
Şekil 6.25.	Seri KTBA-DAA-DVM modeli histogramı	96
Şekil 6.26.	Seri KTBA-DAA-DVM modeline ait blok diyagramı	97
Şekil 6.27.	Paralel KTBA-DAA-DVM algoritma yapısı.....	98
Şekil 6.28.	Paralel KTBA-DAA-DVM modeline ait LabVIEW blok şeması	99
Şekil 6.29.	LabVIEW Kalp atım hızı tespit şeması	103
Şekil 6.30.	Kan basıncı LabVIEW blok şeması.....	104

TABLÖLAR LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1. Elektriksel kökenli biyomedikal işaretler	10
Tablo 2.2. Elektriksel kökenli olmayan biyomedikal işaretler	16
Tablo 4.1. Çekirdek Fonksiyonları	44
Tablo 4.2. Veri noktaları	49
Tablo 4.3. Sonuç verisi	52
Tablo 4.4. Varyans	52
Tablo 4.5. Veri kümelerinin ortalamaları.....	56
Tablo 6.1. Gerçek veri ile TBA uygulanmış veri.....	70
Tablo 6.2. Gerçek veri ile DAA uygulanmış veri.....	72
Tablo 6.3. Göğüs kanserine ait öznelilikler ve hedefler	74
Tablo 6.4. LabVIEW-YSA analiz sonuçları	76
Tablo 6.5. MATLAB-YSA analiz sonuçları.....	77
Tablo 6.6. LabVIEW ve MATLAB için farklı ve aynı eğitim-test veri setleri için TBA-DVM sınıflandırma sonuçları	78
Tablo 6.7. LabVIEW ve MATLAB için farklı ve aynı eğitim-test veri setleri için DAA-DVM sınıflandırma sonuçları	80
Tablo 6.8. LabVIEW ve MATLAB aynı eğitim-test veri setleri için KTBA-DVM sınıflandırma sonuçları	82
Tablo 6.9. TBA-DVM için uygulama sonuçları ve ortalamaları	85
Tablo 6.10. DAA-DVM için uygulama sonuçları ve ortalamaları	85
Tablo 6.11. KTBA-DVM için uygulama sonuçları ve ortalamaları.....	86
Tablo 6.12. Seri TBA-DAA-DVM modeline ait sayısal sonuçlar	87
Tablo 6.13. Seri TBA-DAA-DVM modeline ait başarımlar sonuçları.....	89
Tablo 6.14. Paralel TBA-DAA-DVM modeline ait sayısal sonuçlar.....	90
Tablo 6.15. Paralel TBA-DAA-DVM modeline ait başarımlar sonuçları.....	93
Tablo 6.16. Seri KTBA-DAA-DVM yapısına ait ortalama sonuçlar	94
Tablo 6.17. Seri KTBA-DAA-DVM yapısına ait çapraz doğrulama ve holdout sonuçları	95
Tablo 6.18. Seri KTBA-DAA-DVM modeline ait başarımlar sonuçları.....	96
Tablo 6.19. Paralel KTBA-DAA-DVM modeline ait sayısal sonuçlar	98
Tablo 6.20. Paralel KTBA-DAA-DVM modeline ait başarımlar sonuçları	100
Tablo 6.21. Önerilen TBA-DAA-DVM seri-paralel modellerine ait sınıflandırma sonuçları	100
Tablo 6.22. EEG verilerine ait seri TBA-DAA-DVM modeli için başarımlar sonuçları.....	101
Tablo 6.23. EEG verilerine ait paralel TBA-DAA-DVM modeli için başarımlar sonuçları	101
Tablo 6.24. EKG Kalp Atım Hızı (bpm).....	102
Tablo 6.25. Dünya Sağlık Örgütü Uluslararası Hipertansiyon Komitesi kan basıncı standartları	103
Tablo 6.26. Elde edilen kan basıncı değerleri	103

KISALTMALAR LİSTESİ

EKG	: ElektroKardiyoGram
EEG	: ElektroEnsefaloGram
ENG	: ElektroNöroGram
EMG	: ElektroMiyoGram
EGG	: ElektroGastroGram
KB	: Kan Basıncı
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
KZFD	: Kısa Zamanlı Fourier Dönüşümü (Short Time Fourier Transform)
DD	: Dalgacık Dönüşümü (Wavelet Transform)
SDD	: Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
ADD	: Ayrık Dalgacık Dönüşümü
YSA	: Yapay Sinir Ağları
CKA	: Çok Katmanlı Ağ (Multi Layer Network)
GYA	: Geri Yayılım Ağı (Back Propagation)
DVM	: Destek Vektör Makinesi (Support Vector Machine)
k-NN	: En Yakın Komşu Algoritması (K-nearest neighbors)
TBA	: Temel Bileşen Analizi (Principal Component Analysis)
DAA	: Doğrusal Ayrıştırma Analizi (Linear Discriminant Analysis)
KTBA	: Kernel Temel Bileşen Analizi (Kernel Principal Component Analysis)
LabVIEW	: Sanal Mühendislik Tezgahı Laboratuvar Enstrümanı (Laboratory Virtual Instrument Engineering Workbench)
HTML	: Hyper Text Markup Language
DAQ	: Veri Toplama (Data Acquisition)
HRV	: Kalp Hızı Değişkenliği (Heart Rate Variability)
NIBP	: Noninvazif kan basıncı analizi (Noninvasive Blood Pressure Analysis)

SEMBOLLER LİSTESİ

cpm	: Dakika başına döngü
pH	: Hidrojen potansiyeli
PO₂	: Kandaki oksijen miktarı
s	: Ölçekleme parametresi
To	: Kaydırma parametresi
$\Psi_{s,\tau}(t)$	: Ana Dalgacık Fonksiyonu
d(p,q)	: İki nokta arası uzaklık
E^T	: E öz değer matrisi A özdeğerlere ait köşegen matrisi
X	: X eğitim örneklerini içeren matris
X^T	: Eğitim örneklerinin transpozesi
P_p	: p boyutlu P matrisi
A	: Öz değerlere ait köşegen matris

1. GİRİŞ

1.1. Genel Bakış

Biyomedikal işaretler, canlı vücudundan elektrotlar veya dönüştürücüler aracılığıyla algılanan, elektriksel kökenli veya elektriksel kökenli olmayan işaretler olmak üzere iki ayrı grupta incelenmekte olup organizmanın fizyolojik aktiviteleri ile ilgili bilgiler sunmaktadır. Bu işaretler, insan vücudunda herhangi bir patolojik durumun tespiti konusunda çok kullanışlıdır. İşlenmemiş bu işaretlerin doğru yorumlanmasına katkı sağlayacak önemli bilgilerin elde edilmesi ve işarete karışan gürültülerin kaldırılması için sinyal işleme metotlarına ihtiyaç duyulmuştur [1]. Sinyal işleme, işaretlerden bilgi çıkarmak ya da bilgileri taşıyan işaretleri bir formdan başka bir forma dönüştürmek için yapılmaktadır. Sinyal işleme ile işaretin fiziksel olarak boyutunu ölçme, işareti depolama ve daha sonra da işareti yeniden yapılandırma, gürültü azaltma, işaretin kalitesini artırma, depolama alanından kazanç sağlama amacıyla veri sıkıştırma, özellik çıkarma gibi işlemleri yapmak mümkündür [2-8]. Sinyal işleme tekniklerine bakıldığında zaman literatürde Fourier Dönüşümü (FD), Sürekli Dalgacık Dönüşümü (SDD), Ayrık Dalgacık Dönüşümü (ADD), Çoklu Dalgacık Dönüşümü (ÇDD), filtreleme tabanlı yöntemler mevcuttur [9-12]. Dönüşüm, bir işaretin orijinal haline göre ilk etapta anlamsız gibi gelen ya da görülemeyecek bilgilerin anlamlı hale getirilmesidir. FD, zaman bölgesi sinyallerini frekans bölgesi gösterimlerine dönüştürerek spektral gösterimlerini sağlamanın yanı sıra, frekans bölgesinde belli sistemlerin ve özelliklerinin betimlenmesinde de rol oynar [13]. Dalgacık Dönüşümü (DD), bir işareti tanımlamak için bir dizi ötelenmiş ve sıkıştırılmış dalgacık fonksiyonu kullanan bir yöntem olup farklı frekans özellikli durağan olmayan işaretler arasında ayırım yapmaya izin veren dönüşümdür [14]. FD ile zaman bölgesindeki işaretin frekans bölgesindeki karşılığı elde edilip, işaretin zaman bilgisi kaybolur. Yani işaret içerisindeki farklı frekansların hangi zaman dilimlerine ait olduğu bilinemez, bu da zaman içerisinde değişim gösteren işaretler için problem olur. Bunu engellemek için pencereleme işlemi ile işaret küçük pencerelere ayrılır ve çerçeve içindeki kısa süreli işaretler durağan kabul edilerek her çerçeve için FD hesaplanır. Bu işlem, Kısa Zamanlı Fourier Dönüşümü (KZFD) olarak isimlendirilir. KZFD ile işaretin zaman dilimine göre

hangi frekansa ait olduđu hakkında bilgi elde edilir. KZFD bütün frekanslarda sabit çözünürlük sağlarken, DD ise farklı frekanslarda farklı çözünürlüklerin elde edilmesini sağlayan çoklu çözünürlük (multi-resolution) tekniklerini kullanır, bu teknik de işareti küçük parçalara ayırır. Fakat, FD ile bu işlem için sonsuz uzunlukta olduđu varsayılan ve değışik frekanslardaki düzenli sinüs dalgaları kullanılırken, DD ile sınırlı süreli, düzensiz, asimetrik işaretlerin ölçeklenmiş ve kaydırılmış halleri kullanılır. DD ile işaret, yüksek ve alçak frekans bileşenlerini içeren alt bantlarına ayrılır [15-21].

Son yıllarda, teknolojinin gelişmesine paralel olarak bilgisayarlar ve bilgisayar destekli sistemler insan hayatında önemli bir noktada yer almaktadır. Verileri özetleyebilme, veriler arasında ilişki kurabilme ve bu ilişkiler neticesinde sonuçları yorumlayabilme amacıyla yapılan çalışmalar yapay zekâ kavramını geliştirmiştir. Yapay zekâ teknikleri kullanılarak oluşturulmuş bir bilgisayar sistemi, eldeki verileri kullanarak olaylar arasında ilişkiler kurmakta ve gelecek yeni olaylar hakkında önceden tahminde bulunabilme özelliğine sahip olmaktadır. Bu özelliklerinden dolayı, Yapay Sinir Ağları (YSA) ve MÖ gibi yapay zekâ teknikleri farklı alanlarda problemlerin çözümü için fazlaca kullanılmaktadır. YSA, insan beyninden esinlenerek geliştirilmiştir. Her nasıl ki merkezi sinir sisteminin temel işlem elemanı sinir hücreleri (nöronlar) ise YSA'nın da temel işlem elemanı nöronlardır. Yapay nöronlar, aralarında bağ kurarak YSA'yı oluştururlar. Beyinde olduđu gibi YSA'da da yapay nöronların, giriş işaretlerini aldığı, işlediği ve çıktılar ilettiği bölümleri bulunmaktadır. YSA, birbirine bağlı çok sayıda işlem elemanlarından oluşmaktadır [22-24]. İnsan beyni gibi hatırlama, öğrenme ve genelleme yapabilme yeteneğine sahiptir. Ayrıca deneme yolu ile öğrenme ve genelleme yapabilmektedir. MÖ ise yapay zekânın bir dalı olup bilinen örneklerden öğrenme yoluyla bilinmeyen örnekleri belirlemeyi amaçlamaktadır. Diğer bir deyişle, veri içerisindeki karmaşık parçacıkların bulunması, bunların alt sınıflara ayrılması ve gelecekteki veriler için tahmin yapmasını sağlar [25]. MÖ, kullanılan verinin yapısına göre denetimli öğrenme algoritmaları, denimsiz öğrenme algoritmaları ve boyut azaltma algoritmaları olmak üzere farklı algoritma seçeneklerinden oluşmaktadır. Her algoritmanın kullanıldığı amaca göre avantaj ve dezavantajı mevcuttur [26].

Programlama dili, yazılımcının bir algoritmayı ifade etmek amacıyla, bir bilgisayara hangi aşamada neyi ne şekilde yapması gerektiğini anlatmasının bir yoludur. Programlama dillerini, çalışma mantıkları, kodlama yapıları ve görselliği gibi farklı özelliklere göre gruplandırmak mümkün olmaktadır. Gelişen teknoloji metin tabanlı

programlama mantığı ile çalışan dillerin yerine nesne tabanlı programlama dillerinin gelişimine ihtiyaç duymuştur. Böylece kod yazmaya gerek kalmadan görsel olarak programlama yapmak mümkün olmuştur. LabVIEW, ardışık metin satırı yerine bir veri akışı modelini kullanan bir grafiksel programlama dilidir. Çoklu işlemlerin paralel olarak yapılmasına imkân sağlayabilme, programların hazır fonksiyonlarla grafiksel olarak tasarlanabilmesi ve kod yazmaya gerek kalmaması sağladığı en önemli avantajlarıdır. Böylece zaman kaybı önlenmektedir.

1.2. Literatür Özeti

Biyolojik işaretler, insan vücudunda herhangi bir patolojik durumunun tespiti konusunda çok kullanışlıdır. İşlenmemiş bu işaretlerden çok fazla bilgi elde edilememekle birlikte, işarete karışan gürültüleri yok etmek ve önemli bilgilerin çıkarılması için sinyal işleme metotlarına ihtiyaç duyulmuştur [27]. Literatürde (ElektroKardiyoGram) EKG işaretlerinden kalp hastalıklarının teşhisi [28], ElektroEnsefaloGram (EEG) işaretlerinden nörolojik hastalıkların teşhisi [29]; ElektroGastroGram (EGG) işaretlerinden midesel rahatsızlıkların teşhisi [30], elektriksel kökenli olmayan göğüs kanseri gibi görüntü verilerinden göğüs kanseri teşhisi [31] ve kan basıncı değerlerinden tansiyon problemi teşhisi için de çalışmalar mevcuttur [32].

EKG işaretlerinin özelliklerinin incelenmesi ve korelasyon analizi ile kalp atışlarındaki düzensizliklerin belirlenmesi adına çalışmalar [33-35]'te yapılmıştır. [36]'da, Doppler kalp seslerinin parçacık tanıma kullanılarak yorumlanması adına bir karar destek sistemi geliştirilmiştir. Özellik çıkarma adına dalgacık paket ayrıştırma, zaman-frekans ifadesi için de FFT kullanılmıştır. Valvüler kalp hastalıkları, mitral ve aort rahatsızlıkları, kalp aritmileri, damar tıkanıklığı, kulakçık-karıncık kas yapısının büyümesi, kalp krizi, miyokardın yetersiz oksijenizasyonu gibi kalp hastalıklarının erken teşhisi önemli bir araştırma alanını oluşturmaktadır [37-39]. [40]'da gerçek EKG verileri, kaba kümeler teorisi ile sınıflandırılmıştır. Kaba kümeler teorisi sayesinde gereksiz nitelikler elenerek çalıştırma zamanında iyileştirmeler sağlanmıştır. Ayrıca sınıflandırma sonuçlarının, uzmanlardan alınan geri bildirimlerle -yüksek oranda uyduğu gösterilmiştir. [41]'de kalp seslerine Bağımsız Bileşen Analizi (BBA) uygulanmış ve işaretlerin özellikleri elde edilmiştir. Elde edilen bu özellikler, farklı denetimli öğrenme algoritmaları ile sınıflandırılmış ve sonuçlar kıyaslanmıştır.

EEG verileri, BBA ve YSA ile sınıflandırılmış ve sonuçlar incelenmiştir [42]. [43]'te, EEG işaretleri DD ile 5 alt banda ayrılmış, her bandın bazı istatistiksel parametreleri elde edilmiştir. Bu özellikler en yakın komşu algoritması (k-NN) ve DVM sınıflandırıcıları ile sınıflandırılmış ve sonuçlar karşılaştırılmıştır. Aynı şekilde [44]'te EEG işaretleri farklı dalgacıklar kullanılarak elde edilen yeni özellikli vektör k-NN ile sınıflandırılarak dalgacıkların performansları karşılaştırılmıştır. [45]'te EEG verileri en küçük kareler destek vektör makinesine dayalı kümeleme tekniği ile sınıflandırılmıştır. Alt kümelere ayrılan EEG verilerinde bazı istatistiksel özellikler çıkarılarak verinin boyutu azaltılmış, önemli özellikler elde edilmiştir. Bu özellikler, LS-DVM algoritması ile sınıflandırılmış ve sonuçlar bazı istatistiksel ölçümlere göre değerlendirilmiştir. [46-48]'de DD kullanılarak EEG işaretleri sınıflandırılmıştır. [49,50]'de EEG işaretleri YSA kullanılarak sınıflandırılmıştır. [51-55]'te epilepsi atak tespiti ve EEG işaretlerinin sınıflandırılması, [56-58]'de uyku evrelerinin ve uyku apnesinin sınıflandırılması, [59]'da duygu sınıflandırılması, [60]'da hayal edilen olayın çeşidinin EEG işaretleri ile tahmin edilebilmesi, [61]'de ruhsal kökenli epileptik olmayan nöbetlerin sınıflandırılması incelenmiştir. EEG işaretleri kullanılarak midesel rahatsızlıkların tespiti için de literatürde birçok çalışma mevcuttur [62-79].

Kanser, birçok çeşidi bulunan bir hastalıktır. Kanser hastalıklarında hastalığın erken tespiti çok önemlidir ve bu süreç hastalığın takibini önemli ölçüde etkilemektedir. Diğer hastalıklarda olduğu gibi kişinin sağlıklı, hasta veya yüksek riskli gruplara ait olup olmadığını belirlemek için kanser vakalarındaki verileri sınıflandırmak önemlidir [80,81]. Globolcan 2012 istatistiklerine göre %11.9 oranıyla dünyada ölümlere sebep olan ikinci kanser türü olan göğüs kanserinin karakteristik özelliklerini tanıma ve özelliklerini analiz etme adına farklı yöntemler kullanılarak literatürde çalışmalar mevcuttur [82]. Bu çalışmalardan göğüs kanseri tespiti [83]'te karar ağacı metoduyla, [84]'te DAA ile, [85]'te çapraz doğrulama DVM ile, [86]'da neuro-fuzzy ile, [87]'de Vektör Nicemleme Teknikleri ile incelenmiştir.

Kan Basıncı (KB), damar yatağındaki kanın akış sırasında damar duvarlarına yaptığı basınçtır. Kalp kasıldıkça, damarlara kan pompalanır. Bu, arterlerdeki basıncı artırırken, kalp atışlarında basınç azalır. Bunun bir sonucu olarak, kan basıncı sistolik basınç ve diyastolik basınç olmak üzere iki değerle gösterilir ve birim milimetre cıvadır (mmHg) [88,89]. Bu Kan Basıncı değerlerinin tespit edilerek kişinin optimum, normal, hipertansiyon, hipotansiyon ve prehipertansiyondan hangi özelliklerin sergilediğine karar

verilebilir [90,91]. Bu deęerlerin tespit edilmesi amacıyla [32]'de noninavazif kan basıncı tespiti yapılmıřtır.

Sinyal iřleme, iřaretlerden bilgi ıkarmak ya da bilgileri taşıyan iřaretleri bir formdan dięer bir forma dnřtrmek iin yapılan uygulamalardır [92]. Sinyal iřleme ile iřaretin fiziksel olarak boyutunu lme, iřareti depolama ve daha sonra da iřareti kendi isteęimiz doęrultusunda yeniden yapılandırma, grlt azaltma, iřaretin kalitesini artırma, depolama alanından kazanç saęlama amacıyla veri sıkıřtırma, zellik ıkarma gibi iřlemleri yapmak mmkn olmaktadır. Sinyal iřleme teknikleri olarak literatrde; FD, SDD, ADD, DD, filtreleme tabanlı yntemler mevcuttur. Duraęan olmayan iřaretlerden EEG, EGG, EKG gibi biyomedikal iřaretlerin grltye maruz kalmaları, grltlerin tepe deęerlerini etkilemelerinden dolayı Hızlı Fourier Dnřm (FFT) zaman-frekans bilgisinin bir arada olmasında yetersiz kalmıřtır. Buna alternatif olarak geliřtirilen KZFD; hassasiyet pencere seimine baęlı olup zamansal ve spektral znrlkler arasında kayıplar yarattıęından, tm frekans bantları iin sınırlı frekans znrlę saęladıęından ve zaman bilgisi kaybolduęundan dolayı yine duraęan olmayan iřaretler iin uygun olmamıřtır [93]. İřaret ierisindeki farklı frekansların hangi zaman dilimlerine ait olduęu bilinmemesi ve dalganın hem zaman hem de frekans karakteristiklerinin tanımlanmasındaki eksiklikleri gidermek iin DD nemli yer tutmaktadır [13,92-94]. Bylece btn frekans aralıklarında esnek zaman-frekans znrlę elde edilir. Detay ve yaklařık katsayılar elde edildikten sonra iřaret, farklı frekans bantlarına ayrılmıř olur. Her bir bileřen, o lekteki znrlę ile incelenir [94]. Bu alt bantların g spektral yoęunluklarının hesaplanması, iřaret hakkında nemli sayılabilecek zellikleri verebilir [95]. İřaretin zaman bilgisi, DD'nin zamanda kaydırılmıř dnřm ile frekans bilgisi ise lekli dnřm ile elde edilir [96]. Bir bařka deyiřle dřk frekansta doęru bir frekans bilgisi, yksek frekansta doęru bir zaman bilgisi verir [97]. DD ile grltlerin elimine edilmesi, iřaretlerin zellik ıkarmı, spektral parametrelerin belirlenmesi ve zaman-frekans bilgisinin eř zamanlı olarak alınabilmesinden dolayı olduka nemli bir metottur [98]. DD'nin yanı sıra, nemli zelliklerin korunduęu boyut azaltma algoritmaları ile zellik ıkarmı yapılan verilerin akıllı hesaplama yntemleri ile sınıflandırılması olduka nemli sonular vermiřtir [99-102]. zellikle denetimli ęrenme algoritmaları ile literatrde farklı iřaretlerin sınıflandırılması, DVM [25,103-105] ve k-NN [106,107] ile yapılmıřtır. Bazı alıřmalarda, YSA ve DVM performansları karřılařtırılmıřtır ve

DVM'nin daha hızlı, daha az hafıza gerektirdiği ve daha iyi sınıflandırma yüzdesi verdiği gözlenmiştir [102,104]. Boyut azaltma, eldeki verinin özelliklerini saklamakla birlikte verinin gereksiz olan niteliklerinin belirlenerek veriden atılmasına yönelik bir uygulamadır [106-109]. Boyut azaltma algoritmalarından birisi olan TBA, veriyi değişkenliğin en yüksek olduğu tarafa doğru yönlendirmeye amaçlayan doğrusal bir boyut azaltma metodudur. Bu yöntem, farklı koşullar altında bir araya gelen çoklu işaretleri birbirinden ayırmak için kullanılmaktadır [110]. Bir diğer boyut azaltma yöntemi olan Bağımsız Bileşen Analizi (BBA), TBA ile karşılaştırılmış ve elde edilen veriler DVM, DAA ve Naive Bayes (NB) sınıflandırıcısı ile sınıflandırılmıştır [49]. Epileptik EEG verilerinin sınıflandırılması için işaretin spektral çözümlemesi sonunda elde edilen sonuçlar, K-means kümeleme yöntemi ile bileşenler kümelendirilmiş, elde edilen veriler rastgele eğitim ve test kümelerine ayrılarak YSA ile sınıflandırılmıştır [50]. Özellikleri çıkarılan EEG işaretleri DVM, k-NN ve Radyal Tabanlı Sinir Ağları ile sınıflandırılıp performansları ölçülmüştür. YSA ve DVM, ayrıca kemik erimesi teşhisi için de kullanılmıştır [111].

Bu tezde, biyomedikal işaretlerin sınıflandırılması için akıllı hesaplama yöntemleri kullanan LabVIEW tabanlı algoritmaların geliştirilmesi amaçlanmıştır. National Instruments firmasının LabVIEW programını geliştirmesiyle, programların hazır fonksiyonlarla grafiksel olarak tasarlanması mümkün olmuş ve böylece kod yazmaya gerek kalmamıştır.

1.3. Problemin Tanımlanması ve Tezin Amacı

Farklı biyomedikal verilerin farklı algoritmalarla MATLAB ortamında sınıflandırılmasına dair literatürde pek çok çalışma bulunmasına rağmen, LabVIEW ortamında bu sınıflandırma algoritmalarının kullanımı yaygın değildir. LabVIEW, programların hazır fonksiyonlarla grafiksel olarak tasarlanmasına imkân sağlamaktadır. Ayrıca, modüler fonksiyonları ile diğer programlama dillerinin yapabileceği her türlü işlemi yapabilme yeteneğine sahiptir. LabVIEW, ardışık metin satırı yerine bir veri akışı modelini kullanan bir grafiksel programlama dilidir. Diğer dillerle karşılaştırıldığında, LabVIEW, ardışık kod dizilerinin yerine bir veri akışıyla çalışabildiğinden dolayı çoklu işlemlerin paralel olarak hızlı bir şekilde yapılmasına imkân sağlamakta ve zaman kaybının önüne geçmektedir. Tez çalışmasında, LabVIEW'in bu özelliklerinden faydalanılmış olup YSA ve MÖ ile ilgili algoritmalar üzerine çalışılmıştır. Boyut azaltma algoritmalarından

TBA, DAA, KTBA kullanılarak verilerden özellik çıkarılarak, DVM ile biyomedikal işaretlerin sınıflandırılması gerçekleştirilmiştir. Ayrıca aynı yöntemler kullanılarak MATLAB ortamında da sonuçlar alınmış, her iki programdan elde edilen sınıflandırma sonuçları karşılaştırılmıştır.

Literatürde Gauss, polinomial ve doğrusal çekirdek fonksiyonları gibi farklı fonksiyonlar sınıflandırma algoritmalarında kullanılmaktadır [108,111,125]. Sınıflandırma işlemlerinde, farklı işaretler için farklı çekirdek fonksiyonu seçimi yapılmakta, bu durum da sınıflandırma işleminde iş yüküne neden olmaktadır. Oysa değişen farklı işaretlere rağmen herhangi bir çekirdek fonksiyonu ile yüksek sınıflandırma doğruluğu elde edebilmek istenen bir durumdur. Bu amaçla, tez çalışmasında istenilen başarı oranını artırmak için seri TBA-DAA-DVM, paralel TBA-DAA-DVM, seri KTBA-DAA-DVM, paralel KTBA-DAA-DVM modelleri LabVIEW ortamında gerçekleştirilmesi önerilmiştir. Bu modeller ile hem sınıflandırma yüzdelерinde iyileştirme sağlanması hem de Gauss dışındaki çekirdek fonksiyonlarının kullanılmasıyla iyi bir başarı yüzdesi alınması sağlanmıştır. Önerilen yapılar, çekirdek fonksiyonu seçimi sırasında ortaya çıkan zorluğun üstesinden gelebilmek için kullanılabilecek alternatif bir çözüm yolu olarak düşünülmüştür.

1.4. Tezin Yapısı

Bu doktora tezi, aşağıda açıklamaları verilen 7 bölümden oluşmaktadır.

Tezin birinci bölümünde; tez çalışmasına genel bir bakış yapılmış, tez için problem tanımlanmış, literatürde bu alanda yapılan çalışmalar hakkında bilgiler verilmiş ve tezin yapısından bahsedilmiştir.

Tezin ikinci bölümünde; biyomedikal işaretler (EEG, EKG, EGG, göğüs kanseri, kan basıncı) hakkında genel bilgiler literatür taramasıyla birlikte verilmiştir.

Tezin üçüncü bölümünde; sinyal analiz metotlarından bahsedilmiştir. Genel olarak DD, FD gibi yöntemlerin özelliklerinden, literatürde kullanım alanlarından ve birbirlerine göre avantaj ve dezavantajlarından bahsedilmiştir. SDD ve ADD ayırımından bahsedilmiştir. Ayrıca işaretlerin spektral parametrelerinin çıkarılması üzerinde durulmuştur. Güç spektrum yoğunluğu, Welch diagramı, periyodogram çıkarılışı ve bunların ne anlama geldikleri üzerinde durulmuştur.

Tezin dördüncü bölümünde; son yıllarda çeşitli mühendislik problemlerinin çözümünde sağladıkları kolaylık ve üstünlükleri nedeniyle tercih edilen akıllı hesaplama

yöntemlerinden bahsedilmiştir. Akıllı hesaplama yöntemlerinden olan ve tez çalışmasında kullanılan MÖ algoritmaları ve YSA yapıları ve çalışma prensipleri kısaca açıklanmıştır. Denetimli öğrenme algoritmaları, denetimsiz öğrenme algoritmaları ve boyut azaltma algoritmalarının yapıları ve özellikleri bu bölümde incelenmiştir.

Tezin beşinci bölümünde; LabVIEW programının genel hatlarıyla tanıtımı, tez çalışmasında kullanılan araç çubuklarından biyomedikal işaret işleme kiti, ileri sinyal işleme kiti, MÖ kiti tanıtımları ve ileri düzeyde grafiksel çizim yapma kiti hakkında bilgilendirme yapılmıştır.


Tezin altıncı bölümünde; LabVIEW’de oluşturulan programlarla TBA, DAA, KTBA ve önerilen hibrit modellerin DVM ile sınıflandırılması farklı biyomedikal veriler için yapılmıştır. Özellikle çekirdek fonksiyonu seçimi için yöntemlerin birbirlerine göre farklılıkları analiz edilmiştir. Önerilen yöntemlerle çekirdek fonksiyonu seçim zorluğunun önüne geçilmeye çalışılmıştır.

Tezin son bölümünde ise tezden elde edilen sonuçlar özetlenmiş ve gelecekte yapılabilecek çalışmalar hakkında fikirler sunulmuştur.

2. BİYOMEDİKAL İŞARETLER

2.1. Giriş

Biyomedikal işaretler, canlı vücutundan elektrotlar veya dönüştürücüler aracılığıyla algılanan, içerikleri Şekil 2.1’de verilen elektriksel kökenli veya elektriksel kökenli olmayan işaretler olup gen-protein dizilerinden, sinir ve kalp ritimlerine, doku ve organ görüntülerine kadar organizmanın fizyolojik aktivitelerini incelemektedir. Bu işaretler, insan vücutunda herhangi bir patolojik durumunun tespiti konusunda çok kullanışlıdır. Bununla birlikte, işlenmemiş bu işaretlerden çok fazla bilgi elde edilememektedir ve bu sebeple önemli bilgilerin çıkarılması için sinyal işleme metotlarına ihtiyaç duyulmuştur [1,2].



Şekil 2.1. Elektriksel kökenli ve elektriksel kökenli olmayan biyolojik işaretler

Organizma, çeşitli alt sistemleri bulunan oldukça karmaşık bir yapıdır. Bu alt sistemler, birbirleriyle etkileşimde olduğundan dolayı biyomedikal işaretlerde iletim hattından kaynaklanan gürültüler dışında, bu biyomedikal sistemlerin kendilerinden kaynaklanan gürültüler de mevcuttur. Bu nedenle, istenmeyen gürültüleri yok etmek için filtreleme tabanlı [3-9] ve dönüşüm tabanlı yöntemler yıllardır kullanılmaktadır [10-21]. Gürültü yok etmede en temel yöntem işaretin spektrum analizinin çıkarılması ve istenmeyen frekansların bastırılmasıdır [20]. Bunun yanı sıra biyomedikal işaretlerin karakteristiklerinin belirlenmesi, özelliklerinin çıkarılması, akıllı tekniklerle farklı gruplara ayrılması gibi durumlar için literatürde birçok çalışma yapılmıştır [8-32].

Biyomedikal işaret işleme, biyologlar için yeni keşiflere imkân sağlarken, doktorlar için de farklı rahatsızlıkların takip edilmesinde kolaylık sağlamaktadır. Böylece ucuz ve etkili teşhis mümkün olmaktadır.

2.2. Elektriksel Kökenli İşaretler

Elektriksel kökenli işaretler, elektrotlar aracılığıyla canlı vücudundan alınan $100\ \mu\text{V}$ ~ $1\ \text{mV}$ arası düşük genlikli gürültülü işaretlerdir. Frekans spektrumları $0.1\ \text{Hz}$ ~ $2000\ \text{Hz}$ bölgesindedir. İşaretlerdeki gürültüler, şebeke gürültüleri, diğer biyomedikal işaret kaynakları ve elektronik elemanlardan kaynaklanmaktadır. Tablo 2.1’de bazı elektriksel kökenli işaretler, bu işaretlerin alındığı yerler, genlik ve frekans aralıkları verilmiştir. Biyomedikal potansiyelleri ölçebilmek için iyonik potansiyel ve akımları elektrik potansiyel veya akımlarına dönüştüren dönüştürücülere ihtiyaç vardır. Dönüştürücü, iki elektrottan meydana gelir ve elektrotların uygulandıkları noktalar arasındaki iyonik potansiyel farkını ölçer. Her bir hücrenin ürettiği bireysel aksiyon potansiyellerini ölçmek, bazı özel uygulamalar dışında çok zordur. Çünkü hücre içine hassas olarak elektrot yerleştirilmesi gerekmektedir.

Biyopotansiyeller için yapılan en genel ölçme yöntemi, vücut yüzeyinden yapılan ölçümlerdir. Bu durumda alttaki birçok hücrenin aksiyon potansiyellerinin yüzeye gelen toplamı alınmaktadır. Bazı ölçümler ise bir kasa, sinire veya beyinin belirli bölgelerine batırılan iğne elektrotlar yardımıyla yapılır. Bu yöntem, yüzey elektrotlarıyla yapılan ölçüme göre ağırlı bir yöntemdir.


Tablo 2.1. Elektriksel kökenli biyomedikal işaretler

İşaret	Alındığı yer	İşaretin Genliği	Frekans
Elektrokardiyogram (EKG)	Kalp	$100\text{-}500\ \mu\text{V}$	$0.1\text{-}150\ \text{Hz}$
Elektroensefalogram (EEG)	Beyin	$2\text{-}100\ \mu\text{V}$	$0.5\text{-}50\ \text{Hz}$
Elektrogastrogram (EGG)	Mide-Bağırsak	$100\text{-}500\ \mu\text{V}$	$2\text{-}4\text{cpm}$

2.2.1. ElektroKardiyoGram (EKG)

EKG, kalbin elektriksel aktivitesini gösterir ve kalp ritmi de Sinotrial Düğüm (SA) olarak bilinen kalp atışını düzenleyen hücreler tarafından kontrol edilirler. EKG kalpteki elektriksel potansiyel değişikliklerini kaydetmeye dayanan bir yöntemdir [9]. EKG, kalbin kulakçık ve karıncıklarının kasılma, gevşeme evrelerini, kalbin uyarılması ve uyarının iletilmesi sırasında ortaya çıkan elektriksel aktiviteyi milimetrik kâğıt üzerine yazdırma temeline dayanan bir tanı yöntemidir. Şekil 2.2’de normal 2 saniyelik PQRST dalga şekli gösterilmiştir. Sinotrial düğümünden uyarı çıktığında P dalgası oluşur ve burada oluşan darbe, atrium boyunca yayılıp, atrial kasılmayı tetikler. Darbenin kulakçıktan karıncığa

doğru ilerlerken oluşan yayılım gecikmesini PQ aralığı ifade eder. QRS süresi ventriküler aktivasyonun süresini gösterir ve saniyeye göre ölçülür. ST, ventriküler depolarizasyonun bitmesi ile repolarizasyonun (T dalgası) başlaması arasındaki aralığı gösterir. T dalgası, ventriküler repolarizasyon tarafından oluşturulan elektriksel kuvvetleri gösterir [33-35]



Şekil 2.2. Normal EKG

EKG, kardiyologlara birçok kalp hastalığı teşhisi konusunda önemli bilgiler vermektedir [28]. Dünyadaki ölümlerin önemli bir kısmını kalp hastalıkları oluşturmaktadır [19,36]. Valvüler kalp hastalıkları, mitral ve aort rahatsızlıkları, kalp aritmileri, damar tıkanıklığı, kulakçık-karınçık kas yapısının büyümesi, kalp krizi, miyokardın yetersiz oksijenizasyonu gibi hastalıklar kalp hastalıklarına örnek verilebilmektedir. Bu hastalıkların erken teşhisi, tıpın önemli bir araştırma alanını oluşturmaktadır [37]. EKG işaretlerinin teşhisi tek başına yeterli olmamakla birlikte hekimin deneyim ve bilgisi de önem taşımaktadır. Nadir de olsa normal bir EKG'ye sahip kişide kalp hastalığının gözlenmesi veya EKG'deki bazı anormalliklere bakılarak kişinin kalp hastası olduğuna dair net bir şey söylenemez [38].


Normal bir EKG'de, her döngü, bir P dalgasından, düzenli bir dar QRS dalgasından ve bir T dalgasından oluşur. ST ve PR segmentlerinin ve RR, QT ve PR aralıklarının oluşumu dalgaının şekli, süresi tek başına ya da başka tahlillerle birlikte kalp sorunları hakkında bilgi vermektedir [39,40].

Kalp rahatsızlıklarını incelemeye en temel metot, kalp seslerinin analiz edilmesidir. Kalbin kasılıp-gevşemesi sırasında kalp, kan akışı ve valf hareketlerinin mekanik fonksiyonlarıyla kalp sesi oluşur. Stetoskopla dinleyerek teşhis koyma, duymayla sınırlı olduğundan aşırı güvenli değildir. Bu sebeple hekimlerin kalp seslerini doğru bir şekilde analiz etmeye ihtiyaçları vardır. Sinyal işleme ve MÖ tekniklerinin gelişmesiyle, kalp seslerine dayalı birçok otomatik analiz ve teşhis yöntemi kullanılabilmektedir [41]. EKG'nin bilgisayar ortamında sinyal analiz metotları ile yorumlanması, hekimin işini kolaylaştırmaktadır [33].

2.2.2. ElektroEnsefaloGram (EEG)

Beyin, vücut aktivitelerinin kontrol edilip düzenlenmesini, duysal emirlerin alınıp yorumlanmasını buna bağlı olarak da alınan bilginin ilgili kaslara ve organlara iletilmesi gibi görevleri yerine getiren en önemli organdır. Beynin faaliyeti esnasında, sürekli ritmik elektriksel potansiyeller oluşurken aynı zamanda reseptör faaliyetlerine bağlı elektriksel potansiyeller de oluşur. Bu elektriksel potansiyellerin kafatasına yerleştirilen elektrotlarla kaydedilmesi işlemi EEG olarak isimlendirilir [42-44]. Önerilen EEG bağlantısı Şekil 2.3'te verilmiştir. Büyük bir veri kümesinden oluşan EEG, sinyali kaydeden elektrotların yakınlarında bulunan yaklaşık 100 milyon nöronun toplam aktivitelerinin ölçümü olup beynin fonksiyonel yapısı ve dinamiği hakkında bakış açısı sağlamaktadır [45,46].

EEG işaretleri, biyomedikal işaretler olup frekans bileşenleri son derece önemlidir [29]. Elektriksel aktivite kafatası boyunca yayıldıkça zayıflar. Fakat, analiz edilmeye yetecek seviyede kuvvetlendirici ile yükseltilir. Genlikleri 5-400 μV , frekans bölgesi de 0.5-100 Hz arasında değişiklik göstermektedir EEG dalgaları, frekans aralıklarına bağlı olarak beş grupta incelenir. Delta dalgaları 3.5 Hz altındaki frekansları içerirken, derin uykuda ve bebeklerde düzensiz aktivite esnasında meydana gelmektedir. Teta dalgaları 4-7 Hz arasındaki frekansları içerirken, uyumadan önce, uykulu ve stres sırasında meydana gelmektedir. Alfa dalgaları 8-13 Hz arasındaki frekansları içerirken, uyanık ve dinlenme halinde meydana gelmektedir. Beta dalgaları ise 13-30 Hz arasındaki frekansları içerirken, çok stresli olunan durumlarda öne çıkmaktadır [20]. Gamma dalgaları ise 30 Hz'den büyük frekansları içerirken, beynin tüm aktivitelerinden etkilenir Beynin aktivite düzeyi arttıkça EEG dalga frekansı yükselirken, genlikleri ise azalmaktadır.



Şekil 2.3. Önerilen EEG bağlantısı

EEG işaretleri, sinir sistemi rahatsızlıkları hakkında bilgi verir [46]. Özellikle EEG işaretlerinde oluşan piklerle karakterize olan atakları içeren nörolojik hastalıkların teşhisi için önem taşımaktadır. Sara olarak da bilinen epilepsi, beyin içinde bulunan sinir hücrelerinin olağan dışı bir elektrokimyasal boşalma yapması sonucu ortaya çıkan nörolojik bir rahatsızlıktır [47]. Epileptik nöbetler, beyindeki elektriksel aktivitenin aşırı ve kontrolsüz yayılımı sonucu oluşur [42,47], insan davranış ve hareketlerini etkileyerek geçici bilinç kaybı, dengesiz vücut hareketleri ve kas kasılmalarına neden olur [48]. Bu işaretler epileptik nöbetlerin nedenlerinin anlaşılması için önemli bilgiler taşımakla birlikte en önemli sorun gerçekleşme anının önceden tespit edilememesidir [44]. EEG’de gözlenen bazı epileptik dalga şekilleri, diğer bazı beyin rahatsızlıklarındaki dalga şekilleriyle benzerlik göstermektedir. Rutin bir EEG, beynin elektriksel gerilimlerinin geçici ve konumsal bilgilerinin gösterir [48]. EEG işaretlerinden epilepsi tespiti, hastalığın tedavi ve nöbetlerin önceden tahmin edilmesi açısından çok önemlidir. Ataklar düzensiz bir şekilde meydana geldikçe, epilepsiyi EEG’den tespit etmek yorucu ve zaman alıcı hale gelmektedir. Atak aktivitesinin analizi için EEG kaydı, uzman kişiler tarafından yorumlanmaktadır. Kişinin epilepsi hastası olup olmadığına karar verilmesi uzun süreli deneyim ile gözleme dayanmaktadır [49,50]. Bu süreç çok zaman alacağından işaretlerin yorumlanmasını kolaylaştırmak amacıyla literatürde birçok çalışma yapılmış olup spektral analizler beyin aktiviteleri hakkında önemli bilgiler vermektedir [51-55].

EEG, epileptik rahatsızlıklar dışında uyku apnesi hakkında bilgi almak için de kullanılmaktadır. Uyku, insan vücudunun kendini yenileme ve onarmasında büyük rol alan önemli bir fizyolojik aktivitesidir [56-58]. EEG, duygu tanımlama hakkında bilgi almak için de kullanılmaktadır [59]. Beyin Bilgisayar Arayüzü (BBA), nöromusküler hastalığa sahip kişilere bağlanır. İyi tasarlanmış bir BBA'da bu rahatsızlığı yaşayan kişinin beyniyle haberleşmek mümkündür. Benzer şekilde bir kişi bir aktiviteyi hayal ettiği zaman elektriksel aktivite EEG işaretlerine kaydolur. Böylece hayal edilen olayın çeşidi, kaydedilen EEG işaretleri ile tahmin edilebilir [60]. Ruhsal kökenli epileptik olmayan nöbetlerin de, EEG işaretleri ile gözlenmesi mümkün olmaktadır. Ancak, bu nöbetlere anormal elektriksel deşarjlar değil psikolojik süreçler sebep olmaktadır [61].

2.2.5. ElektroGastoGram (EGG)

EGG, mide yüzeyini kaplayan ön karın bölgesine yerleştirilen yüzey elektrotlarıyla mideye ait elektriksel aktivitenin ölçülmesini sağlayan bir tekniktir [62]. Sindirim sistemi ile ilgili sorun yaşayan hastalarda mide bulantısı, kusma, karın ağrısı, gecikmeli mide boşalması sonucu ortaya çıkan şişkinlik, hazımsızlık gibi problemler oluşmaktadır. [62-64]. Gecikmeli mide boşalması ince bağırsak aktivitesinin anormalliği sonucu ortaya çıkabildiği gibi, bağırsak tıkanması veya anormal midesel motor aktivitesi ile de ilgili olabilmektedir. Çoğu hasta, doğru teşhis koyulmadan önce birçok ameliyat geçirmektedir. Sindirim sistemi hareketleri, bu rahatsızlıkların teşhisine yardımcı olmaktadır [63].

Mideye ait rahatsızlıklar yaşa ve cinsiyete göre insanları etkilemektedir [64]. Bu hastalıklar, fonksiyonel ve bulaşıcı hastalıkları olmak üzere iki grupta incelenmektedir. Bulaşıcı hastalıklara mikroorganizmalar ve bakteriler sebep olurken, fonksiyonel hastalıklara beslenme yetersizliğinden kaynaklanan kas zayıflamaları sebep olmaktadır. Bu fonksiyonel rahatsızlıkların teşhisi için endoskopi, kolonoskopi gibi metotlar olmakla birlikte bu metotlar masraflı, ağrılı ve zaman aldığından dolayı hastalar tarafından çok istenmemektedir [65]. Mide elektriksel aktivitesi vücut içinden ve vücut dışından ölçülebilmektedir. Mide içerisinden yapılan ölçümler mikro elektrotlarla gerçekleştirilirken, mide dışından yapılan ölçümlerde iğne elektrotlar kullanılmaktadır. Bunun yerine elektriksel aktivite noninvazif bir yöntem olan EGG ile yüzey elektrotları kullanılarak kaydedilir [66]. Midedeki elektriksel aktiviteler, midesel motor aktivitelerinin temelini oluşturur ve genellikle iki önemli başlıkta incelenir [67]. Bunlar, durağan dalga

(slow wave) ve diken dalga (spike wave)'dır [68]. Durağan dalga, elektriksel kontrol aktivitesi olarak bilinmekte (EKA) diğeri ise elektriksel tepki aktivitesi olarak (ETA) bilinmektedir. Midede bir kasılma meydana geldiğinde genellikle EKA ile ETA üst üste çakışmaktadır.


EGG işaretlerinin diğeri biyomedikal işaretlere göre daha düşük genlikli olmaları, çevre organlardaki hareketler, solunum ve dış etkilerin ek gürültülere sebep olmaları işaretin analiz edilmesini zorlaştırmaktadır. Dolayısıyla bu sinyallerin kaydı çok hassas bir şekilde yapılmalı, daha sonra da karakteristik özelliklerin doğru çıkarılması için kaydı alınan işaretler uygun bir filtreleme ve yükseltme işlemlerine tabi tutulmalıdır [69]. Kayıttan önce her hastanın sindirim sistemi ile ilgili şikâyetleri (bulantı, kusma, hazımsızlık, ülser vb.) kayıt altına alınmalı ve 48 saat öncesinden mide fonksiyonunu etkileyebilecek tüm tıbbi müdahale ve ilaç kullanımı kesilmelidir. Hastalardan alınan EGG kayıtları, hastanın aç ve tok olduğu her iki durum için de yapılacağından kayıttan 6 saat önce yemek de kesilmelidir [70].

Noninvazif yapısı, ağrısız oluşu ve devam eden mide aktivitelerine engel olmayışı EGG'yi cazip hale getirmektedir [71]. Mide kaslarındaki elektriksel aktivitenin kaydedilmesi için algılayıcı olarak Ag/AgCl referans elektrotları kullanılmaktadır [72]. Elektriksel işaretler, genellikle elektriksel aktivitelerin yer aldığı orta corpustan elde edilir. Fazla gürültü oluşumunu engellemek amacıyla, hasta hareketsizce sırtüstü yatırılmalıdır. Literatürde, gürültü seviyesini minimuma indirmek için farklı bağlantı şekilleri denenmiştir.

EGG analizi, frekans ve genlik analizine dayalıdır. EGG işaretlerini analiz etmek ve ölçüm yapmak için literatürde birçok yöntem bulunmaktadır [73-77]. Midenin elektriksel aktivitesinde EGG, durağan dalga ve diken dalga olmak üzere iki bileşenden oluşur. Peristaltik kasılmaları tetiklemekten sorumlu daha yüksek frekans içerikli (antral kasılma) diken dalga, doğrudan durağan dalga üzerine eklenmiş olan saniye/pik gerilimi ile ilgilidir. Durağan dalga aktivitesi ise mide elektriksel aktivitesinin yayılmasını ve maksimum frekansını kontrol eder, 3 cpm normal frekansa sahiptir [78]. Hasta olmayan kişide test yemeğinden önce ve sonra frekans ile genlik değişimi gözlemlendiğinde, her iki durumda da elektriksel frekansın sabit olması beklenmektedir [79].

EGG işaretinde yavaş dalga normal frekansı 2-4 cpm frekans seviyesine sahiptir, bu değer aralığının aşağı veya yukarı seviyesi normal kabul edilmemektedir [70]. Midesel ritim bozuklukları, bradygastria (< 2cpm), tachygastria (>4 cpm) ve disritmi (belli bir

ritim yok) olarak bilinir. Şekil 2.4'te bu ritim bozukluklarına ait işlenmemiş ham EGG kayıtları verilmiştir.



Şekil 2.4. Ritim bozuklukları [74]

2.3. Elektriksel Kökenli Olmayan İşaretler

Kan basıncı, kan akış hızı, solunum hacmi, kalp sesi, sıcaklık, pH, PO₂ gibi işaretler de organizmanın içinde oluşan ve dönüştürücüler yardımıyla alınan elektriksel kökenli olmayan işaretlerdir. Tablo 2.2'de elektrik kökenli olmayan işaretler, kullanılan dönüştürücüler ve incelendiği birim verilmiştir. Ayrıca, görüntü işlemede kullanılan göğüs kanseri gibi görüntü verileri de, elektriksel olmayan işaretler grubunda yer alabilmektedir.

Tablo 2.2. Elektriksel kökenli olmayan biyomedikal işaretler

İşaret	Dönüştürücü	İncelendiği Birim
Kan basıncı	Basınç	Kalp-dolaşım sistemi
Kan Akış Hızı	Elektromagnetik-ultrasonik	Dolaşım sistemi
Solunum Hacmi	Pletismograf	Akciğer
Sıcaklık	Sıcaklık	Vücudun veya organların
pH	pHmetre	Kanın
PO ₂	Kimyasal	Kanın ve havanın

2.3.1. Göğüs Kanseri

Kanser, bir organın veya dokunun anormal hücrelerinin, düzensiz olarak bölünmesi ve hücrelerin kontrolsüz çoğalmasıyla oluştuğu bir hastalık grubudur. Vücudumuzdaki kas ve sinir hücreleri dışında, diğer sağlıklı hücreler bölünme kabiliyetine sahiptir. Yaşamın ilk yıllarına göre, yaş ilerledikçe, bölünme hızı yavaşlar ve bazı durumlarda hücreler sonsuz bölünme yeteneğine sahip değildir. Normalde, vücudun büyümesi, bölünmesi ve sağlıklı ve düzgün işleyişi için daha fazla hücre üretmesi gerekir. Ancak bazen bu süreç olması gerekenden farklı bir boyut kazanarak bilincini kaybetmiş olan kanserli hücreler, kontrolsüz bir şekilde bölünmeye ve çoğalmaya başlar. Aşırı bölünen hücrelerin kitleleri tümör oluşturur. Tümörler iyi huylu veya kötü huylu olabilirler. Kötü huylu tümörler kanserdir, iyi huylu tümörler ise tekrarlanmaz ve vücudun diğer bölgelerine yayılmazlar. Kontrolsüz ve düzensiz şekilde bölünen kötü huylu tümörler normal dokuları daraltabilir, veya yok edebilirler. Kanser hücreleri tümörden ayrılırsa, kan veya lenf dolaşımı yoluyla vücudun diğer kısımlarına giderek o bölgelerde tümör kolonileri oluştururlar [80,81].

Yıllar içinde, kanser vakalarının sayısı ve türlerinde büyük bir artış gözlenmektedir. Uluslararası Kanser Ajansı tarafından yayınlanan 2012 kanser tahminlerine göre, dünyada yeni teşhis edilen kanser hastalarının sayısı ve kansere bağlı ölümler gittikçe artmaktadır. GLOBOCAN 2012 verilerine göre 2012 yılında dünyada toplam 14,1 milyon yeni kanser vakası geliştirilmiş ve 8.2 milyon kanser kaynaklı ölüm olmuştur [82]. Dünyada en çok teşhis edilen kanser türleri arasında akciğer (%13), göğüs (%11.9) ve kolon (%9.7) kanseri yer almaktadır. Ayrıca kanser ölüm oranları ise sırasıyla akciğer (%19.4), karaciğer (%9.1) ve mide (%8.8) kanserleridir [82]. Bu nedenle, kanser vakaları arasında teşhis edilen ikinci en büyük kanser tipinin göğüs kanseri olduğu söylenebilmektedir. Göğüs kanseri, kadınlarda en sık görülen kanser türüdür ve ölümle sonuçlanabilmektedir. Göğüs kanserinin erken teşhisi, taranması ve tedavisine yönelik çabaların artırılması gerekmektedir. Tıpta yeni gelişmelerle birlikte, önemli bir araştırma alanı olan kanser verilerine doğru tanı koymak ve buna bağlı olarak bir tedavi sürecine başlamak doktorlar için büyük bir sorumlulukla iyi bir deneyim gerektirmektedir. Dolayısıyla, tıp araştırmacıları tarafından öğrenilen yapay bir sistemin kullanılması, hem verilerin durumu hakkında yorum yapılmasını hem de tanı ve tedavinin uygulanmasının gecikmesini önlemeyi sağlayacaktır. Bu amaçla, tıbbi teşhis alanında otomatik sınıflandırıcı

sistemlerinin kullanımı, gelecek yeni verilerin durumu hakkında karar vermekte etkili olacaktır. Özellikle, MÖ yöntemleri önemli bir yere sahip olup bu teknikler, gelecekte yeni bir kanser verisini tahmin etmenin yanı sıra parçacıkların karmaşık veri kümeleri içinde kısa sürede ve daha ayrıntılı olarak tanımlanmasına imkân sağlar [83-87]. Literatürde kanser teşhisi için birçok yöntem ve strateji bulunmasına rağmen, mevcut yöntemler kötü huylu tümörlerin, hastalığın erken evrelerindeki iyi huylu tümörlerden ayırt edilmesinde düşük bir duyarlılığa sahiptir.

2.3.2. Kan Basıncı

Kan basıncı, damar yatağındaki kanın akış sırasında damar duvarlarına yaptığı basınçtır. Kalp kasıldıkça, damarlara kan pompalanır. Bu, arterlerdeki basıncı artırırken, kalp atışlarında basınç azalır. Bunun bir sonucu olarak, kan basıncı sistolik basınç ve diyastolik basınç olmak üzere iki değerle gösterilir ve birim milimetre-civadır (mmHg) [88]. Kan basıncı ölçümü ile kişinin optimum, normal, hipertansiyon, hipotansiyon ve prehipertansiyondan hangi özelliklerin sergilediğine karar verilir. Optimum Kan basıncı 120/80 mmHg'nin altında iken, normal kan basıncı 130/85 mmHg'nin altındadır. Hipertansiyon 140/90 mmHg'den daha yüksektir ve en önemli sağlık sorunlarından biridir. Hipertansiyon, fark edilmediğinde baş ağrısı, baş dönmesi, böbrek bozuklukları, felç ve görme bozukluklarına yol açabilir. Çoğu hipertansiyon hastası, iç organlarının yavaşça hasar gördüğünün farkında değildir. [89]. Sistolik ve diyastolik kan basıncı seviyeleri, gelecekte tehlikeli bir durumu tahmin edebilen önemli parametrelerdir. Ek olarak, artan kalp atım hızı, azalan kalp hızı değişkenliği, artan arteriyel nabız basıncı, artmış nabız dalga hızı, hastaları etkileyen diğer risk faktörleridir. [90]. Hipertansiyonun doğru teşhisi ve tedavisi için sürekli kan basıncı ölçümü gereklidir [91]. Hipotansiyon anormal derecede düşük kan basıncıdır ve 90/60 mmHg'nin altındadır. Bu durum üzüntü, stres, uzun süreli açlık ve vitamin eksikliği gibi birçok nedenden dolayı ortaya çıkabilir. Fakat, her düşük kan basıncı bir sağlık sorununa işaret etmemektedir. Prehipertansiyon, kan basıncı yükselmiş ancak yine de normal sınırlar içinde olan hastaları tanımlamak için kullanılır. Kan basıncı değerlerinin tespit edilerek yorum yapabilmesini kolaylaştırmak amacıyla [32]'de noninavazif kan basıncı tespiti yapılmıştır.

3. SİNYAL ANALİZ METOTLARI

3.1. Giriş

Sinyal, bilgi taşıyan herhangi bir fiziksel büyüklük, işleme belirli bir sonuca ulaşmak için uygulanan bir dizi işlem adıdır. Dolayısıyla sinyal işleme, işaretlerden bilgi çıkarmak ya da bilgileri taşıyan işaretleri bir formdan diğerine dönüştürmek için yapılan uygulamalardır [92]. Sinyal işleme ile ses işaretleri, elektromanyetik dalgalar veya görsel öğeler kullanılarak birçok alana uygulanabilir hale getirilebilirler. Sayısal işaret işlemede işaretler mikroişlemciler, bilgisayarlar veya lojik devrelerle işlendiğinden sayısal ismini almaktadır. Sayısal işaret işleme alanı, bilgisayar teknolojisindeki gelişmelerle birlikte haberleşme, multimedya, tıbbi ve bilimsel görüntüleme dâhil olmak üzere geniş bir alan yelpazesinde hızla gelişmektedir. Sinyal işleme ile işaretin fiziksel olarak boyutunu ölçme, işareti depolama ve daha sonra da işareti kendi isteğimiz doğrultusunda yeniden yapılandırma, gürültü azaltma, işaretin kalitesini artırma, depolama alanından kazanç sağlama amacıyla veri sıkıştırma, özellik çıkarma gibi işlemleri yapmak mümkün olmaktadır [93].

Sinyal işleme tekniklerine bakıldığında zaman literatürde; FD, filtreleme tabanlı yöntemler ve dönüşüm tabanlı yöntemler mevcuttur. Bu tez çalışmasında EKG sinyallerinin maruz kaldığı gürültüyü kaldırmak için dönüşüm tabanlı yöntemler kullanılmıştır.

3.2. Fourier Dönüşümü

FD, zaman bölgesi işaretlerini frekans bölgesi gösterimlerine dönüştürerek spektral gösterimlerini sağlamasının yanı sıra, frekans bölgesinde belli sistemlerin ve özelliklerinin betimlenmesinde de rol oynar.

Durağan olmayan işaretlerin yapıları gereği, hangi frekansların hangi zaman anında olduğu konusunda net bir veri olmazken, durağan işaretlerde böyle bir problemle karşılaşılmaz, çünkü durağan işaretlerde frekanslar zamanla sabittir. Durağan olmayan işaretlerden EEG, EGG, EKG gibi biyomedikal işaretlerin gürültüye maruz kalmaları,


gürültülerin tepe değerlerini etkilemelerinden dolayı FFT zaman-frekans bilgisinin bir arada olmasında yetersiz kalmaktadır [11,16]. Kısa Zamanlı Fourier Dönüşümünde (KZFD) hassasiyet pencere seçimine bağlı olup, zamansal ve spektral çözünürlükler arasında kayıplar yarattığından ve tüm frekans bantları için sınırlı frekans çözünürlüğü sağladığından durağan olmayan işaretler için ideal olarak uygun değildir [12]. Yüksek frekans çözünürlüğü elde etmek için zamanda kayan uzun pencere seçilirse düşük zaman çözünürlüğü elde edilecek aynı şekilde küçük pencere kullanımı zamanda iyi çözünürlük verecek fakat düşük frekans çözünürlüğüne sebep olacaktır. [75]. Dolayısıyla dalganın hem zaman hem frekans karakteristiklerinin tanımlanmasındaki eksiklikleri gidermek için DD önemli yer tutmaktadır [13,92].

3.3. Dalgacık ve Dalgacık Dönüşümü

DD, basit bir zaman fonksiyonu ile ölçekleme ve kaydırma yapar. Ölçekleme ile ana dalgacık sıkıştırılır, kaydırma ile de zamanda değişken pencerelerle kaydırılır. Böylece bütün frekans aralıklarında esnek zaman-frekans çözünürlüğü elde edilir. Detay ve yaklaşık katsayılar elde edildikten sonra işaret farklı frekans bantlarına ayrılmış olur. Her bir bileşen o ölçekteki çözünürlüğü ile incelenir [93]. Bu alt bantların güç spektral yoğunluklarının hesaplanması işaret hakkında önemli sayılabilecek özellikleri verebilir [72]. Sinyalin zaman bilgisi DD'nin zamanda kaydırılmış dönüşümüyle, frekans bilgisi ise ölçekli dönüşümüyle elde edilir [71]. Diğer bir deyişle DD, düşük frekansta doğru bir frekans bilgisi, yüksek frekansta doğru bir zaman bilgisi verir. DD ile gürültülerin elimine edilmesi, işaretlerin özellik çıkarımı, spektral parametrelerin belirlenmesi ve zaman-frekans bilgisinin eş zamanlı olarak alınabilmesinden dolayı oldukça önemli bir metottur.

Dalgacıklar, veriyi farklı frekanstaki elemanlara dönüştüren matematiksel fonksiyonlardır. DD, bir işareti tanımlamak için bir dizi temel ötelenmiş ve sıkıştırılmış dalgacık fonksiyonu kullanan bir yöntem olup farklı frekans özellikli durağan olmayan işaretler arasında ayırım yapmaya müsaade eden dönüşümdür [93]. Bu fonksiyonların, süreksizlik ve keskin artış durumlarında Fourier metotlarına göre avantajları vardır. Dalgacıklar belirli matematiksel fonksiyonları ifade etmek için kullanılırlar. Daubechies, Mallat ve Strang dalgacık teorisine birçok katkıda bulunmuşlardır [94,97]. Bilim adamları yıllardır Fourier'in temelini oluşturan sinüs ve kosinüs fonksiyonlarından ziyade değişken işaretleri tahmin etmek için daha uygun fonksiyonlar istemişlerdir. Bu fonksiyonlar dalgacık analizi ile belirgin süreksizliklerde uygunlaştırılır. Dalgacık sonlu enerjili küçük

bir dalga olup, işaretlerin zaman-frekans ifadesini elde etmeye imkân verir. Şekil 3.1’de dalga ile dalgacık kıyaslanmıştır. Soldaki grafik sonsuz enerjili sinüs dalgasını ifade ederken, sağdaki grafik sonlu enerjili dalgacığı ifade eder.



Şekil 3.1. Dalga ve Dalgacık

FD’nin tersine, DD ile her bir zaman aralığında işaretin hem alçak (A) hem de yüksek frekans bileşenlerini (D) hesaplamak mümkündür. Yüksek frekans bileşenleri ile ayrıntılar elde edilirken, düşük frekanslı bileşenlerle temel işaret elde edilir. Geniş bir uygulama alanı içerisinde başarılı sonuçlar veren zaman-skala ifadesidir. İşlenmemiş biyomedikal işaretlerde hareket artefaktı, elektriksel potansiyel değişimlerinden kaynaklanan artefakt, kayıt esnasındaki kayıplardan kaynaklanan artefaktların elimine edilmesi için uygun bir analiz yöntemine ihtiyaç vardır [59]. DD ile biyomedikal işaretlerin karakteristiklerin çıkarılması, önemli sayılabilecek özelliklerin korunmasında, parçacık tanımda etkilidir [88,90]. Bunun için de uygun dalgacığın seçilmesi önemli rol oynamaktadır [98]. Dalgacık seçimi ile ilgili pek çok yöntem olmakla birlikte bir dalgacık mümkün olduğunca az sayıda dalgacık katsayısı ile gösteriliyorsa onun uygun bir dalgacık olduğu düşünülmektedir. Bir dalgacık için sıkıştırılmış işaretlerle ilgili hata minimum ise seçilen dalgacığın dalgacık katsayılarının orijinal işareti en iyi şekilde temsil ettiği düşünülür [94]. Üstelik skaler dalgacıklar, yerine çoklu dalgacıkların kullanılması performansı daha da artırmaktadır. Bu yöntemle frekansı zamanla değişen sistemlerin analizi, geçici durum analizleri ve veri sıkıştırma oldukça hassas bir şekilde yapılmaktadır. Veri sıkıştırmada kullanılan diğer teknikler, verinin önemli sayılabilecek özelliklerinin

kaybedilmesine ve işaretin bozulmasına sebep olabilmektedir. Dalgacık analizi, Fourier ve diğer sinyal analiz yöntemlerini elimine etmemekle birlikte bu tekniklere ilave özellikler sağlamıştır.

3.3.1. Dalgacık Dönüşümü Yöntemleri

Dalgacık dönüşümleri nümerik analiz, sinyal ve görüntü işleme gibi çeşitli uygulamalarda kullanışlı bir araçtır. Özellikle akıllı hesaplama yöntemlerinde ham verinin özelliklerini çıkarmak adına önemli bir yer tutmaktadır. DD, SDD, ADD, ÇDD olmak üzere üç başlıkta incelenebilir.

3.3.1.1. Sürekli Dalgacık Dönüşümü (SDD)

FD'nin temelini oluşturan SDD işaret tüm zaman aralığında dalgacık fonksiyonunun farklı ölçekli ve kaydırılmış halleri ile çarpımının toplamı olarak ifade edilir. SDD'de her bir çarpanda yeni bir katsayı elde edileceğinden, her bir katsayı orijinal işaretin farklı ölçek ve konumlardaki dalgacık bileşenlerini oluşturmaktadır. Fourier Dönüşümde eşit aralıklarla işlem yapılırken, DD'de düşük frekanslarda geniş zaman aralığında, yüksek frekanslarda ise küçük zaman aralığında işlem yapılmaktadır. SDD ;

$$SDD(s, \tau) = \int_{-\infty}^{+\infty} f(t) \Psi_{s,\tau}^*(t) dt \quad (3.1)$$

* kompleks eşleniği

S ölçek parametresini

τ kaydırma parametresini

$f(t)$ dönüşümü yapılacak fonksiyon

$\Psi_{s,\tau}(t)$ ana dalgacık fonksiyonu olarak ifade edilir.

Dalgacık fonksiyonları ana dalgacıktan, ölçek ve kaydırma faktörlerinin kullanılmasıyla elde edilir. Matematiksel ifadesi;


$$\Psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t - \tau}{s}\right) \quad (3.2)$$

Kaydırma parametresi, pencerenin geçici pozisyonunu ifade eder. Bu pencere, işaret üzerinde kaydırıldığında frekans spektrumunun geçici bilgisi elde edilir. Ölçekleme

bir dalgacığın sıkıştırılması ya da genişletilmesi anlamına gelmektedir. Genişletme ölçekleme faktörü kullanılarak tanımlanır. Daha küçük bir ölçek faktörü daha sıkıştırılmış bir dalgacık anlamına gelir.

3.3.1.2. Ayırık Dalgacık Dönüşümü (ADD)


ADD’de işaret alçak frekans bileşenlerine ve yüksek frekans bileşenlerine ayrıştırılır. Ayırık zamanlı S işareti, Şekil 3.2’de gösterildiği alçak geçiren filtreden geçirilerek A yaklaşıklık katsayıları, yüksek geçiren filtreden geçirilerek de D detay katsayıları elde edilir. Yaklaşıklık ve detay katsayılarının toplanması ile tekrar orijinal S işaretini elde etmek mümkündür.



Şekil 3.2. S işaretinin alçak geçiren ve yüksek geçiren filtre ile filtrelenmesi

DD ile veri, alt bantlara ayrılmaktadır. Alçak ve yüksek geçiren filtre ile filtrelenen veride, yüksek geçiren filtre dalgacık fonksiyonunu ve alçak geçiren filtre ölçeklendirme fonksiyonunu modellemektedir. Veriden önce iki ara alt bant elde edilmekte ve süzgeç çıktıları ile aşağı örneklenmektedir. Daha sonra elde edilen ara alt bantlara tekrar filtreleme yapılmakta ve filtre çıktıları ile aşağı örneklenmektedir. S ayırık işaretinin 1. seviyeden ayrıştırılmasıyla $cA1$ ve $cD1$ katsayıları elde edilir. 2. Seviyeden ayrıştırmada $cA1$ tekrar alçak ve yüksek geçiren filtre ile filtrelenerek $cA2$ ve $cD2$ katsayıları elde edilir. Ardışıl olarak bu alçak ve yüksek geçiren filtrelerin uygulanması istenilen ayrıştırma seviyesine kadar uygulanır. En son seviyedeki cAn bandı alçak geçiren filtreleme ile elde edildiğinden orijinal verinin düşük frekanslı, düşük çözünürlüklü bir kopyası gibidir. Dönüşümünün veriye bir kez uygulanması ile tek seviyeli DD elde edilmektedir. Aynı filtre çiftinin cA

bandına arka arkaya uygulanması ile DD'nin seviyesi arttırılabilir. Şekil 3.3'te 2. seviyeden DD sonucunda elde edilen alt bantlar gösterilmektedir.



Şekil 3.3. 2.seviyeden dönüşüm

Literatürde ÇDD'nin, TDD'ye oranla daha üstün olduğu belirtilmesine rağmen bu dönüşümünün temelini tekli DD'ye bağlı olduğu belirtilmiştir [15-17].

3.4. Spektral Kestirim Yöntemleri

Spektral analiz, bir işaretin frekans içeriği hakkında bilgi vermektedir. Spektral analiz yöntemleri parametrik analiz ve parametrik-olmayan analiz olmak üzere iki gruba ayrılmaktadır.

3.4.1. Sonlu Süreli İşaretlerin Spektral Kestirimi


Veri dizisinin sonlu süreli olması güç spektrumu kalitesinde kısıtlamaya sebep olmaktadır. Dolayısıyla verinin boyutunun büyük olması veriden daha iyi kestirim çıkarılmasına imkân sağlamaktadır. Eğer işaret durağan bir işaret değilse bu durumda keyfi uzunlukta veri seçememekle birlikte veri uzunluğu işaretteki zaman değişimlerinin hızı tarafında belirlenir. Amaç, çok yakın aralıklı spektrumları olan veri kayıtlarındaki farklı işaret bileşenlerinin spektral karakteristiklerini çıkarmayı sağlayan en kısa veri kaydıdır. Sonlu uzunluktaki verilerin güç spektrum kestirimlerindeki en büyük problem bozunumdur. Bu, hem deterministik işaretin hem de rastgele işaretin spektrum hesaplamasında ortaya çıkmaktadır [2].

3.4.1.1. Deterministik İşaretlerin Enerji Yoğunluk Spektrumunun Hesaplanması

Deterministik işaret, işaretin her değerinde matematiksel bir fonksiyon veya tanımlı bazı kurallarla ifade edilebilen işarettir. Bu işaretlerde geçmiş değerler üzerinden gelecek değerler üzerine hesaplamalar yapılabilir. Rastgele işaret ise davranışı belli olmayan sonraki değerleri tahmin edilemeyen işarettir. Bir işaretin spektrumunun başarısı işaretin periyodik, sonlu uzunlukta olmasına bağlı olup ayrıca gürültüden ve özellikle biyomedikal işaretlerde artefaktlardan çok etkilenmemesi gerekmektedir. Dolayısıyla farklı spektrum yöntemleri önem taşımaktadır [2].

3.4.1.2. Rastgele İşaretlerin Güç Spektrum Kestirimi

Sonlu enerji işaretleri FD sahiptir ve spektral bölgede enerji yoğunluk spektrumları ile tanımlanırlar. Diğer yandan durağan rastgele işaretlerin de sonlu enerjisi yoktur ve dolayısıyla FD sahip değildir. Bu tip işaretler sonlu ortalama güce sahiptir ve dolayısıyla güç yoğunluk spektrumu ile tanımlanırlar. Bu da periyodograma karşılık gelmektedir. Periyodogram, büyüklük spektrumunun karesinin alınmasıyla benzerlik göstermekle birlikte, tek fark ölçek faktörüdür. İşaretin spektrumu, AFD ile hesaplanır, elde edilen sonucun karesi alınır ve desibel cinsinden ifade edilerek periyodogram elde edilir. Şekil 3.4'te periyodogramı alınmış işaret verilmiştir [2].



Şekil 3.4. Periyodogramı alınmış işaret

3.4.2. Güç Spektrum Kestirimi İçin Parametrik Olmayan Yöntemler

Verilerin nasıl üretildikleri hakkında bilgi sahibi olunamadığından bu ismi almıştır. Parametrik olmayan yöntemler güç spektrum yoğunluğunun doğrudan işareten tahmin edildiği yöntemlerdir.

Fourier dönüşümü alınamayan, sonlu enerjisi olmayan işaretlerin sonlu ortalama güçleri vardır ve güç spektral yoğunluğu ile ifade edilmektedir. Güç spektrum yoğunluğu (PSD), periyodogram ile ifade edilir. En basit yöntem periyodogram olup, periyodogramın geliştirilmiş bir versiyonu Bartlett yöntemi, Welch yöntemi, Blackman ve Tukey Yöntemi olmak üzere farklı çeşitleri mevcuttur [2].

3.4.2.1. Bartlett Yöntemi (Periyodogramların Ortalanması)


Periyodogramdaki varyansları düşürmek için ilk olarak N noktalı bir dizi birbiriyle örtüşmeyecek şekilde K parçaya bölünür, her bir parçanın uzunluğu M olur. Her bir parça için periyodogram hesaplanır. Son olarak da bu K parça için periyodogramların ortalaması hesaplanır. Sonuç olarak veri uzunluğu N noktadan, N/K 'ya inmiş, spektral genişlik K çarpanı kadar artan pencere sonucunu vermektedir. Dolayısıyla frekans çözünürlüğü K çarpanı kadar küçülmüştür.

3.4.2.2. Welch Yöntemi (Değiştirilmiş Periyodogramların Ortalanması)

Welch yönteminin, Bartlett yönteminden farkı veri parçalarının örtüşmesine müsaade edilmesi ve veri parçalarının pencerelendikten sonra periyodogramının alınmasıdır. Farklı pencere fonksiyonlarının kullanımı farklı varyanslar oluşturacaktır. Bu da veri parçalarının %50'den az veya çok örtüşmesi ile ilgili olup kestirimin özellikleri iyileştirilebilmektedir. Welch metodu, periyodogramın geliştirilmiş halidir. Bu yöntemde ilk olarak veri her birinde M örnek içeren üst üste binmiş K segmente ayrılır. Örtüşmeyen boyut D ise bu durumda örtüşmeyen segment M-D örnek içerir. Bu durumda $K=(N-M)/D+1$ ve örtüşme yüzdesi $100 * (M-D)/M$ olur.

Welch periyodogramı, klasik periyodograma göre daha yumuşak bir spektrum oluşturur. Şekil 3.5'te EKG işaretine ait periyodogram (a) ve welch periyodogramı (b)

verilmiştir. Welch periyodogramında, daha yumuşak bir spektrum olduğu açıkça görülmektedir. Her ikisinde de frekans eksenini normalize edilmiştir.



Şekil 3.5. EKG işaretinin güç spektrumu a) periyodogram b) welch periyodogramı

3.4.2.3. Blackman ve Tukey Yöntemi (Periyodogramların Yumuşatılması)

Blackman ve Tukey Yöntemi, örnek özkorelasyon dizisinin önce pencerelendiği ve ardından güç spektrum kestirimi vermesi için Fourier Dönüşümün alındığı bir yöntemdir.

3.4.3. Güç Spektrum Kestirimi için Parametrik Yöntemler

Parametrik yöntemler, işaret uzunluğu kısa olduğunda, parametrik olmayan yöntemlere göre daha yüksek çözünürlük verebilir. Bu yöntemler, spektral kestirim için Güç Spektrum Yoğunluğunu doğrudan veriden tahmin etmeye çalışmak yerine, verileri beyaz gürültüye dayanan doğrusal bir sistemin çıktısı olarak modeller ve daha sonra bu doğrusal sistem parametrelerini tahmin etmeye çalışır. En sık kullanılan doğrusal sistem modeli, tüm kutup modeli olup, z-düzleminde tüm sıfırları olan bir filtredir. Beyaz gürültü girişi için böyle bir filtrenin çıktısı, otomatik ilerletici bir işlemdir. Bu nedenle, bu yöntemlere bazen AR spektral tahmini (Autoregressive power spectral density estimate) yöntemleri de denir. Bu yöntem parametrik olmayan yöntemlere göre avantaj sağlamakla birlikte kısa veri uzunluklarında sınırlı frekans çözünürlükleri dezavantaj olarak sayılabilir.

Parametrik olmayan güç spektrum kestirim yöntemleri kolay anlaşılır, FFT algoritması ile hesaplanabilmektedir. Bu yöntemler, birçok uygulamada gerekli frekans çözünürlüğünü elde etmek için uzun veri kaydının olması gerekir. Ayrıca bu yöntemler pencerelemeden dolayı sonlu uzunluklu veri kayıtlarına özgü spektral sızıntı etkilerinden olumsuz etkilenirler. Bunu engellemek amacıyla geliştirilen parametrik yöntemlerle FFT tabanlı yöntemlere göre daha iyi çözünürlük sağlar ve zamanla değişen veya kısa veri kayıtlarının olduğu uygulamalarda oldukça iyi sonuçlar vermektedir [2].



4. AKILLI HESAPLAMA YÖNTEMLERİ

Son yıllarda teknolojinin gelişmesine paralel olarak bilgisayarlar ve bilgisayar destekli sistemler hayatımızda önemli bir yer edinmiştir. Bilgisayarlar, kullandığımız pek çok elektronik cihazlarda bulunmakla birlikte, bilgisayar destekli sistemlerden de sağlık, ticaret, tarım ve sanayi gibi farklı alanlarda faydalanılmaktadır. Önceleri uygulama alanlarında bilgisayarlar yüksek hızlarından dolayı yalnızca veriler arasında işlem yapmak ve sonuç almak için kullanılırken, son zamanlarda geliştirilen yeni yöntemler eklenerek bilgisayarlar artık elde edilen verileri özetleyebilen, veriler arasında ilişki kurabilen ve bu ilişkiler neticesinde sonuçları yorumlayabilen makineler haline gelmişlerdir [99].

Bilgisayarlarla veriler arasında ilişki kurma özelliği sağlama ve matematiksel olarak modellenmesi mümkün olmayan sistemlerin modellenmesi amacıyla yapılan çalışmalara yapay zekâ adı verilmektedir. Zekâ, ilk kez karşılaşılan bir olaya uyum sağlayabilme, herhangi bir durumu öğrenme ve analiz etme yeteneğine sahiptir. Zekânın, yazılımlarla taklit edilmesi de yapay zekâ olarak adlandırılmaktadır. Yapay zekâ teknikleri kullanılarak oluşturulmuş bir bilgisayar sistemi, eldeki verileri kullanarak olaylar arasında ilişkiler kurmakta ve gelecek yeni olaylar hakkında önceden tahminde bulunabilme özelliğine sahip olacaktır.

Bu özelliklerinden dolayı YSA ve MÖ gibi yapay zekâ teknikleri farklı alanlarda problemlerin çözümü için fazlaca kullanılmakta ve kullanılmaya da devam edilecektir.

4.1. Yapay Sinir Ağları (YSA)

Beyin, idrak etmeye dayalı herhangi bir olay karşısında geçmişte kazanılmış deneyimlerine bağlı olarak çözüm bulma yeteneğine sahiptir. Biyomedikal bir sinir sisteminde, bir önceki sinir hücresinden veya dış dünyadan alınan bir işaretin elektriksel işaretlere dönüştürülüp beyne iletilmesi ve bu elektriksel işaretlerin de tepki sinirleri ile tepki oluşturduğu Şekil 4.1'de gösterilmiştir. YSA, insan beyninden esinlenerek geliştirilmiştir [100]. Sinirsel algılayıcılar aracılığı ile kazanılmış bilgilerle çözüm bulma yeteneği ve beynin davranışının modellenmesi için YSA kavramı geniş bir araştırma ve

uygulama alanına sahiptir. Bu bağlamda, her nasıl ki merkezi sinir sisteminin temel işlem elemanı sinir hücreleri (nöronlar) ise YSA'nın da temel işlem elemanı nöronlardır. Yapay nöronlar, aralarında bağ kurarak YSA oluştururlar. Beyinde olduğu gibi YSA'da da yapay nöronların, giriş işaretlerini aldığı, işlediği ve çıktılar ilettiği bölümleri bulunmaktadır. YSA, birbirine bağlı çok sayıda işlem elemanlarından oluşmaktadır. İnsan beyni gibi hatırlama, öğrenme ve genelleme yapabilme yeteneğine sahiptir. Ayrıca deneme yolu ile öğrenme ve genelleme yapabilmektedir.




Şekil 4.1. Sinir sisteminin blok gösterimi

Sinir ağları bilgisayar teknolojisindeki gelişmelerden sonra özellikle mühendislik alanının önemli bir aracı olmuştur. Sinir ağlarının temel karakteristik özellikleri uyarlanabilir ve paralel dağılmış yapısı ile algoritmik olmamalarıdır [101]. YSA'nın işaret işleme, sınıflandırma, parçacık tanıma, fonksiyonel görüntüleme gibi alanlarda oldukça tatmin edici sonuçlar vermektedir [102]. Aynı zamanda işaretin sınıfı hakkında bilgi verebilmesi medikal teşhiste büyük ilgi görmektedir [49,103,104].

4.1.1. Yapay Sinir Ağının Ana Öğeleri

YSA'nın temel işlem elemanı yapay tek bir sinirdir. Biyomedikal sinir hücresinin işleyişinin matematiksel olarak modellenmesi amacı ile gerçekleştirilen yapay sinir hücresi, nöronlarla bilgi işleme sürecini sağlar. İşaretler nöronlar arası bağlantılarla iletilir, nöronlar arasındaki her bir bağlantı bir ağırlık değerine sahiptir ve her bir nöronun net çıkışı, net girdisinin bir aktivasyon fonksiyonundan geçirilmesi ile elde edilir [23]. Şekil 4.2'de yapay bir sinir ağlarının en temel yapısını oluşturan yapay bir sinir hücresi gösterilmiştir. Bu temel yapı, girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardan oluşmaktadır. YSA'nın temelini oluşturan basit nöron yapısında giriş değerleri her biri ağırlık ile gösterilen w değerleri ile çarpılır. Daha sonra bu değerler eşik değeri olarak gösterilen θ_j ile toplanır ve nöron çıkışını oluşturmak için aktivasyon fonksiyonu ile işlendikten sonra çıkış y_i değeri hesaplanır.



Şekil 4.2. Yapay sinir hücresinin yapısı

Girişler, çevreden aldığı bilgiyi sinire getirir, n elemanlı bir sütun vektörüdür. Ağırlıklar, girişlerin, sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen katsayılarıdır. Böylece girişlerin çıktı üzerine etkileri ayarlanabilmektedir. Ağırlık değeri büyük ise o girişin yapay sinire güçlü bağlanması anlamına gelirken, küçük olması zayıf bağlanması anlamına gelmektedir. Toplama fonksiyonunda, her bir ağırlık ait olduğu girişle çarpılır ve eşik değeri ile toplanıp aktivasyon fonksiyonuna gönderilir. Toplama işleminin sonucu, çeşitli aktivasyon fonksiyonlarından geçirilerek, hücrenin bu girdiye karşılık vereceği sonuç elde edilir. YSA yapılarında etkinlik işlemi için farklı aktivasyon fonksiyonları kullanılmaktadır. Yaygın olarak kullanılan aktivasyon fonksiyonları; lineer aktivasyon fonksiyonu, eşik aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonu, hiperbolik tanjant aktivasyonu gibi fonksiyonlardır. Bunlardan lineer aktivasyon fonksiyonu;

$$F(x) = \begin{cases} 0 & x \leq 0 \\ x & 0 < x < 1 \\ 1 & x \geq 1 \end{cases} \quad \text{veya} \quad F(x) = \begin{cases} -1 & x \leq -1 \\ x & -1 < x < 1 \\ 1 & x \geq 1 \end{cases} \quad (4.1)$$

şeklinde tanımlanır. Eşik aktivasyon fonksiyonu;

$$F(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad \text{veya} \quad F(x) = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (4.2)$$


şeklinde tanımlanır. Sigmoid aktivasyon fonksiyonu;

$$F(x) = \frac{1}{1 + e^{(-\alpha_x)}} \quad (4.3)$$

şeklindedir. Hiperbolik tanjant aktivasyon fonksiyonu ise;

$$F(x) = \frac{1 - e^{(-\alpha_x)}}{1 + e^{(-\alpha_x)}} \quad (4.4)$$

şeklinde tanımlanır. Bu fonksiyonların grafiksel gösterimleri Şekil 4.3'te verilmiştir.




Şekil 4.3. Etkinlik fonksiyonları a) lineer aktivasyon fonksiyonu, b) eşik aktivasyon fonksiyonu, c) Sigmoid aktivasyon fonksiyonu d) Hiperbolik tanjant aktivasyon fonksiyonu

Çıkış işlevi ise etkinlik işlevi sonucunun, başka sinirlere veya dış dünyaya iletildiği yerdir. İstenildiği durumda elde dilen çıktı tekrar ağ içerisinde kullanılabilir. Elde edilen çıkış yüzlerce sinir hücresinin girişi olabilmektedir [105].

4.2. Yapay Sinir Ağlarının Yapısı

YSA, yapay sinir hücrelerinin gruplanmasıyla oluşan sisteme verilen isimdir. Bu gruplanma katmanları oluştururken, birbirine bağlı katmanlar da YSA'yı oluştururlar.

YSA, özellikle karmaşık işlevlerin hesaplanması hususunda giriş katmanı, gizli katmanlar ve çıkış katmanı olmak üzere en az üç katmandan oluşur. Sadece giriş ve çıkış katmanının bulunduğu ağlar karmaşık hesaplamaları yerine getirmede yetersiz kalmaktadır. Şekil 4.4'te çok katmanlı bir sinir ağı modeli verilmiştir. Giriş Katmanı, YSA'ya dış çevreden girdilerin geldiği katmandır. Gizli katman, giriş katmanından çıkan bilgilerin işlenip çıkış katmanına iletildiği katmandır. Bazı YSA'larda gizli katman bulunmadığı gibi bazılarında ise kullanılan YSA modeline göre birden fazla seçilebilmektedir [22]. Gizli katmanların ve bu katmanlardaki nöronların sayısının ağı en iyi çalışabileceği sayıda seçilmesi gerekmektedir. Uygun sayıdaki gizli katman ile bu katmanlardaki nöronlar, hesaplama karmaşıklığını ve süresini arttırmasına rağmen YSA'nın karmaşık problemlerin çözümünde etkili olmasını sağlar. Gereğinden fazla sayıda gizli katman seçilmesi durumunda ise aşırı parametre fazlalığı oluşturacağından eğitilemeyen verilerden dolayı yetersiz bir genellemeye neden olur. Dolayısıyla gizli katman sayısını bulan en popüler yöntem deneme yanılma yöntemidir [100]. Çıkış katmanı ise gizli katmanlardan gelen bilgileri işleyerek ağı çıktılarını dış çevreye gönderilir. Geri beslemeli ağlarda bu katmanda üretilen çıktı kullanılarak ağı yeni ağırlık değerleri hesaplanır. YSA'nın doğrusal olmayan yapıları modelleyebilme yeteneği, paralel yapılı oluşu, öğrenme ve genelleme yapabilme yeteneği, uyarlanabilme özelliği ve hata toleransına sahip olması en önemli özelliklerindendir [24,101-102]. YSA, doğrusal olmayan, düzensiz ve gürültülü verileri sınıflandırmada başarıyla kullanılmıştır.



Şekil 4.4. Yapay sinir ağı modeli

4.3. Yapay Sinir Ağlarında Öğrenme

YSA’da öğrenme, beklenen bir işlevi yerine getirecek şekilde sinirler arasındaki ağırlıkların ayarlanması sürecine karşılık gelmektedir. Bu ağırlıkların dinamik olarak değiştirilmesiyle oluşan ağlar eğitilebilir. Öğrenebilen ağlara yeni bir veri girişi söz konusu olduğunda, girişin hangi sınıfa ait olduğu hakkında bilgi verebilir. Ağırlıklar, problemin türüne göre uygulanan öğrenme kuralı ile değiştirilir [24].

4.4. YSA’nın Sınıflandırılması

YSA ile istenilen çıkışa ulaşmak için nöronlar arasındaki bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Kullanılan öğrenme kuralına göre hatayı sıfıra indirecek şekilde ağırlıklar değiştirilir. Sinir ağları statik ve dinamik sinir ağları olmak üzere iki grupta incelenebilir. Statik sinir ağları, herhangi bir geri besleme elemanı ve gecikme içermez. Çıkış doğrudan ileri besleme yoluyla hesaplanır. Dinamik ağlarda ise çıkış mevcut girişin yanı sıra önceki giriş, çıkış ve ağın durumuna bağlıdır [103]. YSA’lar yapılarına, öğrenme algoritmalarına, katman sayılarına ve tiplerine göre sınıflandırılır.

4.4.1. Yapılarına Göre YSA’lar

Yapılarına göre YSA’lar, nöronlar arasındaki bağlantıların şekli göz önüne alınarak ileri beslemeli ve geri beslemeli ağlar olmak üzere iki grupta incelenmektedir. İleri

beslemeli ağlarda, nöronlar bir katmandan sadece kendinden sonraki katmanlarla bağ kurar, aynı katman içerisinde bağlantıları bulunmaz. YSA'ya gelen bilgiler giriş katmanından geçtikten sonra sırasıyla gizli katmandan ve çıkış katmanından işlenerek geçer ve daha sonra dış dünyaya çıkar. Geri beslemeli ağlarda ise bir hücrenin çıktısı sadece kendinden sonra gelen hücrenin katmanına girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir hücreye de girdi olarak bağlanabilir. Böylece girişler hem ileri yönde hem geri yönde aktarılır. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu ağlarda bir andaki çıkış, hem o andaki hem de önceki girişleri yansıtır [104].


4.4.2. Öğrenme Algoritmalarına Göre YSA'lar

Farklı metot ve kurallara bağlı olarak gözlem ve eğitim tabanında ağdaki ağırlıkların değiştirilmesiyle ağ eğitilir. YSA öğrenme algoritmalarına göre denetimli, denetimsiz ve destekleyici öğrenme olmak üzere üç grupta incelenir. Denetimli öğrenmede, ağa verilen giriş değerleri için çıktı değerleri de verilir. İstenilen çıktı ile ağın çıktıları karşılaştırılır, aradaki fark hata olarak ele alınır. Bu hatayı minimuma indirecek şekilde nöronlar arasındaki bağlantıların ağırlıkları en uygun çıkışı elde etmek için düzenlenir. Bu işlem, kabul edilebilir hata seviyesine ulaşınca kadar devam eder. Denetimsiz öğrenmede, girişe verilen örnek aynı zamanda çıkışı da ifade ettiğinden ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında istenen çıkış değerinin bilinmesine gerek yoktur. Destekleyici öğrenmede ise istenilen çıkış olmamakla birlikte ağa bir öğretmen yardım olur. Her iterasyon sonucunda elde ettiği sonucun iyi veya kötü olup olmadığına dair bir bilgi verilerek, ağın kendini yeniden düzenlemesine imkân sağlar. Bu sayede ağ herhangi bir girdi dizisiyle hem öğrenerek hem de sonuç çıkararak işlemeye devam eder [105].


4.4.3. Katman Sayılarına Göre YSA'lar

Katman sayılarına göre geliştirilen YSA'lar tek katmanlı ve çok katmanlı olmak üzere iki grupta incelenmektedir. En basit sinir ağı örneği tek katmanlı ve tek sinirli basit algılayıcıdır. İlk geliştirilen YSH, girdilerin ağırlıklı toplamının eşik değerinden büyük veya küçük olmasına göre çıktı üretmekteydi. Perceptron da denilen bu yapılar Şekil 4.5'te

modellenmiştir. Bu sinir ağlarının birden çok girişi olmakla birlikte tek bir çıkışı vardır. Daha çok nesneleri farklı iki sınıfa ayırmak, aritmetik ve mantıksal işlevleri yapabilmek amacıyla geliştirilmiş olsa da her fonksiyonda olumlu bir sonuç alınamamıştır. Bu amaçla giriş katmanının doğrudan çıkış katmanına bağlandığı tek katmanlı sinir ağlarının yetersiz kaldığı karmaşık problemlerin çözülmesinde çok katmanlı sinir ağlarının etkili olduğu sonucuna varılmıştır. Özellikle katman sayısının belli bir sınıra kadar artırılması ağın öğrenme yeteneğini artırmaktadır. Çok katmanlı algılayıcı (ÇKA) da denilen bu ağ türü Şekil 4.6’da verilmiştir. Geri Yayılım Ağları (GYA) olarak da isimlendirilmektedir. Bu öğrenme yöntemi, YSA’nın bulduğu çıkış ile arzu edilen çıkışlar arasındaki farkı en az indirebilmek için hata değerinin geriye dönük ağırlıklara yayılması şeklinde yapılmaktadır.



Şekil 4.5. Perceptron



Şekil 4.6. Çok katmanlı algılayıcı

4.5. Makine Öğrenmesi (MÖ)

Öğrenme, sözlük anlamı olarak "öğrenim, öğretim veya deneyim yoluyla bilgi-beceri kazanma" ve "davranış eğilimini tecrübe ile modifiye etme" gibi ifadeleri içerirken, MÖ, yapay zekânın bir dalı olup bilinen örneklerden öğrenme yoluyla bilinmeyen örnekleri belirlemeyi amaçlamaktadır [106-113]. Diğer bir deyişle de veri içerisindeki kompleks parçacıkların bulunması ve bunların alt sınıflara ayrılabilmesi işlemidir [60]. Makine öğrenimi fikri, insanoğlunun öğrenme sürecini taklit etmek, diğer bir deyişle tecrübe yoluyla bilgi kazandırmaktır. MÖ algoritmaları, makinelerin kuralları ampirik verilerden genelleştirmesini ve öğrenilen kurallara dayanarak gelecekteki veriler için tahmin yapmasını sağlar [114,115]. MÖ'nde, sınıflandırıcının performansını değerlendirmek amacıyla ya bir test kümesi ya da çapraz doğrulama tekniği kullanılabilir. Bir test kümesi, eğitim setinde kullanılan örneklerden farklı örnekleri içerir. Bu test veri kümesi, eğitim için değil değerlendirme amacıyla kullanılmaktadır. Veri çok fazla değilse sınıflandırıcının performansını geliştirmek için yararlı olabilecek herhangi bir veriyi boşa harcamamak adına çapraz doğrulama yöntemi kullanılabilir. Tüm veriler hem sınıflandırıcıyı eğitmek hem de sınıflandırıcının performansını test etmek için kullanılır. Çok fazla örnek çok iyi performans anlamına gelmemekle birlikte sınıflandırıcı eğitim verisinde çok iyi olmasına rağmen, test kümesinde kötü performans gösterebilmektedir [116].


Var olan verilerin çıkarımlarını matematiksel ve istatistiksel yöntemlerle yapan ve bilinmeyen bir yöntem paradigması olan MÖ, kullanılan verinin yapısına göre farklı algoritma seçeneklerinden oluşmaktadır. Denetimli öğrenme algoritmaları ve denetimsiz öğrenme algoritmaları olmak üzere iki ana başlıkta incelenmektedir. Her algoritmanın kullanıldığı amaca göre avantaj ve dezavantajı mevcuttur [117].

4.5.1. Denetimli Öğrenme Algoritmaları

Denetimli öğrenme, girdi verileri ile bunlara karşılık gelen çıktı verileri arasında bir ilişki genelleştirilmesine imkân sağlar. Aradaki bu ilişki, bir eğitim seti aracılığıyla öğrenilir. Eğitim boyunca, gerçek ve istenen çıkışlar arasındaki hata sistem parametrelerini ayarlamak amacıyla belirli öğrenme kuralına uygun olarak sık sık sisteme geri beslenir. Sistem, hatayı en aza indirmek için kendini uyarlayarak öğrenir. Eğitimden sonra,

öğrenilen ilişkinin performansı, farklı bir test seti ile değerlendirilir. Denetimli öğrenme parçacık tanıma, fonksiyon uydurma, sınıflandırma ve tahmin gibi uygulamalarda kullanılır [118].

DVM, k-NN, geri yayılım sinir ağı ve vektör nicemleme öğrenme denetimli öğrenme algoritmalarına örnek olarak verilebilmektedir. Genel olarak denetimli öğrenme algoritmalarının kullanım blokları Şekil 4.7’de verilmiştir.




Şekil 4.7. Denetimli öğrenme algoritmalarının sıralı işlem blokları

4.5.1.1. Destek Vektör Makinesi (DVM)

DVM, doğrusal olmayan girdi verilerini yüksek boyutlu özellik alanlarına haritalamak suretiyle kabul edilen iki sınıfı doğrusal bir hiper düzlemi ile birbirinden ayırır [118]. DVM, sınıflandırma konusunda, performansının yüksek ve uygulanabilirliği kolay olmasından ve yüksek genelleme yeteneğine sahip olmasından dolayı sıklıkla kullanılan algoritmalarından birisidir [119]. DVM, sınıfları birbirinden uzak bir hiper düzlem ile ayıran doğrusal bir ayırt edici fonksiyon bulunmasını amaçlar [120]. Farklı çekirdek fonksiyonlarıyla örnekler birbirinden ayrılır. DVM daha çok iki sınıflı sınıflandırmaya uygundur [43]. Çok boyutlu verilerde öğrenme ve genelleme yapabilme yeteneği önem taşıdığından, DVM sınıflandırıcıda iki grup veri uygun bir dönüşümle iyi bir genelleme yapabilen hiper düzleme ayrılır. Eğitim verileriyle bulunan hiper düzlemde, test verileri bu sınırın ne tarafında kalıyorsa yeni veriler o gruba dâhil edilirler. DVM için kullanılacak örnek sayısı önemli değildir. Eğitim esnasında kullanılmayan verileri de sorunsuz sınıflandırma yeteneğine sahiptir [121].

Destek vektör makineleri, doğrusal destek vektör makineleri, doğrusal olmayan destek vektör makineleri, çok sınıflı destek vektör makineleri olmak üzere gruplanabilmektedir. Verilerin bir bölümü doğrusal olarak ayrılabilirdiği gibi, bir bölümü de doğrusal olarak ayrılamamaktadır. Dolayısıyla DVM bu tür karmaşık problemlerin çözümünde iyi bir alternatif olmaktadır. Doğrusal destek vektör makineleri, hiper düzlemle

ayrılan sınıfların örnek gruplarına eşit uzaklıkta olmayı amaçlar (Şekil 4.8) ve veriler arasında maksimum sınırın bulunması kolaydır [122]. Doğrusal olmayan veriler arasında bu maksimum sınırın bulunması için ise veriler öncelikle doğrusal olarak ayrılabilirler farklı bir düzleme aktarılmalıdırlar [123,124]. Veri tipinin doğrusal olarak ayrılamadığı durumlarda yanlış bir sınıflandırmayı önlemek için çekirdek fonksiyonlarıyla doğrusal olmayan dönüşümler yapılarak veri setleri doğrusal olarak ayrıştırma yapabilen düzlemlere taşınır ve sınıflandırmanın orada yapılması mümkün olabilmektedir [125]. Bunun için öncelikle veri mevcut boyutundan daha yüksek boyutlu bir uzaya bir çekirdek fonksiyonuyla taşınır. Kullanılan çekirdek ile dönüşümü sağlayan sistem tanımlanmış olur ve yüksek boyutlu uzaya taşınan vektörler doğrusal olarak ayrıştırılabilir hale getirilir. Optimal ayrıştırıcı, farklı sınıflara uzaklığı en çok olan doğrusaldır. Destek vektörleri olarak adlandırılan yüzeye en yakın vektörler ayrıştırıcı düzlemi belirlerler [124]. İki sınıftan fazla sınıfın olduğu veri setlerinde ise bire karşı bir (problemin ikili gruplara indirgenmesi), bire karşı hepsi yöntemleri kullanılır. DVM, YSA'ya kıyasla daha hızlı, daha az hafıza gerektiren ve daha iyi sınıflandırma yüzdesine sahiptir [102].



Şekil 4.8. Destek vektörlerinin ve optimal ayırıcı düzlemin gösterimi

4.5.1.1.1. Doğrusal Olarak Ayrılabilen Veri Kümeleri İçin DVM

Doğrusal olarak ayrılabilen veri kümelerinde kastedilen nokta, elde edilmeye çalışılan ayırıcı düzlemin sınıflandırma probleminde eğitim verisini hatasız bir şekilde ayırabilen doğrusal bir fonksiyon olmasıdır.

$$(x_1, y_1), \dots, (x_n, y_n), x \in R^d, y \in \{+1, -1\} \quad (4.18)$$

n tane örnekten oluşan bir eğitim verisi, d tane özelliğe sahip örneklerden oluşmaktadır. Sınıfları belirten y sadece iki değer olabilir ($y \in \{1, -1\}$). d boyutlu bu uzayda bütün hiper düzlemler bir vektör ve bir sabit sayı ile belirtilir. Bu ifadeyi aşağıdaki gibi belirtebiliriz.

$$d(x) = (w \times x) + w_0 \quad (4.19)$$

w vektörü hiper düzleme dik bir vektördür. Bu formülü DVM'nin sınıflandırma fonksiyonu olarak kullanılırsa;

$$f(x) = \text{sign}(w \cdot x + w_0) \quad (4.20)$$

Eğitim verileri (4.20) denklemindeki ayırıcı fonksiyonuyla birbirlerinden ayrılabilirler.


Veri setinde bulunan herhangi örnek olan x_i formülde yerine koyulursa, ayırma düzlemi n sayıda veri örneğinin ayrılmasını tanımlayan şu koşulları sağlar [126];

$$(w \times x_i) + w_0 \geq +1 \quad \text{eğer } y_i = +1 \quad (4.21)$$

$$(w \times x_i) + w_0 \leq -1 \quad \text{eğer } y_i = -1, \quad i = 1, \dots, n \quad (4.22)$$

$$y_i(w \times x_i + w_0) \geq +1 \quad (4.23)$$

ifadesi veri setindeki her örnek için doğru olur. Eşitsizliklerini sağlayan hiper düzlemin iki tarafındaki en yakın örneklere olan dik uzaklıkları toplamı sınır olup bu sınırı maksimum yapan hiperdüzlem optimum ayırıcı hiperdüzlem olarak kabul edilir (Şekil 4.8). Optimum ayırıcı hiperdüzlemi bulmak için uygun w ve w_0 değerleri hesaplanır [124].



Şekil 4.9. Doğrusal ayrılabilen optimum ayırıcı hiperdüzlem

Şekil 4.9’da C_1 sınıfını ayıran A_1 hiper düzlemini oluşturan eşitsizlik (4.21) eşitsizliği ile, C_2 sınıfını ayıran A_2 hiper düzlemini oluşturan eşitsizlik ise (4.22) eşitsizliği ile tanımlanmıştır. Bu durumda A_1 hiper düzleminin orijine olan uzaklığı;

$$\frac{|1-b|}{\|w\|} \quad (4.24)$$

A_2 hiper düzleminin orijine olan uzaklığı;

$$\frac{|-1-b|}{\|w\|} \quad (4.25)$$

Bu iki hiper düzlemin optimal hiper düzleme uzaklıkları ise

$$\frac{1}{\|w\|} \quad (4.26)$$

yani iki örnek kümesi arasındaki uzaklık

$$\frac{2}{\|w\|} \quad (4.27)$$

olacaktır. Bu iki hiper düzlem arasındaki maksimum uzaklık ise en küçük $\|w\|$ değerinin tespitiyle bulunabilir. DVM yöntemiyle yapılmaya çalışılan bu iki hiper düzlemin arasındaki uzaklığın (sınırın) maksimum olmasını sağlamaktır. Şekil 4.9’da görüldüğü gibi A_1 ve A_2 hiper düzlemleri arasında eğitim verilerine ait hiçbir örnek bulunmamaktadır [127].

Geometrik olarak x_i noktasının hiper düzleme olan uzaklığı hesaplanırken w normalize edilmelidir. Böylece x_i noktasının hiper düzleme olan uzaklığı;

$$d((w, w_0), x_i) = \frac{y_i(w \times x_i + w_0)}{\|w\|} \geq \frac{1}{\|w\|} \quad (4.28)$$

Bu noktanın hiper düzleme olan uzaklığını maksimize edilmek istendiği için $\|w\|$ ifadesi minimize edilmesi gerekmektedir. Bu ifadenin minimize edilmesinde kullanılan Lagrange çarpanlarıdır.

$$W(\alpha) = -\sum_{i=1}^N \alpha_i + \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j (x_i^T * x_j) \quad (4.29)$$

Denklemine göre bulunan alfa değerlerinden sıfırdan büyük olanlar destek vektörler olarak tanımlanmıştır. α_i değeri sıfırdan büyük ise bu değerin ait olduğu x_i vektörü destek vektörü

olarak tanımlanır. Destek vektörlerinin bulunması ile lineer olarak ayrılan veriler için maximum marjine sahip hiper düzlem bulunmuş olur. Eğitim verileriyle bulunan hiper düzlemde, test verileri bu sınırın ne tarafında kalıyorsa yeni veriler o gruba dâhil edilirler. DVM için kullanılacak örnek sayısı önemli değildir.

4.5.1.1.2. Doğrusal Olarak Ayrılamayan Veri Kümeleri için DVM

DVM’de, ayırım bir hiper düzlemle iki grubu ayıran bir doğru ve bu doğruya bağlı bir tolerans ile yapılır. Gerçek dünya verileri için doğrusal fonksiyonlar çok basit olup, doğrusal yolla ayırım yapılması mümkün olmayan veri örnekleri yanlış sınıflandırılmayla sonuçlandırılabilirler (Şekil 4.10). Öte yandan da, çok karmaşık fonksiyonların kullanılmasından kaçınılmalıdır. Kontrol edilebilir karmaşıklıkla doğrusal modelleri ve doğrusal olmayan karar işlevlerini kullanılarak, gerçek dünya verileri için uygun bir çözüm olacaktır. Çekirdek metotları, çok genel veri türleri üzerinde çalışabilen ve çok genel ilişkileri tespit edebilen, bir model analizi algoritması sınıfıdır. Çekirdek yöntemlerinin temel fikri, doğrudan giriş düzlemine doğrusal bir algoritma uygulamak yerine, öncelikle girdi düzlemi üzerinde doğrusal olmayan bir haritalama kullanmak ve daha sonra bu yeni düzleme doğrusal bir algoritma uygulamaktır. Bunu engellemek ve doğru çözüme ulaşabilmek için eğitim verileri, çekirdek fonksiyonları kullanılarak daha yüksek boyutlu ve doğrusal olarak ayrılacakları bir özellik düzlemine aktarılırlar (Şekil 4.11). Eğitim aşaması, bu düzlemdeki verilerin K çekirdek fonksiyonu olmak üzere

$$K=\varphi(x_i) \cdot \varphi(x_j) \quad (4.30)$$


iç çarpımlarına bağlı olacaktır. Karar fonksiyonu ise

$$f(x) = \sum_{i=1}^{ls} \alpha_i y_i \varphi(x_i) \varphi(x) + b = \sum_{i=1}^{ls} \alpha_i y_i K(x_i, x) + b \quad (4.31)$$


olacaktır. Bu fonksiyonda α_i değerleri pozitif Lagrange çarpanlarıdır. ls , destek vektörlerinin sayısı, x_i de destek vektörleridir [108].

Doğrusal olarak ayrılamayan verileri ayıracak en uygun hiper düzlemi bulmak için Doğrusal, Polinom, Sigmoid Kernel, Gauss tabanlı Kernel ve Anova Radyal Basis Kernel fonksiyonları kullanılır. Bu tez çalışmasında LabVIEW’de bulunan Doğrusal, Polinom ve Gauss tabanlı çekirdek fonksiyonları kullanılmıştır. Tablo 4.1.’de tez çalışmasında kullanılan çekirdek fonksiyonlarının matematiksel formülleri verilmiştir. Belli boyutlardaki

bir düzlemde yer alan verilerin koordinatlarının doğrusal olmayan kombinasyonlarını kullanarak daha yüksek boyutlu başka bir düzleme taşımak yerine çekirdek fonksiyonları, bu doğrusal olmayan dönüşümü yapmak ve yeni uzaydaki koordinatları hesaplamak zorunda kalmadan yeni düzlemde bazı işlemlerin sonuçlarını hesaplayabilme imkânı tanımaktadır. Bir veri kümesindeki her örnek, örneği temsil eden değerlerin sayısı kadar boyutu olan bir uzayda bir noktadır. Bu noktaları ifade etmek için kullandığımız vektörlerin her bir bileşeni, noktaların uzaydaki bir koordinatıdır. Veri, yeni düzleme taşınırken dönüşümden önceki vektörler cinsinden ifade edilebilir. Bu da dolayısıyla çok boyutlu yeni bir düzlemin yeni koordinatlarını, bilinen noktalarla belirlemek anlamına gelmektedir.



Şekil 4.10. Doğrusal olmayan DVM



Şekil 4.11. Giriş verisinin özellik düzlemine aktarımı

Tablo 4.1. Çekirdek Fonksiyonları

Çekirdek Fonksiyonu	Formülü	Açıklama
Doğrusal Çekirdek	$K(x,y)=x.y$	-
Polinom Çekirdek	$K(x,y)=(x.y+1)^d$	d, polinom derecesi
Gauss Çekirdek	$K(x,y)=e^{-\gamma\ x-y\ ^2}$	γ , Gauss çekirdeğinin boyutu

Sınıf sayısı ikiden fazla olduğu durumlarda Lagrange fonksiyonunun kullanımı ile sınıf sayısının artmasına paralel olarak hatalar arttığından dolayı için bu yöntem fazla tercih edilmemektedir. Diğer bir yaklaşım ise, bire karşı bir ve bire karşı hepsi yöntemleri olup sınıf sayısına göre ikili sınıflandırmalar yapmaktadır. Bire karşı bir yönteminde her örnek kümesi diğer örnek kümeleriyle ayrı ayrı eğitilir. Yani n sınıf varsa $n(n-1)/2$ tane eğitim işlemi yapılır. Daha sonra eğitim işlemlerinin sonucunda bulunan destek vektörlerle test aşamasında gelen örnek kıyaslanır ve sınıfı bulunur. Bire karşı hepsi yönteminde ise her örnek kümesinin eğitimi, diğer bütün örneklerin aynı kümeye ait olduğu varsayımı ile yapılır. Yani n farklı sınıf var ise n tane eğitim işlemi yapılır. Test aşamasında da örneğin ait olduğu sınıf bu eğitim verilerinde elde edilen destek vektörler ile kıyaslanmasıyla tespit edilir [124].

DVM'nin avantaj ve dezavantajları şu şekilde listelenmiştir.

DVM'nin Avantajları

- Sınıflandırmada oldukça etkili ve en çok kullanılan araçtır.
- Çok büyük veri setlerinde de başarılı sonuçlar vermektedir.
- Çekirdek yöntemleriyle doğrusal olmayan verilerin sınıflandırılmasında da başarılı sonuçlar vermektedir.

DVM'nin Dezavantajları

- Hızı düşürmemek için az sayıda test verisinin kullanılması
- Çekirdek fonksiyonunun seçimi,
- İkiden fazla sınıflandırıcılar için optimal tasarım çalışmalarının netleşmemesi

4.5.1.2. En Yakın Komşu Algoritması (k-NN)

En yakın komşu algoritması (k-NN), eğitim veri setini kullanarak doğrudan tahminlerde bulunur [128]. m boyutlu bir uzaydaki veri kümesinde, bir test örneğinin sınıfının belirlenmesi için o test örneğinin verilen veri kümesindeki en yakın k tane komşusuna bakılması k-NN algoritmasının temelini oluşturur. Yeni sınıflandırılacak bir örnek için k tane sayıda örneğe bakmamız istenilirse önceden sınıflandırılmış elemanlardan en yakın k tanesi alınır. Bu uzaklık mesafesi, Öklit, Manhattan, Chebyshev, Minkowski v.b. uzaklık formülleri hesaplanmakta olup reel değerli giriş değişkenleri için genellikle öklid mesafesi kullanılmaktadır. p ve q veri noktaları olmak üzere d(p,q) iki nokta arasındaki uzaklığı ifade etmektedir [109]. Buna göre;

$$d_{\text{öklid}}(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (4.32)$$

$$d_{\text{Manhattan}}(p, q) = \sum_{i=1}^n |p_i - q_i| \quad (4.33)$$

$$d_{\text{Chebyshev}}(p, q) = \max_i (|p_i - q_i|) \quad (4.34)$$

$$d_{\text{Minkowski}}(p, q) = \sqrt[m]{\sum_{i=1}^n |p_i - q_i|^m} \quad (4.35)$$

olarak ifade edilir [56]. Test verilerinin tüm öğrenme örneklerine olan uzaklığı hesaplanır, minimum uzaklığa göre sıralanır, yeni örneğin ait olduğu sınıf değerleri bulunur ve baskın olan sınıf seçilir [44,107]. k-NN herhangi bir model öğrenmemekle birlikte bir girdi örneği ile her eğitim örneği arasındaki benzerliği hesaplayarak tahmin yapar. Kullanılacak veri tipine göre de farklı mesafe yöntemlerini kullanması da önem taşımaktadır [128].

4.5.2. Denetimsiz Öğrenme Algoritmaları

Denetimsiz öğrenme algoritmaları, önceden sınıfı belli olmayan verilerin saklı yapılarını açığa çıkarma problemleriyle ilgilenir. Veri etiketsiz olduğundan dolayı algoritmada eğitime geri besleme sağlayacak hata işareti bulunmamaktadır. Geri beslemenin olmaması da denetimsiz öğrenmeyi denetimli öğrenmeden ayırmaktadır. Kümeleme, denetimsiz öğrenmede önemli ve temel bir yaklaşımdır. Kümeleme ile bir sınıfın üyelerinin benzer olanlarını bir grupta farklı olanları da bir grupta olacak şekilde değerlendirilir. Bu sebeple kümeleme, verideki farklı parçacıkların saptanmasında, tıpta gen dizilimi ve DNA analizinde oldukça kullanışlıdır. Kümelemede küme içi benzerlik en

yüksek, kümeler arası benzerlik ise en düşük olduğu sürece kümelemenin doğruluğundan söz edilebilir.

k-means, k-medians, k-medoids, Fuzzy C-means, spektral kümeleme ve self-organizing map (SOM) fonksiyonları denetimsiz öğrenme algoritmalarına örnek olarak verilebilmektedir. Genel olarak denetimsiz öğrenme algoritmalarının kullanım blokları Şekil 4.12’de verilmiştir.



Şekil 4.12. Denetimsiz öğrenme algoritmalarının sıralı işlem blokları

4.5.3. Boyut Azaltma Algoritmaları

MÖ’nün diğer bir önemli başlığı da boyut azaltma problemidir. Özellik seçme için boyut azaltma yöntemlerinden de yararlanılabilir. Boyut azaltma, eldeki verinin özelliklerini saklamakla birlikte verinin gereksiz olan niteliklerinin belirlenerek veriden atılmasına yönelik bir uygulamadır [110,128-131]. Azaltılmış düzlemdeki veri setinin özelliklerinin ve önemli karakteristiklerinin korunması beklenir. Kümeleme gibi bazı veri analizlerinde azaltılmış düzlem, orijinal düzleme göre daha kolay ve daha iyi sonuçlar vermektedir. Veri sıkıştırma, veri görselleştirme, gibi pratik uygulamaları mevcut olup bu tez çalışmasında TBA, KTBA ve DAA üzerine çalışılmıştır. Genel olarak boyut azaltma algoritmalarının kullanım blokları Şekil 4.13’te verilmiştir.



Şekil 4.13. Boyut azaltma algoritmalarının sıralı işlem blokları

Verilerin sınıflandırılması konusunda birçok yöntem olmakla birlikte TBA ve DAA en çok kullanılan yöntemlerdendir. Boyut azaltma, hesap yükünü azaltmakla birlikte aynı zamanda parametre tahmininde hatayı en aza indirgeyerek aşırı uyumsuzluğu önlemek adına faydalı olmaktadır. DAA ve TBA arasındaki en önemli fark TBA’nın daha çok özellik sınıflandırması ve DAA’nın da veri sınıflandırması yapmasıdır. TBA’da, orijinal

veri kümelerinin şekli ve yeri, farklı bir alana dönüştürüldüğünde değişir. DAA konumu değiştirmez, ancak yalnızca daha fazla sınıf ayrılabilirliği sağlamaya ve verilen sınıflar arasında bir karar bölgesi çizmeye çalışır. Bu yöntem aynı zamanda özellik verisinin dağılımını daha iyi anlaşılmasına yardımcı olur [132].

4.5.3.1. Temel Bileşenler Analizi (TBA)

İstatistiksel bir yöntem olan Temel Bileşen Analizi, Tekli Değer Ayrışım Analizi kökenli olup ilk olarak Pearson (1931) ve Hotelling tarafından önerilmiştir. Temel bileşenler analizi, aralarında korelasyon bulunan p sayıda değişkenlerden oluşan veri setini, aralarında korelasyon bulunmayan daha az n sayıda ve orijinal değişkenlerin doğrusal bileşenleri olan yeni değişkenlerle ifade etme yöntemine temel bileşenler analizi denir [28, 133]. TBA, bağımlılık yapısını yok etme, boyut indirgeme amacıyla kullanılır. Veriyi değişkenliğin en yüksek olduğu tarafa doğru yönlendirmeye amaçlayan doğrusal bir boyut azaltma metodudur [134]. Tanıma, sınıflandırma, boyut indirgeme ve yorumlanmasını sağlayan çok değişkenli bir istatistik yöntemidir. Bu yaklaşım veri içindeki en güçlü örüntüyü bulmaya çalışır. Bir veri setinde yer alan p değişken arasında önemli sayılabilecek kovaryans ya da korelasyonlar mevcutsa bu veri setini analizlerde doğrudan kullanmak yerine, bu setin daha az sayıdaki doğrusal bileşenlerinden oluşan bir seti oluşturmak gerek işlem yükü, program hızı bakımından daha etkilidir [133].

Çoğunlukla verinin çeşitliliği, tüm boyut takımından seçilen küçük bir boyut setiyle yakalanabilir. Bu durum asıl veriyi daha az veriyle ifade edebilecek şekilde veriden özellik çıkarma işlemine karşılık gelmektedir [135-137]. Verideki gürültüler, örüntülerden güçsüz olduklarından, boyut küçültülmesiyle gürültüler temizlenebilir. TBA, uygulandıktan sonra elde edilen gerçek boyut temel bileşenler adını alır. Bu bileşenlerden 1. bileşen toplam değişkenliği en çok açıklayan değişken, 2. bileşen ise kalan değişikliği açıklayan değişken olarak bilinir. Veri setindeki örüntünün tanımlanmasında, veri setindeki benzer-farklı desenlerin tanımlanmasında kullanılır. TBA verinin sıkıştırılmasına veri kaybı yaşanmadan boyut azaltarak imkân verir. En az ortalama karesel hata oranı temelinde fazlalıkları azaltmak için kullanılan, veriye ait koordinatların doğrusal dönüşümüne imkân sağlayan bir metottur [42].

TBA, orijinal veriler için dik olan en büyük varyans yönleri bulup orijinal verileri bu koordinat sisteminde gösterir. Uygun koordinat sisteminin bulunması için 1. eksen

olarak verilerin değişiminin en büyük olduğu yön seçilir. 2. eksen olarak 1. eksene dik olan verilerin en büyük değişiminde olan yön seçilir. 3. eksen olarak da 1. ve 2. eksene dik olan ve kalan verilerin en büyük değişiminde olan yön seçilir. Bu şekilde seçilmiş dikey olan en büyük değişim yönlerine temel bileşenler denir. TBA yönleri, verilerin değişimi ile ilgili en büyük katkıda olan yönü ilk önce belirtmekte, daha sonra da az katkıda olan yönleri açıklamaktadır. Yani birinci temel bileşen en çok, diğer bileşenler ise gittikçe azalan miktarlarda toplam varyansa katkıda bulunurlar. Bu nedenle, az sayıda bileşenle toplam varyansın büyük bir kısmı açıklanabilmektedir.

Verilerin orijinal n-boyutlu uzaydan p-boyutlu altuzayına p ana vektörü tarafından dönüştürülmesi, ortalama kareli hata anlamında en iyisidir. Bu sebeple n boyutlu X matrisinin boyutu azaltılarak minimum hatayla p boyutlu P matrisine dönüşür.

Temel bileşenlerin hesaplanması için,

$$E^T(XX^T)E = A \quad (4.36)$$

Öz değer denklemi çözülür. Burada X eğitim örneklerini içeren matris, E öz değer matrisi A özdeğerlere ait köşegen matrisidir.

$$P_P = E_P^T X \quad (4.37)$$

TBA'nın istenen sonucu 'iyi' verileri temsil eden verileri, daha küçük bir alt düzlemle yansıtmaktır. Hesap yükünün ve parametre tahmin hatasının azaltılmasıyla elde edilen alt düzlem, en iyi veri kümesi olarak isimlendirilir. TBA'da sınıf etiketleri olmadan tüm veri kümesi farklı bir alt uzay üzerine yansıtılır ve verilerin en fazla yayıldığı yerde en fazla varyansa sahip eksenler bulunur.

TBA, adım adım incelenmesi durumunda sırasıyla sınıf etiketlerinin göz ardı edildiği d boyutlu örnek veri seti alınır bu veri setinin ortalama vektörü hesaplanır, tüm veri setinin dağılım matrisi hesaplanır, öz vektör ve ilgili öz değerleri hesaplanır. Öz değerleri azaltarak öz vektörler sıralanır, en büyük öz değerli k öz vektör seçilir ve dxk boyutlu W matrisi oluşturulur. Bu matris de yeni alt düzleme dönüştürülmek için kullanılır.

$$Y = W^T \times X \quad (4.38)$$

X: d×1 boyutlu bir örneği temsil eder.


Y: yeni alt düzleme dönüştürülmüş k×1 boyutlu örnek

Yukarıda bahsedilen adımların sırasıyla gerçeklemesi ve TBA'nın anlaşılabilirliği için kullanılan veri noktaları Tablo 4.2'de verilmiştir. Ayrıca Şekil 4.14'te de kullanılan veri noktalarının MATLAB Programı üzerinde çizilmiş gösterimi sunulmuştur.


Tablo 4.2. Veri noktaları

	P_1	P_2	P_3	P_4	P_5	P_6	P_7	P_8	P_9
x	0.4	1.5	1.6	2.2	2.5	3.5	2.9	4.8	5
y	1	1.8	1.9	3.3	2.9	4	3.6	5.6	5.8


TBA'nın uygulamalarda düzgün çalışabilmesi için, ortalaması sıfır olan yeni bir veri kümesi oluşturmak gerekir. Dolayısıyla verinin ortalaması orijinal veride her boyuta ait noktadan o boyutun ortalamasının çıkarılması gerektirir. x boyutunun ortalaması $\bar{x}$, y boyutunun ortalaması $\bar{y}$ kabul edilirse, burada $\bar{x}=2.7$ ve $\bar{y}=3.34$ bulunur. Şekil 4.15'te ortalaması çıkarılmış veri ve Şekil 4.16'da orijinal veri ile ortalaması çıkarılmış veri birlikte verilmiştir.



Şekil 4.14. Gerçek veri seti



Şekil 4.15. Ortalamasından çıkarılmış veri seti



Şekil 4.16. Orijinal ve farkı alınmış veri seti

n adet değişkenlerden oluşan bir vektörde $n \times n$ büyüklüğünde her değişkenin diğer bütün değişkenlerle ilişkisini veren matris kovaryans matrisi adını alır. Kovaryans iki değişkenin birlikte ne kadar değiştiklerinin ölçüsüdür. Standart sapma ve varyans tek boyutlu veriler için kullanılırken, kovaryans iki boyut arasında ölçüm yapmak için kullanılır. Kovaryans değeri pozitif ise her iki değişkenin birlikte arttığı, negatif ise değişkenin biri artarken diğerinin azaldığı, sıfır ise de değişkenlerin birbirinden bağımsız olduğu yorumu yapılır. Bu uygulama için elde edilen kovaryans matrisi; $C = \begin{bmatrix} 2.27 & 2.4 \\ 2.4 & 2.6103 \end{bmatrix}$ şeklinde olup simetriktir.


Kovaryans hesabından sonra yapılması gereken adım veriyi öz vektörlere ve öz değerlere ayıştırmaktır. Öz vektörler ve öz değerler çiftler halinde bulunur: her öz vektör, bir öz değer değerine sahiptir. Bir öz vektör bir yöndür, bir öz değer ise o yönde verinin ne kadar varyansa sahip olduğunu söyleyen bir sayıdır yani verilerin yayılma oranını gösteren

bir sayıdır. Bu nedenle, en yüksek öz değer değerine sahip olan öz vektör, ana bileşendir. Kovaryansı hesaplanmış verilerin öz vektör ve öz değerleri;

$$\text{özvektör} = \begin{bmatrix} -0.7317 & 0.6816 \\ 0.6816 & 0.7317 \end{bmatrix}$$

$$\text{özdeğer} = \begin{bmatrix} 0.0341 & 0 \\ 0 & 4.8462 \end{bmatrix}$$

Öz vektörlerin, veri üzerinde önem taşımaktadır. Şekil 4.17’de mavi ve yeşil çizgiler öz vektörleri ifade eder. Kovaryans matrisinin köşegen olmayan elemanlarının pozitif olması, yani x ve y noktalarının birlikte artması gerçeği elde ettiğimiz şekilde de görülmektedir. Öz vektörler birbirlerine diktir. Öz vektörlerden de açıkça görüleceği üzere, yeşil ile çizilmiş öz vektör veri noktaları arasında uzanmaktadır. Bu durum da gösteriyor ki, veri noktalarımız bu öz vektör doğrusu üzerinde birbirleriyle ilişkilidir. Büyük öz değere ait öz vektör, veri kümemizin temel bileşenidir. Verilen örnekte, veri noktaları arasında uzanan öz vektör temel bileşen ve en büyük ilişkiyi sağlayandır. Mavi ile çizilmiş olan ikinci öz vektör ise, daha az öneme sahip olan diğer ilişkiyi vermektedir. Dolayısıyla, kovaryans matrisinin öz değer ve öz vektörlerini bulmak, veriyi karakterize eden doğruların elde edilmesini sağlar. Sonraki adımlar ise, verinin dönüştürülmesi ve elde edilen doğrularla ifade edilmesini sağlar.



Şekil 4.17. Normalize edilmiş veri ve öz vektörler

Elde edilen öz değerler ve ilgili öz vektörler, büyükten küçüğe doğru sıralanır ve bazı bileşenler dikkate alınmayabilir. Bu durumda oluşan yeni veri kümesinin boyutu

öncekine göre daha küçük olacak, dolayısıyla veride bazı bilgi kayıpları yaşanabilmektedir. Öz değerin büyüklüğüne göre bilgi kaybı değişiklik göstermektedir.

Yeni türetilcek veri için de dikkate alınan öz vektörlerin sütunlar halinde sıralanarak nitelik vektörleri matrisi oluşturulur. Mevcut iki öz vektörlerimizden, ilki dikkate alınmadığı durumda, tek sütunlu nitelik vektörü elde edilir.

$$\text{özvektör} = \begin{bmatrix} -0.7317 & 0.6816 \\ 0.6816 & 0.7317 \end{bmatrix}$$

$$\text{nitelik vektörü} = \begin{bmatrix} 0.6816 \\ 0.7317 \end{bmatrix} \text{ olur.}$$

Yeni türetilen veri için nitelik vektörünün transpozu alınır ve ortalama çıkarılmış orijinal veri setin transpozu ile çarpılır. Elde edilen sonuç verisi artık x ve y eksenlerine değil, kovaryans matrisinden elde edilen öz vektörlere bağlı olarak ifade edilir. Eğer bazı öz vektörler dikkate alınmazsa, bu durumda ise sonuç verisi, elde tutulan öz vektörlere bağlı olarak gösterilir.

Yeni veri=Nitelik vektörü'*ortalama çıkarılmış orijinal veri seti'

Mevcut örnek için her iki temel bileşen kullanılarak elde edilen sonuç verisi Tablo 4.3'te ve çizimi ise Şekil 4.18'de verilmiştir. Elde edilen öz değerler ise Tablo 4.4'te verilmiştir.


Tablo 4.3. Sonuç verisi

Sonuç verisi	x	-3.1368	-1.9480	-1.8067	-0.3733	-0.4615	1.0250	0.3233	3.0818	3.2963
	y	0.2211	-0.1747	-0.1798	0.3355	-0.1566	-0.1385	0.0279	9.6371e-04	0.0641

Tablo 4.4. Varyans


Öz değer	0.0341	0
	0	4.8461

İki temel bileşen yani öz vektörler kullanıldığından dolayı, sonuç verisinde modelle ilgili bilgi kaybı yaşanmamıştır. Sonuç verisinin yeni eksenleri ise, temel bileşenlerdir. Veri sıkıştırma yaygın olarak kullanılan TBA ile verinin tekrar elde edilebilmesi için tüm temel bileşenlerinin kullanılmasını gerektirir.



Şekil 4.18. Öz vektörler kullanılarak türetilmiş veri seti

Orijinal veri setine ve TBA dönüşümü sonrası elde edilen veri setine ait veri yığınları Şekil 4.19’da gösterilmiştir. TBA sonra verilerin genliğinde değişim gözlenmiştir.



Şekil 4.19. Gerçek ve TBA sonrası elde edilen veri yığını

4.5.3.2. Doğrusal Ayrıştırma Analizi (Linear Discriminant Analysis)

Doğrusal Ayrıştırma Analizi (DAA), iyi bir sınıf ayrılabilirliği oluşturabilen daha düşük boyutlu bir veri kümesi oluşturmayı sağlayan bir boyut azaltma tekniğidir. DAA, sınıf içi frekansların düzensiz ve performanslarının rastgele oluşturulmuş test verileri

üzerinde incelendiğinde olumlu sonuçlar veren bir metottur. Bu yöntem, belirli bir veri kümesindeki sınıflar arası varyansın sınıflar içi varyansa oranını maksimize eder ve böylece maksimum ayrılabilirliği garanti eder. Veri içerisinde bulunan farklı sınıflara ait grupların doğrusal ayrılabilirliğini maksimize etmeyi sağlayan bir yöntemdir. Veri setindeki bir verinin hangi değişken grubuna gireceğini bulmak için yapılır, yani değişkenleri özelliklerine göre birbirinden ayırır [132].

DAA, adım adım incelenmesi durumunda sırasıyla veri setleri hazırlanır ve formülize edilir,

$$\text{set1} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ \vdots & \vdots \\ a_{m1} & a_{m2} \end{bmatrix} \quad \text{set2} = \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \\ \vdots & \vdots \\ b_{m1} & b_{m2} \end{bmatrix} \quad (4.39)$$

Eşitlik 4.35’deki gibi verilen farklı sınıfları ifade eden her bir veri setinin ortalaması ayrıca tüm veri setinin ortalaması hesaplanır.

$$\mu_3 = p_1 \times \mu_1 + p_2 \times \mu_2 \quad (4.40)$$

Burada μ_1 ve μ_2 veri setlerinin ortalamaları, p_1 ve p_2 sınıfların olası ihtimallerini, μ_3 ise tüm veri setinin ortalamasını ifade etmektedir.

DAA’da sınıf ayrılabilirliğini formülize etmek için sınıflar arası ve sınıf içi dağılım matrisleri hesaplanır. Dağılım, sınıfların her birinin kovaryansını belirtir ve (4.41)’deki eşitlik ile hesaplanır.

$$S_W = \sum_j p_j \times (cov_j) \quad (4.41)$$

İki sınıflı problemlerde bütün kovaryans matrisleri simetriktir. Dolayısıyla kovaryans matrisi,

$$cov_j = (x_j - \mu_j)(x_j - \mu_j)^T \quad (4.42)$$

eşitliğiyle hesaplanır.

Sınıflar arası dağılım ise

$$S_b = \sum_j (\mu_j - \mu_3) \times ((\mu_j - \mu_3))^T \quad (4.43)$$

S_b , her sınıfın ortalama vektörleri olduğu veri kümesinin kovaryansı olarak düşünülebilir. Sınıfa bağlı dönüşümlerde optimizasyon kriteri sınıflar arası dağılımın sınıf içi dağılıma oranı ile ifade edilir. Bu kriteri en üst düzeye getirerek elde edilen çözüm, dönüştürülmüş alanın eksenlerini tanımlar. L sınıflı, sınıfa bağlı bir DAA'da her bir sınıf için L ayrı optimizasyon kriteri gereklidir. Sınıfa bağlı durumda optimizasyon kriteri,

$$kriter_j = inv(cov_j) \times S_b \quad (4.44)$$

Sınıfa bağlı olmadığı durumda ise optimizasyon kriteri,

$$kriter_j = inv(S_W) \times S_b \quad (4.45)$$

ile bulunur. Tanımı gereği, bir dönüşümün bir öz vektörü, dönüşümün uygulandığı vektör uzayının bir alt uzayını temsil eder. Öz değerleri sıfır olmayan bu öz vektörler dizisi tümüyle doğrusal olarak bağımsızdır ve dönüşüm altında değişmezdir. Böylece, herhangi bir vektör uzayı, öz vektörlerin doğrusal kombinasyonları açısından temsil edilebilir. Özellikler arasındaki doğrusal bağımlılık, sıfır öz değeri ile gösterilir. Yeterli seviyede bir özellik kümesini elde etmek için sıfır olmayan öz değerlere karşılık gelen tüm öz vektörler dikkate alınır ve sıfır öz değerlerine karşılık gelen vektörler ihmal edilir [132]. Dağılım matrisleri için elde edilen öz vektörlere karşılık gelen öz değerleri hesaplanır, öz değerleri azaltarak öz vektörler sıralanır, en büyük öz değerli k öz vektör seçilir ve dxk boyutlu matris oluşturulur. Bu matris de yeni alt düzleme dönüştürülmek için kullanılır [132].

$$Y_{nxk} = X_{nxd} \times W_{dxk} \quad (4.46)$$

Y: dönüştürülmüş nxk boyutlu matris


X: nxd boyutlu örnek matrisi

W: dxk boyutlu öz vektör matrisi

Yukarıda bahsedilen adımların sırasıyla gerçekleştirilmesi ve DAA'nın anlaşılabilirliği açısından kullanılan veri noktaları, her bir verinin boyutu, her bir sınıfa ait verilerin ortalamaları ile verinin genel ortalaması Tablo 4.5'te verilmiştir. Ayrıca Şekil 4.19'da da kullanılan veri noktalarının MATLAB programı üzerinde çizilmiş gösterimi sunulmuştur.

Tablo 4.5. Veri kümelerinin ortalamaları

Veri					
Veri_1			Veri_2		
1	1		1	2	
2	1		2	3	
3	2		3	3.5	
4	2		4	3	
5	2.5		4	4	
5.5	2		-	-	
Boyut					
Veri_1			Veri_2		
6			5		
Ortalama					
Veri_1		Veri_2		Veri	
3.4167	1.75	2.8	3.1	3.1083	2.4250



Şekil 4.19. Gerçek veri seti

Her sınıfın ortalama vektörlerinin olduğu veri kümesinin kovaryansı;

$$S_b = \text{Kovaryans} = \begin{bmatrix} 1.0458 & -2.2894 \\ -2.2894 & 5.0119 \end{bmatrix}$$

ile bulunur, kovaryans matrisi sınıflar arası dağılımı ifade eder.

Sınıflara bağlı tip DAA'da her bir sınıf için ayrı bir optimizasyon kriteri gerekir. Bu örnekteki optimizasyon kriteri;

$$\text{Kriter} = \begin{bmatrix} 0.7314 & -1.6011 \\ -1.9483 & 4.2651 \end{bmatrix}$$


Bu kriterlere bağlı olarak elde edilen öz vektör ve öz değerler;

$$\text{özvektör} = \begin{bmatrix} -0.9096 & 0.3514 \\ -0.4155 & -0.9362 \end{bmatrix}$$

$$\text{özdeğer} = \begin{bmatrix} 0 & 0 \\ 0 & 4.9965 \end{bmatrix}$$

Elde edilen yeni verinin dağılımı Şekil 4.20’de verilmiştir. Dönüşüm sonrası elde edilen grafik ile veriler arasında düzgün bir sınıflandırma için iyi bir sınır olduğu görülmektedir. Sınıfları arasında örtüşmelerin olduğu verilerde düzgün bir karar bölgesi oluşturmak yani verileri birbirinden ayırmak için dönüşüm gereklidir. En büyük öz vektör eksenini boyunca dönüşüm en iyi dönüşümdür.

DAA denetimli bir yöntem ve TBA denetimsiz bir yöntemdir. Her ikisi de verileri temsil eden başka bir hiper düzlem bulmayı amaçlar, fakat bu gösterimler çok farklı amaçlara hizmet eder. DAA, aynı sınıftaki verilerin dağılımının minimum varyansa, farklı sınıftaki verilerin maksimum varyansa sahip olması için bir hiper düzlem bulur. TBA, tüm verileri aynı şekilde değerlendirir dolayısıyla analiz sonrası oluşan veriler maksimum varyansa sahiptir, fakat bazı durumlarda sınıflar arasındaki ayrımcılığı bozabilir. Dolayısıyla DAA’yı sınıflandırma, TBA’yı ise veri sıkıştırma / boyut azaltma amacıyla kullanmak yerinde olacaktır.



Şekil 4.20. Dönüşüm sonrası elde edilen grafik

4.5.3.3. Çekirdek Temel Bileşen Analizi

Çekirdek temel bileşenler analizi, temel bileşenler analizinden farklı olarak veri setine ilişkin doğrusal olmayan şekilde bir dönüşüm elde edilmesini sağlar. Bir başka ifadeyle doğrusal bir dağılım izlemeyen verilerin doğrusal bileşenler ile ifade edilmesini

sağlamaktadır. Bu tarz bir dönüşüm için bazı polinom tabanlı bazı çekirdek fonksiyonlarına ihtiyaç duyulmaktadır. Çekirdek fonksiyonları ile örnekler önce daha yüksek boyutlu ve doğrusal olarak ayrılabilen bir düzleme taşınır ve çözüm burada aranır.

4.6. Akıllı Hesaplama Yöntemlerinin Uygulama Alanları

Son yıllarda akıllı hesaplama yöntemleri konusunda önemli gelişmeler elde edilmiştir. YSA, denetimli, denetimsiz akıllı öğrenme algoritmaları, Boyut azaltma algoritmaları ile işaretlerin sınıflandırılması, verilerin kümelenmesi, parçacık tanıma gibi konularda etkili olmuştur. Normal ve gecikmeli mide boşalması hastalarından alınan EGG verilerini ayırmak için başarılı sonuçlar alınan çok katmanlı ileri beslemeli YSA kullanılmıştır [67]. Sindirim sistemi rahatsızlıklarının sınıflandırılması amacıyla LVQ ile ART1 sinir ağı sınıflandırıcıları kullanılmış ve LVQ ile daha iyi sonuçlar alınmıştır [134]. Uyku apnelerinin sınıflandırılması için ADD ile elde edilen katsayılar YSA girişine verilmiş ve sınıflandırma yapılmıştır [57]. Bağımsız bileşen analizi, biyoişaretlere uygulanan ve bağımsız kaynakları birbirinden ayıran yöntemlerden biri olmuştur [135-137]. Bu yöntemle farklı koşullar altında bir araya gelen çoklu işaretleri birbirinden ayırmak için kullanılmaktadır [133]. Bazı çalışmalarda YSA ve DVM performansları karşılaştırılmıştır ve DVM'nin daha hızlı, daha az hafıza gerektirdiği ve daha iyi sınıflandırma yüzdesi verdiği gözlenmiştir [102]. Yine en küçük kare DVM ile EKG ve EEG işaretlerinin sınıflandırma performansları incelenmiştir [36,45]. Boyut azaltma yöntemlerinde biri olan bağımsız bileşen analizi, temel bileşen analizi ile karşılaştırılmış ve elde edilen veriler DVM, DAA ve NB sınıflandırıcısı ile sınıflandırılmıştır. [41]. Epileptik EEG verilerinin sınıflandırılması için işaretin spektral çözümlemesi sonun elde edilen sonuçlar K-means kümeleme yöntemi ile bileşenler kümelendirilmiş, elde edilen veriler rastgele eğitim ve test kümelerine ayrılarak YSA ile sınıflandırılmıştır [50]. Özellikleri çıkarılan EEG işaretleri DVM, k-NN ve Radyal Tabanlı Sinir Ağları ile sınıflandırılıp performansları ölçülmüştür.

5. LabVIEW

Bu bölümde LabVIEW programının genel hatlarıyla tanıtımı, tez çalışmasında kullanılan araç çubukları hakkında bilgilendirme yapılacaktır.


5.1. LabVIEW (Sanal Enstrüman)

Programlama dili, yazılımcının bir algoritmayı ifade etmek amacıyla, bir bilgisayara hangi aşamada neyi ne şekilde yapması gerektiğini anlatmasının bir yoludur. Programlama dillerini, çalışma mantıkları, kodlama yapıları ve görselliği gibi farklı özelliklere göre gruptandırmak mümkün olmaktadır. Programlama dillerinin en alt seviyesini oluşturan ve ilk olarak geliştirilen makine dili, insan tarafından anlaşılması oldukça güç olup buna karşılık makine için en anlaşılır dildir. Makine dilinin farklı mikro işlemcili sistemlerde çalışmamasından dolayı assembly dili ortaya çıkmıştır. Assembly, makina dilinin sayısal ifadelerini, daha kolay anlaşılır olan makina koduna çeviren programlardır ve assembler'ı derleyiciden ayıran en önemli özellik bire bir dönüşüm yapmasıdır [138]. Daha sonra Pascal dili ile C dilinin gelişmesine imkân sağlanmıştır. Gelişen teknoloji metin tabanlı programlama mantığı ile çalışan dillerin yerine nesne tabanlı programlama dillerinin gelişimine ihtiyaç duymuştur. Böylece kod yazmaya gerek kalmadan görsel olarak programlama yapmak mümkün olmuştur [139].


National Instruments firmasının LabVIEW programını geliştirmesiyle programların hazır fonksiyonlarla grafiksel olarak tasarlanması mümkün olmuş ve kod yazmaya gerek kalmamıştır. Böylece programların hızlı bir şekilde yapılmasına imkân sağlanmış ve zaman kaybının önüne geçilmeye çalışılmıştır. Çalışma şekli ile laboratuvarında kullanılan fiziksel enstrümanlara benzediğinden dolayı Sanal Enstrüman (VI) adı da verilen LabVIEW [140] modüler fonksiyonları ile diğer programlama dillerinin yapabileceği her türlü işlemi yapabilme yeteneğine sahiptir. LabVIEW, sürükle bırak ile arabirimi oluşturma ve veri görüntüleyicileri ile sonuçları hemen görselleştirmeye imkân sağlamaktadır [26].

LabVIEW, ardışık metin satırı yerine bir veri akışı modelini kullanan bir grafiksel programlama dilidir. Diğer dillerle karşılaştırıldığında, LabVIEW, ardışık kod dizilerinin yerine bir veri akışıyla çalışabildiğinden dolayı çoklu işlemlerin paralel olarak yapılmasına imkân sağlar [26,49].


LabVIEW, ön panel ve blok diyagramı olmak üzere iki bileşenden oluşur. Ön panel kullanıcı arabiriminin hazırlandığı kısma karşılık gelirken, blok diyagramı da grafiksel kodların hazırlandığı kısma karşılık gelmektedir. Şekil 5.1’de gösterilen ön panelde sanal enstrümana bağlanan girişler kontrol olarak isimlendirilirken, çıkışlar ise gösterge-belirteç olarak isimlendirilir. Ön panelde kullanılan palet kontrol paleti, blok diyagramında kullanılan palet ise fonksiyon paleti denilmektedir (Şekil 5.2). Kontrol paleti, çeşitli kontrol ve göstergelere ulaşmaya imkân sağlar ve sadece ön panelde görüntülenir. Aynı şekilde fonksiyon paleti de bir sistemin tasarlanması için çeşitli fonksiyonlar ile bloklara erişmeyi sağlar ve sadece blok diyagramında görüntülenir. Şekil 5.3’te iki sayının toplanması hazırlanan programda, ön panelde kullanılan sayısal nesneler kontrol, toplamının sonucu gösteren nesne sayısal bir gösterge, toplama işlemi de fonksiyonu ifade etmektedir. Blok diyagramında mevcut terminallerin kontrol ve gösterge ayrımını yapabilmek için, nesne üzerindeki okun yönüne dikkat edilmelidir. Okun yönü sağda ise terminal kontrol, solda ise göstergedir. Terminaller, ön paneldeki nesnelerin blok diyagramındaki karşılıklarıdır.



Şekil 5.1. LabVIEW ön panel ve blok diyagramı



Şekil 5.2. LabVIEW Kontrol ve fonksiyon paleti



Şekil 5.3. Toplama Programı

LabVIEW kontrol paletinde sayısal, mantıksal (buton), karakter, dizi, matris, küme, tablo ve grafik gibi birçok nesne bulunmaktadır. Fonksiyon paletinde PID kontrol, bulanık mantık, sistem tanıma, simülasyon yapabilen kontrol ve simülasyon menüsü, karar yapılarının, sayısal, mantıksal, karşılaştırma, zamanlayıcı, dosya işlemi ve dizi-matris işlemlerinin yapıldığı programlama menüsü, sayısal- cebir, türev, integral, optimizasyon ve formülasyon yapabilen matematik menüsü, işaret üretimi, sinyal işleme, işaret ölçümü, pencereleme, filtreleme, dönüşüm, sayısal filtre tasarımı, zaman-frekans analizi, DD gibi işlemlerin yapıldığı işaret işleme menüsü, işaretlerin ne şekilde alınacağını (dışardan alma, dosyadan okuma), çıkışlarının ne şekilde dışarıya verileceğini sağlayan, işaret analizi yapan (genlik seviyesi ölçme, filtreleme, spektral parametrelerin çıkarılması, histogram çıkarılması), aritmetik ve karşılaştırma işlemlerini yapan diğer bir deyişle en sık kullanılan

nesnelerin bulunduğu express menüsü, FPGA ara birimi ve eklentilerin bulunduğu menüler bulunmaktadır.

Bu tez çalışmasında biyomedikal işaretlerin işlenmesi, farklı uzantılardaki dosyaların MATLAB ve LabVIEW ile uyum sağlayabilmesi için dosya çeviricinin bulunduğu biyomedikal araç kiti, verilerin DVM ve YSA ile sınıflandırılması ve boyutlarının azaltılması için MÖ araç kiti, ileri sinyal işleme araç kiti içerisindeki çeşitli işaret işleme blokları, sınıflandırma sonrası elde edilen sonuçların grafiklendirilmesi için ileri çizim araç kiti kullanılmıştır.

5.1.1. Biyomedikal Araç Kiti

Biyomedikal araç kiti ile işaretlerin yüklenmesi, gösterilmesi, üretilmesi ve analiz edilmesi mümkün olmaktadır [141-143]. Sanal enstrüman donanımı, verilerin gerçek zamanlı olarak toplanmasına imkân sağlarken aynı zamanda veri tabanlarından veri çekmeye de müsaade etmektedir [144]. Şekil 5.4'te biyomedikal araç kitine dair uygulamalar görülmektedir. Şekil 5.5'te de biyomedikal tezgahın arabirimi görülmektedir. Biyomedikal tezgâh, biyomedikal işaretlerin analiz edilebilmesine ve biyomedikal görüntü analizleri uygulamalarına imkân sağlayabilmektedir.

Yükleyici ile işaretlerin sensörler aracılığıyla kaydedilmesi ve filtrelenmesi mümkündür. **Görüntüleyici** ile işaretlerin dosyadan görüntülenmesine imkân sağlar ve çok kanallı veri dosyalarını destekler. Görüntüleyici ile aynı zamanda işaret raporu alınabilir ve bir HTML dosyasına çıktı gönderilebilir.


Generatör ile EKG, EEG ve EMG işaretlerini üretebilir. Bu tip işaretler dosya üzerinden yüklenebildiği gibi DAQ donanımının analog çıkış kanalları kullanılarak elde edilebilirler. EKG özellik çıkarımı, EKG işaretini analiz etmek ve işaretin özelliklerini çıkarmak için kullanılmaktadır.

Kalp hızı değişkenliği (HRV) ile EKG işaretindeki RR aralık işaretinden ölçüm alınır ve bu ölçümler bir yazıcıya veya HTML dosyasına çıktı olarak gönderilir.


Noninvazif kan basıncı analizi (NIBP) ile kan basıncı analizi mümkün olmaktadır. Bu tip işaretler de dosya üzerinden yüklenebildiği gibi DAQ donanımının analog çıkış kanalları kullanılarak elde edilebilirler.

Dosya format çeviricisi ile farklı formattaki dosyalar LabVIEW dilini destekleyen dosyalara dönüştürülürler. .hea, .tdms, .tdm, .abf, .lum, .mat, .mp3, .wav, .csv, .rec, .edf, .xml, .emg, .c3d, .ddf, .bdf uzantılı dosyalar LabVIEW dilini desteklemektedir.

3 boyutlu görüntü yapılandırıcısı ile 3 boyutlu bir modeli yeniden yapılandırmaya imkân sağlar. Bu model önceden belirlenmiş bir model de kullanılabilirken gerçek uygulamalarda çekilen harici bir model de kullanılabilir.



Şekil 5.4. Biyomedikal araç kiti




Şekil 5.5. Biyomedikal tezgah

5.1.2. İleri Sinyal İşleme Araç kiti

Biyomedikal araç kiti işaret analizi ve biyomedikal görüntü analizlerini yapabilmesi için ileri sinyal işleme araç kitine ve sayısal filtre tasarım kitine ihtiyaç duymaktadır. Şekil


5.6 sinyal işleme araç kitine ait uygulamalar görülmektedir. Kit içerisinde dijital filtre tasarımı, zaman serisi analizi, istatistiksel analiz, - değişken frekans içeriğine sahip işaretler için grafiksel zaman-frekans analizi, dalgacık ve filtre bankası tasarımı, gürültü azaltma, kısa süreli işaret karakterizasyonu yapmak mümkündür.



Şekil 5.6. Sinyal işleme araç kiti

5.1.3. Makine Öğrenmesi Araç Kiti


Yapılan tez çalışmasında amaç LabVIEW donanımı kullanılarak biyoişaretlerin akıllı hesaplama yöntemleri ile sınıflandırılmasını sağlamaktır. Dolayısıyla bu tez çalışmasında MÖ algoritmaları kullanılmıştır. Donanımda yer alan MÖ araç kiti ile anormallik tespiti, sınıflandırma ve kümeleme yapma mümkün olmuştur. Araç kiti tahmin uygulamaları üzerinde iyi sonuçlar vermektedir. Şekil 5.7’de MÖ araç kitine ait fonksiyonlar görülmektedir. Kit içerisinde yer alan denetimli-denetimsiz öğrenme algoritmaları ile sınıflandırma yapılması, boyut azaltma algoritmaları ile verilerin önemli sayılabilecek özelliklerinin seçilmesi, doğrulama ve görselleştirme uygulamaları ile sınıflandırmanın ne kadar doğru yapıldığına dair bilgi sahibi olmak ve bunu görsel olarak görmek mümkün olmaktadır.



Şekil 5.7. MÖ araç kiti

5.1.4. İleri Çizim Araç Kiti

İleri çizim araç kiti, profesyonel kalitede şekil ve çizimler oluşturmamıza imkân sağlamaktadır. Çizgi, dağılım, kutup ve çubuk grafikleri gibi standart çizim programlarına ek olarak, gelişmiş görselleştirme seçeneklerine sahiptir. Yapılan çizimler üzerinde metin açıklamaları ve matematiksel sembolleri kullanmak mümkündür. Şekil 5.8’de ileri çizim araç kitine ait fonksiyonlar görülmektedir.



Şekil 5.8. İleri çizim araç kiti

6. DENEYSEL SONUÇLAR


Bu tez çalışmasında, EEG, EKG, göğüs kanseri ve kan basıncı gibi farklı biyomedikal işaretlere ait verilerin analizlerinin LabVIEW ortamında yapılması amaçlanmıştır. Öncelikle LabVIEW'in performans analizini yapmak için YSA, TBA-DVM, KTBA-DVM algoritmaları MATLAB ortamında da çalıştırılarak elde edilen sonuçlarla LabVIEW'de elde edilen sonuçlar karşılaştırılmıştır. Böylece programın doğruluk oranı test edilmiş ve önerilen yöntemlerin sonuçlarının değerlendirilmesi kolaylaşmıştır. Yapılan uygulamalar arasında veriler;

- YSA ile sınıflandırılmış, sınıflandırma sonuçları analiz edilmiştir.
- Boyut azaltma uygulamalarından olan DAA, TBA ve KTBA'nın uygulamaları yapılmıştır.
- DAA uygulanmış bir veri, DVM ile sınıflandırılmış analiz sonuçları karşılaştırılmıştır.
- TBA uygulanmış bir veri, DVM ile sınıflandırılmış analiz sonuçları karşılaştırılmıştır.
- KTBA uygulanmış bir veri, DVM ile sınıflandırılmış analiz sonuçları karşılaştırılmıştır.
- Tek başına TBA-DVM'nin kullanımına karşılık seri TBA-DAA-DVM modeli önerilmiş ve sonuçları incelenmiştir.
- Tek başına TBA-DVM'nin ve seri TBA-DAA-DVM modeline, paralel TBA-DAA-DVM modeli önerilmiş ve sonuçları incelenmiştir. Çekirdek fonksiyonlarının performansları karşılaştırılmıştır.
- Tek başına KTBA-DVM'nin kullanımına karşılık paralel KTBA-DAA-DVM modeli önerilmiş ve sonuçları incelenmiştir. Çekirdek fonksiyonlarının performansları kıyaslanmıştır.

Sınıflandırma uygulamalarında, göğüs kanseri verileri ve EEG verileri olmak üzere iki farklı veri grubu kullanılmıştır. Her iki veri grubunda da mevcut sınıflandırma yöntemleri ile önerilen yöntemler için sonuçlar alınmıştır. Sınıflandırma haricinde EKG işaretlerinden kalp atış hızı tespiti ve kan basıncı verilerinden ise kan basıncı tespiti yapılmıştır.

6.1. YSA ile Sınıflandırma Bloğu


LabVIEW'de oluşturulan YSA bloğu Şekil 6.1'de verilmiştir. Veri, eğitim ve test verilerine sırasıyla %80 ve %20 oranıyla ayrılmıştır. Eğitim işlemi sonucu, ağın performansı test verileriyle sağlanmaktadır. Kullanılan algoritma türü, ortalama karesel hata, nöron sayısı, ağı durdurma kriterleri ve ara katman sayısı değiştirilebilmektedir.




Şekil 6.1. YSA ile Sınıflandırma Bloğu

6.2. DVM ile Sınıflandırma Bloğu

Verilerin DVM ile LabVIEW ortamında sınıflandırılması mümkündür. Kullanılan bağlantı şemaları Şekil 6.2 ve Şekil 6.3'te iki bölüm halinde gösterilmiştir. Veri, eğitim ve test verilerine sırasıyla %80 ve %20 oranıyla ayrılmıştır. Burada doğrusal olmayan verilerin farklı çekirdek fonksiyonlarıyla bir üst düzleme taşınması ve bunların birbirleriyle kıyaslanmasına imkân sağlanmıştır. Özellikleri çıkarılan veriler, oluşturulan LabVIEW blok şeması ile sınıflandırmaya tabi tutulabilir.



Şekil 6.2. DVM ile sınıflandırma şeması 1.parça



Şekil 6.4. LabVIEW’de oluşturulan TBA şeması


Tablo 6.1. Gerçek veri ile TBA uygulanmış veri

Veri				TBA uygulanmış Veri	
Stn1	Stn2	Stn3	Stn4	Stn1	Stn2
0,8	0,5	0,4	0,6	0,197355	-0,365428
0,8	0,3	0,5	0,7	0,184373	-0,448306
1	1	0,5	0,6	-0,181581	-0,268328
0,7	1	0,9	0,8	-0,398728	0,0564946
0,1	0,8	1	1	-0,229419	0,477759
0,2	0,3	0,4	0,5	0,583325	0,047498
1	0,8	1	1	-0,58262	-0,284084
0,4	0,8	0,7	0,4	0,1433	0,187539
0,4	1	0,8	0,8	-0,223862	0,290848
0,3	0,5	0,3	0,3	0,610238	0,0494793
0,3	0,4	0,8	0,6	0,213713	0,0868365
0,5	0,8	0,5	0,5	0,165144	0,0599486
0,2	0,3	0,3	0,5	0,640457	0,0279033
1	0,2	0,7	1	-0,119245	-0,639032
1	0,5	1	1	-0,436631	-0,432166
0,4	0,3	0,7	0,7	0,227087	-0,0705201
0,5	0,6	0,8	0,7	-0,0152787	0,0125075
0,4	1	0,7	0,7	-0,113554	0,275005

0,4	0,8	1	0,4	-0,0280964	0,246323
0,8	0,8	1	1	-0,504131	-0,114785
1	1	0,5	0,8	-0,287933	-0,275832
0,2	1	1	1	-0,36599	0,491832
0,2	1	0,8	0,8	-0,145373	0,460146
0,3	1	0,5	0,5	0,146307	0,327968
0,5	0,4	0,2	0,3	0,637544	-0,188775
1	1	1	1	-0,679946	-0,185362
0,4	0,8	0,6	0,5	0,147256	0,164192
1	0,3	0,4	0,4	0,322545	-0,625944
0,2	0,7	0,8	0,7	0,0537918	0,315816
0,3	1	0,5	0,7	0,0399545	0,320465

6.4. DAA ile Boyut Azaltma Bloğu

Boyut azaltma yöntemlerinden bir diğeri ise DAA olup, LabVIEW ile uygulanması gereken blok şeması Şekil 6.5'te verilmiştir. Bu yöntem, denetimli bir algoritma olduğundan dolayı girişte sınıf etiketinin verilmesi gerekmektedir. Tablo 6.2' de boyutu 30x4 olan bir verinin 30x1'e düşürülmesine dair sonuçlar listelenmiştir.



Şekil 6.5. LabVIEW'de oluşturulan DAA şeması


Tablo 6.2. Gerçek veri ile DAA uygulanmış veri

Veri			DAA uyg. Veri
Stn1	Stn2	Stn3	Stn1
0,139904	0,139904	2,29501	0,139904
0,0132641	0,0132641	2,29501	0,0132641
0,31573	0,31573	2,3131	0,31573
0,261909	0,261909	2,32214	0,261909
0,235007	0,235007	2,30405	0,235007
0,0447627	0,0447627	2,32214	0,0447627
0,148167	0,148167	2,30405	0,148167
0,208678	0,208678	2,28597	0,208678
0,278569	0,278569	2,28597	0,278569
0,549911	0,549911	2,30405	0,549911
0,525536	0,525536	2,3131	0,525536
0,655191	0,655191	2,30405	0,655191
0,519983	0,519983	2,30405	0,519983
0,746491	0,746491	2,30405	0,746491
0,575253	0,575253	2,3131	0,575253
0,749188	0,749188	2,29501	0,749188
0,754584	0,754584	2,28597	0,754584
0,854379	0,854379	2,29501	0,854379
0,979519	0,979519	2,30405	0,979519
1,07219	1,07219	2,30405	1,07219
1,09628	1,09628	2,3131	1,09628
1,04591	1,04591	2,32214	1,04591
1,08686	1,08686	2,30405	1,08686
0,945388	0,945388	2,3131	0,945388
1,04682	1,04682	2,28597	1,04682
1,16923	1,16923	2,30405	1,16923
1,20293	1,20293	2,29501	1,20293
1,4169	1,4169	2,28597	1,4169
1,25556	1,25556	2,27693	1,25556
1,31816	1,31816	2,29501	1,31816


6.5. Kernel TBA ile Boyut Azaltma Bloğu

Çekirdek temel bileşenler analizi, temel bileşenler analizinden farklı olarak doğrusal bir dağılım izlemeyen verilerin doğrusal bileşenler ile ifade edilmesini sağlamaktadır. Bu tarz bir dönüşüm için bazı polinom tabanlı bazı çekirdek fonksiyonlarına ihtiyaç duyulmaktadır. Çekirdek fonksiyonları ile örnekler önce daha yüksek boyutlu ve doğrusal olarak ayrılabilir bir düzleme taşınır ve çözüm burada

aranır. Şekil 6.6’da bu dönüşüme ait 3 boyutlu grafikler, Şekil 6.7’de bu dönüşümün gerçekleştirilmesini sağlayan LabVIEW blok şeması verilmiştir. 1000x3 boyutundaki veri sırasıyla Gauss, polinomial ve doğrusal çekirdek fonksiyonları kullanılarak 1000x2 boyutundaki verilere düşürülmüştür.



Şekil 6.6. Gauss, polinomial, doğrusal çekirdek fonksiyonları uygulanmış 3 boyutlu grafikler



Şekil 6.7. LabVIEW’de oluşturulan KTBA blok şeması

6.6. LabVIEW Performans Analizi

LabVIEW performans analizini gerçekleştirmek için kullanılan veri seti, Wisconsin-Madison Üniversitesi Hastanesinde Dr. W. H. Wolberg tarafından alınan göğüs kanseri verileridir [145]. Bu veriler literatürde çoğu araştırmacı tarafından sınıflandırma yapılması amacıyla kullanıldığından dolayı tez çalışmasında önerilen yöntemler ile karşılaştırma yapma imkânı sağlamaktadır. Göğüs kanserine ait kullanılan veri 9 özniteliği içeren 699 biyopsiyi tanımlayan 9x699 bir matristir. Hedef verisi ise iki sınıflı 2x966 bir matristir. Bu verilere ait özellikler Tablo 6.3'te listelenmiştir. Sırasıyla tüm sınıflandırma yöntemleri uygulamış ve sonuçlar listelenmiştir.

Tablo 6.3. Göğüs kanserine ait öznitelikler ve hedefler


Öznitelikler	Hedefler
Hücre şekli	İyi huylu ur
Marjinal Yapışma	Kötü huylu ur
Tek epitel hücresi boyutu	
Çıplak çekirdekler	
Mülayim chomatin	
Normal nükleolit	
Mitozlar	
Küme kalınlığı	
Hücrenin boyutu	

6.6.1. YSA ile Sınıflandırma


YSA uygulaması için kullanılan göğüs kanserine ait veriler hem MATLAB hem de LabVIEW ortamında incelenmiştir. Veri ilk olarak LabVIEW ortamında incelenmiştir. Veri, eğitim ve test verilerine sırasıyla %80 ve %20 oranıyla ayrılmıştır. Eğitim verileri BP öğrenme bloğuna gönderilmiştir. Ağ 9 girişli giriş katmanından, 2 çıkışlı çıkış katmanından ve 10 nöronlu ara katmandan oluşmaktadır. Algoritma olarak geri yayılım algoritması kullanılmıştır. Ortalama karesel hata 10^{-5} olarak seçilmiş, gerektiği durumda durdurma kriterleri ve ara katman sayısı değiştirilebilmektedir.

Bu program ile eğitim ve test verilerinin 3 boyutlu gösterimleri, 2 boyutlu gösterimleri, sınıflandırma sonrası histogramları, sınıflandırma doğruluğunu ifade eden sınıflandırma yüzdesi, hangi verinin ne kadar hata ile ayrıldığını gösteren hata matrisi, rand indeksini elde etmek mümkündür. Eğitim ve test verilerinin 3 boyutlu dağılımları Şekil


6.8’de, test verilerinin 2 boyutlu dağılımı Şekil 6.9’da, sınıflandırma sonrası gerçek verilerle ve tahmin edilen verilere ait histogram Şekil 6.10’da verilmiştir. Tablo 6.4’te ise sınıflandırma doğrulukları ve programın çalışma süresi belirtilmiştir.



Şekil 6.8. Eğitim ve test verilerinin 3 boyutlu dağılımları



Şekil 6.9. Test verisinin 2 boyutlu dağılımı



Şekil 6.10. Sınıflandırma sonrası histogram


Tablo 6.4. LabVIEW-YSA analiz sonuçları

Sınıflandırma Doğruluğu	Süre
%98.5714	4.023s

LabVIEW ortamında oluşturan programla elde edilen eğitim ve test verileri MATLAB ortamına aktarılarak aynı işlemler MATLAB ortamında da yapılmıştır. Şekil 6.11’de MATLAB ortamında elde edilen hata matrisi, Şekil 6.12’de ise ROC eğrisi verilmiştir.

Hata Matrisi			
Çıkış	1	2	
	84 60.0%	4 2.9%	95.5% 4.5%
	2 1.4%	50 35.7%	96.2% 3.8%
	1	2	Hedef sınıf
	97.7% 2.3%	92.6% 7.4%	95.7% 4.3%

Şekil 6.11. Hata matrisi



Şekil 6.12. ROC eğrisi

ROC eğrisinin altındaki alan 1'e yaklaştıkça sınıflandırma doğruluğu artmaktadır.

Tablo 6.5. MATLAB-YSA analiz sonuçları

Sınıflandırma Doğruluğu	Süre
%95.7	8.992407s

Geri yayılım algoritmasına yönelik LabVIEW ve MATLAB ile elde edilen sonuçlar tablolar ve grafikler halinde verilmiştir. Bu sonuçlara göre hata matrisi ve sınıflandırma doğruluğu göz önüne alındığında LabVIEW ile yapılan sınıflandırma doğruluğunun MATLAB ile yapılan sınıflandırmadan daha iyi olduğu ve programın çalışma süresinin neredeyse yarı yarıya düştüğü görülmüştür.

6.6.2. TBA Uygulanmış Verinin DVM ile Sınıflandırılması

Sınıflandırma yapılırken, verilerin doğrudan alınıp sınıflandırmaya tabii tutulması yerine, verilerden önemli sayılabilecek özelliklerin elde edilmesi her zaman daha verimli olmaktadır. Bu sebeple uygulama boyunca kullandığımız kanser verilerine öncelikle TBA ile boyut azaltma işlemi uygulandı. Programa ait LabVIEW blok şeması Şekil 6.13'te verilmiştir. Boyutu azaltılan veri LabVIEW'de eğitim-test verilerine ayrıldıktan sonra DVM girişine uygulandı. Aynı özellik verisi MATLAB'a aktararak orada yazılan kodlarla eğitim-test verilerine ayrılıp DVM ile sınıflandırıldı. Ayrıca ham veri MATLAB'a doğrudan atılarak MATLAB'ta oluşturulan kodlarla TBA ile boyut azaltılmış ve eğitim ve

test verilerine ayrılıp ve sınıflandırma sonuçları incelenmiştir. Dolayısıyla hem farklı hem de aynı eğitim-test verilerinin performansları Gauss ve polinomial çekirdek fonksiyonu kullanılarak her iki ortam için karşılaştırılmış ve elde edilen sayısal sonuçlar Tablo 6.6’da gösterilmiştir. Polinomial çekirdek fonksiyonun, Gauss fonksiyonuna göre daha düşük sonuçlar verdiği görülmektedir. Gauss fonksiyonu için LabVIEW’de elde edilen sonuçların daha yüksek olduğu görülmektedir.

Tablo 6.6. LabVIEW ve MATLAB için farklı ve aynı eğitim-test veri setleri için TBA-DVM sınıflandırma sonuçları

Farklı Eğitim-Test Veri Seti		
Gauss Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	%97.1429	%89.93
Polinomial Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 85	% 92.81
Aynı Eğitim-Test Veri Seti		
Gauss Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	%97.1429	% 93.57
Polinomial Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 82.8571	% 92.86

6.6.3. DAA Uygulanmış Verinin DVM ile Sınıflandırılması


DAA, denetimli bir öğrenme algoritması olup boyut azaltmadan çok veri sınıflandırmaya uygundur. Bu çalışmada kullanılan DAA ile verinin boyutunun azaltılmasına ve sınıflandırılmasına ilişkin LabVIEW blok şeması Şekil 6.14'te gösterilmiştir. 9x699 boyutundaki veri DAA bloğu ile 1x699 boyutuna düşürülmüş, bu boyuttaki verinin DVM girişi için uygun olmadığından dolayı asıl verinin rastgele bir sütunu yeni verinin yanına eklenerek 2x699 boyutlu yeni veri elde edilmiştir. Boyutu azaltılan veri LabVIEW'de eğitim-test verilerine ayrıldıktan sonra DVM girişine uygulandı. Boyutu azaltılmış veri MATLAB'a aktarılarak orada yazılan kodlarla eğitim-test verilerine ayrılıp DVM ile sınıflandırıldı. Ayrıca ham veri MATLAB'a doğrudan atılarak MATLAB'ta oluşturulan kodlarla DAA ile boyut azaltılmış ve eğitim ve test verilerine ayrılıp ve DVM ile sınıflandırma sonuçları incelenmiştir. Dolayısıyla hem farklı hem de aynı eğitim-test verilerinin performansları Gauss ve Polinomial çekirdek fonksiyonu kullanılarak her iki ortam için karşılaştırılmış ve elde edilen sayısal sonuçlar Tablo 6.7'de gösterilmiştir.

Tablo 6.7. LabVIEW ve MATLAB için farklı ve aynı eğitim-test veri setleri için DAA-DVM sınıflandırma sonuçları

Farklı Eğitim-Test Veri Seti		
Gaussian Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 97.1429	% 93.53
Polinomial Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 96.4286	% 94.96
Aynı Eğitim-Test Veri Seti		
Gaussian Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 98.5714	% 98.57
Polinomial Kernel	LabVIEW	MATLAB
Sınıflandırma Doğruluğu	% 96.4286	% 95.71

LabVIEW'de elde edilen eğitim-test verilerinin, MATLAB'ta doğrudan kullanılmasıyla elde edilen sınıflandırma sonuçları ile LabVIEW'de elde edilen sınıflandırma sonuçları birbirine çok yakın çıkmış olup, başarı oranı yüksektir. Fakat

MATLAB'ta elde edilen eğitim-test verilerinin sınıflandırma sonuçları, LabVIEW'de elde edilen verilerin sınıflandırma sonuçlarına göre biraz daha düşüktür.



Şekil 6.14. DAA-DVM sınıflandırılmasına ilişkin LabVIEW blok şeması


6.6.4. Kernel TBA Uygulanmış Verinin DVM ile Sınıflandırılması

Çekirdek temel bileşenler analizi, temel bileşenler analizinden farklı olarak doğrusal bir dağılım izlemeyen verilerin doğrusal bileşenler ile ifade edilmesini sağlamaktadır. Bu tarz bir dönüşüm için bazı polinom tabanlı bazı çekirdek fonksiyonlarına ihtiyaç duyulmaktadır. Çekirdek fonksiyonları ile örnekler, önce daha yüksek boyutlu ve doğrusal olarak ayrılabilen bir düzleme taşınır ve çözüm burada aranır. Bu çalışmada kullanılan KTBA ile verinin boyutunun azaltılmasına ve sınıflandırılmasına ilişkin LabVIEW blok şeması Şekil 6.15'te gösterilmiştir. 9x699 boyutundaki veri KTBA bloğu ile 4x699 boyutuna düşürülmüş, yeni veri elde edilmiştir. Seçilen yüzde oranı ile elde edilen eğitim-test verileri DVM girişine bağlanmıştır. KTBA için hem Gauss hem de polinomial çekirdek fonksiyonu kullanılmıştır. Ayrılan eğitim ve test verileri MATLAB ortamına da aktarılarak orada da analiz edilmiş ve sonuçlar Tablo 6.8'de verilmiştir.

Tablo 6.8. LabVIEW ve MATLAB aynı eğitim-test veri setleri için KTBA-DVM sınıflandırma sonuçları

Yöntem		LABVIEW	MATLAB
KTBA	DVM	Sınıflandırma Doğruluğu	Sınıflandırma Doğruluğu
Gauss	Gauss	% 97.1429	%96,43

Elde edilen sonuçlara göre her iki ortamda da elde edilen sonuçlar yakın çıkmıştır.



Şekil 6.15. KTBA-DVM sınıflandırılmasına ilişkin LabVIEW blok şeması

6.7. Önerilen Yöntemler

Yapılan uygulamalarda [145] veri tabanından alınan göğüs kanseri verileri, [146] veri tabanından alınan EEG verileri ve LabVIEW'in kendi veri tabanı içerisinde olan EKG verileri ile kan basıncı verileri kullanılmıştır. Herhangi bir verinin farklı yöntemler ile sınıflandırılması için verinin niteliğini değiştirmeden, verinin özelliklerinin çıkarılması gerekmektedir. İstatistiksel özellikler ve DD gibi yöntemlerin dışında TBA, DAA ve KTBA boyut azaltma algoritmaları da veriden özellik çıkarmak amacıyla kullanılmaktadır.

6.7.1. Göğüs Kanseri Verilerinin MÖ Algoritmaları ile Sınıflandırılması

Bu tezde göğüs kanseri verileri kullanılarak TBA-DVM, KTBA-DVM, DAA-DVM ve bu yöntemlerin dışında önerilen yöntemler ile verilerin sınıflandırma performansları analiz edilmiştir. Sınıflandırma doğruluk oranları tespit edilirken, holdout ve çapraz doğrulama yöntemleri kullanılmıştır. Çapraz doğrulama yöntemi ve holdout yöntemi kullanılarak elde edilen sınıflandırma doğruluklarının birbirlerine yakın çıkması, ağın tutarlı davrandığı ve ezber bir eğitim yapmadığını göstermektedir. Sınıflandırma performansını elde etmenin haricinde, önerilen yöntemler ile eğitim-test süresi boyunca hiç kullanılmayan bir verinin kanser-sağlıklı ayrımı yapılmıştır. Böylece, gerçek hayattaki uygulamadan alınan veri tabanındaki verilerle bir öğrenme gerçekleşecek ve yeni gelen bir kişiye ait veri hakkında elde edilen sonuçlara göre hızlı bir şekilde yorum yapılabilecektir. Seçilen çekirdek fonksiyonun türüne göre, her bir yöntem için farklı sonuçlar elde edilmiştir. Göğüs kanseri verileri için TBA-DVM ile elde edilen 5 tane sonuca ait ortalama değerler Tablo 6.9'da, DAA-DVM ile elde edilen 5 tane sonuca ait ortalama değerler Tablo 6.10'da, aynı şekilde KTBA-DVM ile elde edilen 5 tane sonuca ait ortalama değerler Tablo 6.11'de verilmiştir. KTBA'da, TBA ve DAA'dan farklı olarak çekirdek fonksiyonu seçimi söz konusu olduğundan KTBA ve DVM'nin farklı çekirdek fonksiyonu kombinasyonları için sonuçlar listelenmiştir.

Tablo 6.9. TBA-DVM için uygulama sonuçları ve ortalamaları

Çekirdek Fonksiyonu	Kullanılan Yöntem	TBA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss	Hold out	%96.25716	45.6s	0.931079
	Çapraz Doğrulama	%94.5706	24.4s	0.899097
Polinomial	Hold out	%91.42858	40.2s	0.8470294
	Çapraz Doğrulama	%96.7143	48.6s	0.93865375
Doğrusal	Hold out	%92.42856	39.8s	0.8597946
	Çapraz Doğrulama	%92.42775	32.2s	0.870263

Tablo 6.9’den, TBA-DVM yapısı için en iyi sonucun Gauss çekirdek fonksiyonu ile sağlandığı görülmüştür.

Tablo 6.10. DAA-DVM için uygulama sonuçları ve ortalamaları

Çekirdek Fonksiyonu	Kullanılan Yöntem	DAA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss	Hold out	%96.3143	44.2s	0.9416438
	Çapraz Doğrulama	%95.856325	28.5s	0.921675
Polinomial	Hold out	%94.89144	33.2s	0.904851
	Çapraz Doğrulama	%95.857125	15.2s	0.92594425
Doğrusal	Hold out	%95.7143	44.6s	0.9176956
	Çapraz Doğrulama	%96.2857	15.1s	0.929688

Tablo 6.10’den, DAA yapısı için DVM’de kullanılan Gauss ve Doğrusal çekirdek fonksiyonu ile elde edilen sonuçların polinomial çekirdek fonksiyonuna göre iyi olduğu görülmektedir.

Tablo 6.11. KTBA-DVM için uygulama sonuçları ve ortalamaları


Çekirdek Fonksiyonu	Kullanılan Yöntem	KTBA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss Gauss	Holdout	%95.28572	38s	0.90974
	Çapraz Doğrulama	%94.5706	24.5s	0.900597
Gauss Polinomial	Holdout	%87.2	29.4s	0.7852624
	Çapraz Doğrulama	%81.41955	26.7s	0.730251
Polinomial Gauss	Holdout	%95.7143	44.8	0.9174924
	Çapraz Doğrulama	%93.85715	23.5s	0.8899055
Polinomial Polinomial	Holdout	%72.51428	28.8s	0.6790958
	Çapraz Doğrulama	%64.705275	18.3s	0.752911
Gauss Doğrusal	Holdout	%95.285	43.4s	0.90978
	Çapraz Doğrulama	%94.713475	37.7s	0.90205275
Doğrusal Gauss	Holdout	%95.71428	43.6s	0.9179036
	Çapraz Doğrulama	%94.284875	33s	0.89587875
Doğrusal Doğrusal	Holdout	%94.14284	40.6s	0.8892704
	Çapraz Doğrulama	%94.85715	22.1s	0.90492625
Polinomial Doğrusal	Holdout	%92.85714	20.2s	0.8670506
	Çapraz Doğrulama	%93.7143	13.2s	0.887455
Doğrusal Polinomial	Holdout	%78.85714	18s	0.7023992
	Çapraz Doğrulama	%92.285725	18.8s	0.86377675

Tablo 6.11’den, KTBA-DVM yapısı için en iyi sonucun DVM’de kullanılan Gauss çekirdek fonksiyonu ile sağlandığı görülmektedir. Doğrusal çekirdek fonksiyonu, Gauss çekirdek fonksiyonuna yakın performans göstermekle birlikte, Polinomial çekirdek fonksiyonun performansı en kötüdür. Dolayısıyla çekirdek fonksiyonlarının performansı artırmak, sonuçlarını iyileştirmek ve seçimlerini kolaylaştırmak için bu yöntemlerin kullanımıyla iki tane model önerilmiştir.

6.7.1.1. Seri TBA-DAA-DVM Modeli

Bu yöntem, TBA-DVM ile veri sınıflandırılmasına alternatif olarak önerilmiştir. Bu amaçla iki model önerilmiştir. Seri TBA-DAA-DVM yapısında, veri önce iki ayrı TBA girişine verilir farklı boyut seçimleri yapılarak TBA çıkışları elde edilir. TBA çıkışlarından da iki ayrı DAA girişine bağlanan veriler DAA çıkışlarında bir matriste toplanarak yeni özellik verileri elde edilir. Elde edilen bu özellik vektörü DVM ile sınıflandırılır. Algoritmaya ait blok diyagramı Şekil 6.16’da, Seri TBA-DAA-DVM yapısı için kullanılan test verisinin 3 boyutlu ile 2 boyutlu grafiksel dağılımları Şekil 6.17’de, programa ait


LabVIEW’de oluşturulan blok şeması Şekil 6.18’de ve programdan elde edilen sayısal sonuçlar da Tablo 6.12’de verilmiştir.




Şekil 6.16. Seri TBA-DAA-DVM modeline ait blok diagramı

Tablo 6.12. Seri TBA-DAA-DVM modeline ait sayısal sonuçlar

Çekirdek Fonksiyonu	Kullanılan Yöntem	Seri TBA-DAA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss	Hold out	%95.7143	41.4s	0.9178206
	Çapraz Doğrulama	%94.856325	25s	0.90461425
Polinomial	Hold out	%70.77144	43s	0.5905242
	Çapraz Doğrulama	%68.6765	23.4s	0.5939235
Doğrusal	Hold out	%95.71432	41.2s	0.9181498
	Çapraz Doğrulama	%94.714275	19s	0.90269325



a)




b)

Şekil 6.17. Kullanılan test verisinin a) 3 boyutlu dağılımı b) iki boyutlu dağılımı

Elde edilen bu sonuçlar, TBA-DVM ile elde edilen sonuçlarla karşılaştırıldığında doğrusal çekirdek fonksiyonu açısından sınıflandırma doğruluğu yüzdesi ve benzerlik oranının iyileştirdiğini görülmekte ve Gauss çekirdek fonksiyonun hemen hemen aynı performansta kaldığını göstermektedir.

Kullanılan veri 458 tane hasta, 241 tane sağlıklı kişiye aittir. MÖ ile yeni bir kişinin hasta-sağlıklı ayrımı yapılması amaçlandığından, çekirdek fonksiyonu Gauss seçilerek 140 test verisinin 136'sı ağırlık performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 4 tanesi ise programa yeni girilecek veriler hakkında yorum yapmak için kullanılmıştır. Sınıflandırma doğruluğu %94.8529 olarak bulunan bir sistem için 100 kişiden yaklaşık 6 tanesinin yanlış sınıflandırılması söz konusudur. Bu aşamada kullanılan 140 tane veriden yaklaşık 8 tanesinin yanlış sınıflandırılması beklenmektedir. Nitekim gerçek ve tahmin sonuçları incelendiğinde 8 kişide hatalı bir sınıflandırma olmuştur. Sisteme sonradan girilen 4 verinin ise 1 tanesinin yanlış sınıflandırıldığı görülmüştür. Bu 4 verinin 3 tanesine sağlıklı, sağlıklı olan bir tanesine ise kanser yorumu yapılabilmektedir. Şekil 6.19'da bu uygulamaya yönelik elde edilen histogram verilmiştir.



Şekil 6.19. Gauss çekirdek fonksiyonu kullanılarak elde edilen histogram

Ayrıca modelin başarımının değerlendirilmesi için kesinlik, duyarlılık ve özgünlük değerleri hata matrisi kullanılarak hesaplanmış ve Tablo 6.13'te listelenmiştir. Hata matrisinde elde edilen sayısal sonuçlar, Şekil 6.19'daki histogramda da gözlenmektedir.


Tablo 6.13. Seri TBA-DAA-DVM modeline ait başarımlar

Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
52	5	0.912280	0.962962	0.939024
2	77			

Doğrusal çekirdek fonksiyonunda performans artmasına rağmen, Polinomial çekirdek fonksiyonun bu hibrit modelle yeterli düzeyde sonuç vermemesinden dolayı, bu modele alternatif paralel TBA-DAA-DVM modeli önerilmiştir.

6.7.1.2. Paralel TBA-DAA-DVM Modeli


Önerilen bu model, polinomial çekirdek fonksiyonun TBA-DVM ve seri TBA-DAA-DVM yapılarında yeterli düzeyde sonuç vermemesinden ve diğer çekirdek fonksiyonlarının da performanslarını artırmak için her iki yapıya alternatif başka bir hibrit model olarak önerilmiştir. Bu yöntem ile ham veri aynı anda hem TBA girişine hem de DAA girişlerine verilecek, her ikisinden de ayrı ayrı elde edilen bu özellik verileri bir matriste toplanıp yeni bir özellik vektörü elde edilecektir. Bu özellik vektörü DVM girişine verilecektir. Şekil 6.20’de algoritmaya ait blok diagramı, Şekil 6.21’de programa ait LabVIEW’de oluşturulan blok şeması, Şekil 6.22’de test verisinin 3 boyutlu ve 2 boyutlu grafiksel dağılımı ve Tablo 6.14’te ise elde edilen sayısal sonuçlar verilmiştir.



Şekil 6.20. Paralel TBA-DAA-DVM algoritma modeli


Tablo 6.14. Paralel TBA-DAA-DVM modeline ait sayısal sonuçlar

Çekirdek Fonksiyonu	Kullanılan Yöntem	Paralel TBA-DAA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss	Hold out	%95.57	27s	0.9152104
	Çapraz Doğrulama	%94.9992	24.2s	0.90720875
Polinomial	Hold out	%94.97142	34s	0.904851
	Çapraz Doğrulama	%94	16.1s	0.89264375
Doğrusal	Hold out	%97.14284	38.2s	0.944584
	Çapraz Doğrulama	94.9992	16.2s	0.90720875



Şekil 6.21. Paralel TBA-DAA-DVM modeline ait LabVIEW’de oluşturulan blok şeması

Elde edilen bu sonuçlar, TBA-DVM ve seri TBA-DAA-DVM yapısı ile karşılaştırıldığında tüm çekirdek fonksiyonlarının performansları için iyi sonuçlar alındığı görülmektedir. Gauss çekirdek fonksiyonun ortalaması hemen hemen aynı kalmakta, doğrusal çekirdek fonksiyonun sınıflandırma doğruluğunda artma gözlenmekte, polinomial çekirdek fonksiyonun ortalamasında ve rand indeksinde de ciddi bir artış olduğu görülmektedir.




Şekil 6.22. Kullanılan test verisinin a) 3 boyutlu dağılımı b)iki boyutlu dağılımı

Doğrusal çekirdek fonksiyonu seçilerek 140 test verisinin 136'sı ağın performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 4 tanesi ise programa yeni girilecek veriler hakkında yorum yapmak için kullanılmıştır. Sınıflandırma doğruluğu %95.5882 olarak bulunan bir sistem için 100 kişiden yaklaşık 5 tanesinin yanlış sınıflandırılması söz konusudur. Bu aşamada kullanılan 140 tane veriden yaklaşık 7 tanesinin yanlış sınıflandırılması beklenmektedir. Nitekim gerçek ve tahmin sonuçları incelendiğinde 6 kişide hatalı bir sınıflandırma olmuştur. Sisteme sonradan girilen 4 verinin tamamı doğru sınıflandırılmıştır. Şekil 6.23'te bu uygulamaya yönelik elde edilen histogram verilmiştir. Ayrıca modelin başarımının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve özgünlük hata matrisi kullanılarak hesaplanmış ve Tablo 6.15'te listelenmiştir. Hata matrisinde elde edilen sayısal sonuçlar, Şekil 6.23'teki histogramda da gözlenmektedir.

Doğru sınıflandırma başarı oranının yüksek oluşundan ve çekirdek fonksiyonu seçim zorluğunu giderdiğinden dolayı seri TBA-DAA-DVM'ye göre daha iyi bir performans göstermektedir.

Tablo 6.15. Paralel TBA-DAA-DVM modeline ait başarımlar sonuçları

Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
53	5	0.913793	0.981481	0.939024
1	77			




Şekil 6.23. Doğrusal çekirdek fonksiyonu kullanılarak elde edilen histogram

6.7.1.3. Seri KTBA-DAA-DVM Modeli

Önerilen bu model, görüntü verileri gibi KTBA'nın kullanılmasına uygun veri tipleri için KTBA-DVM'ye alternatif başka bir model olarak önerilmiştir. Bu amaçla bu çalışmada iki model önerilmiştir.

Seri KTBA-DAA-DVM modeli ile ham veri iki ayrı KTBA girişine verilecek, farklı boyut seçimleri yapılarak KTBA çıkışları elde edilecektir. Bu iki KTBA çıkışları, ayrı ayrı DAA girişine verilecek ve ayrı ayrı elde edilen bu özellik verileri bir matriste toplanıp, DVM girişine verilecek bir özellik vektörü olacaktır. Şekil 6.24'te algoritmaya ait blok diyagramı, holdout yöntemiyle 3 kez çalıştırılarak ortalaması alınan sayısal sonuçlar da Tablo 6.16'da, ağırlık yapmadığını göstermek amacıyla kullanılan çapraz doğrulama yöntemiyle elde edilen sonuçlar Tablo 6.17'de holdout yöntemine ait sonuçlarıyla birlikte verilmiştir.

Bu programda iki tane KTBA ve bir DVM kullanıldığından dolayı programı çalıştırmak için 3 tane çekirdek fonksiyonu seçimi yapılmalıdır. Farklı kombinasyonlu çekirdek fonksiyonları seçimi ile sonuçlar incelenmiştir. Tablodaki çekirdek fonksiyonu sıralaması KTBA₁, KTBA₂ ve DVM şeklindedir.



Şekil 6.24. Seri KTBA-DAA-DVM algoritma yapısı

Tablo 6.16. Seri KTBA-DAA-DVM yapısına ait ortalama sonuçlar

Çekirdek Fonksiyonu	Seri KTBA-DAA-DVM		
Ortalama	Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss Gauss Gauss	%95.9524	44s	0.921925
Gauss Polinomial Gauss	%95.4762	26.3s	0.913155
Gauss Polinomial Polinomial	%79.2857	33.6s	0.669647
Polinomial Gauss Gauss	%95.28572	49.6s	0.891675
Polinomial Polinomial Gauss	%96.1905	44s	0.9263446
Polinomial Gauss Polinomial	%56.9047	30s	0.506306
Polinomial Polinomial Polinomial	%59.0476	26.3s	0.516547
Gauss Doğrusal Gauss	%95.4762	49.6s	0.913018
Gauss Doğrusal Doğrusal	%94.2857	44.3s	0.891538
Doğrusal Gauss Gauss	%96.666	43s	0.93566
Doğrusal Doğrusal Gauss	%94.999	47s	0.905207
Doğrusal Gauss Doğrusal	%95	41.7s	0.90452
Doğrusal Doğrusal Doğrusal	%95.09	36.3s	0.904796
Gauss Doğrusal Polinomial	%73.809	42s	0.614183
Gauss Polinomial Doğrusal	%95	43s	0.90452
Polinomial Doğrusal Gauss	%95	39s	0.90438

Polinomial Gauss Doğrusal	%95.4762	35.6s	0.91315
Doğrusal Gauss Polinomial	%70.809	35.3s	0.59739
Doğrusal Polinomial Gauss	%97.1429	43.7s	0.94457

Tablo 6.17. Seri KTBA-DAA-DVM yapısına ait çapraz doğrulama ve holdout sonuçları

Çekirdek Fonksiyonu	Kullanılan Yöntem	Seri KTBA-DAA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss Gauss Gauss	Holdout	%95.9524	44s	0.921925
	Çapraz Doğrulama	%95	29.7s	0.90748775
Gauss Polinomial Gauss	Holdout	%95.4762	26.3s	0.913155
	Çapraz Doğrulama	%95.2849	22.3s	0.912496
Polinomial Gauss Gauss	Holdout	%95.28572	49.6s	0.891675
	Çapraz Doğrulama	%94.570625	33.8s	0.900661875
Polinomial Polinomial Gauss	Holdout	%96.1905	44s	0.9263446
	Çapraz Doğrulama	%94.8563	35.2s	0.90504125
Gauss Doğrusal Gauss	Holdout	%95.4762	49.6s	0.913018
	Çapraz Doğrulama	%94.856325	39.8s	0.904253
Doğrusal Gauss Gauss	Holdout	%96.666	43s	0.93566
	Çapraz Doğrulama	%94.5706	38.8s	0.899754
Doğrusal Doğrusal Gauss	Holdout	%94.999	47s	0.905207
	Çapraz Doğrulama	%94.856325	35.3s	0.90461425
Polinomial Doğrusal Gauss	Holdout	%95	39s	0.90438
	Çapraz Doğrulama	%95.42775	12.2s	0.91410525
Doğrusal Polinomial Gauss	Holdout	%97.1429	43.7s	0.94457
	Çapraz Doğrulama	%94.999175	34.8s	0.90727425
Gauss Gauss Polinomial	Holdout	%84.2857	11.8s	0.733196
	Çapraz Doğrulama	%76.83745	21.2s	0.65826575
Polinomial Gauss Doğrusal	Holdout	%95.4762	35.6s	0.91315
	Çapraz Doğrulama	%94.428575	32.8s	0.89832375


Elde edilen sonuçlar, KTBA-DVM ile elde edilen sonuçlarla karşılaştırıldığında DVM'nin Gauss ve doğrusal çekirdek fonksiyonu olduğu durumlar için hemen hemen aynı sonuçlar verdiği, KTBA'lardan da en az birinin polinomial çekirdek fonksiyonu olduğu durum için ise KTBA-DVM'ye göre iyileştirme olduğu görülmektedir. Bu çekirdek fonksiyonların performanslarını artırmak için bu modele alternatif paralel KTBA-DAA-DVM modeli önerilmiştir.

KTBA₁ için polinomial, KTBA₂ için polinomial ve DVM için Gauss çekirdek fonksiyonu seçilerek çalıştırılan programda, 140 test verisinin 136'sı ağır performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 4 tanesi ise programa yeni

girilecek veriler hakkında yorum yapmak için kullanılmıştır. Sınıflandırma doğruluğu %95.5882 olarak bulunan bir sistem için 100 kişiden yaklaşık 5 tanesinin yanlış sınıflandırılması söz konusudur. Bu aşamada kullanılan 140 tane veriden yaklaşık 7 tanesinin yanlış sınıflandırılması beklenmektedir. Nitekim gerçek ve tahmin sonuçları incelendiğinde 6 kişide hatalı bir sınıflandırma olmuştur. Sisteme sonradan girilen 4 verinin tamamı doğru sınıflandırılmıştır. Ayrıca modelin başarımının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve özgünlük hata matrisi kullanılarak hesaplanmış ve Tablo 6.18’de listelenmiştir. Şekil 6.25’te bu uygulamaya yönelik elde edilen histogram, Şekil 6.26’da ise programa ait LabVIEW’de oluşturulan blok şeması verilmiştir.

Tablo 6.18. Seri KTBA-DAA-DVM modeline ait başarımlar sonuçları


Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
53	5	0.913793	0.981481	0.939024
1	77			



Şekil 6.25. Seri KTBA-DAA-DVM modeli histogramı

Hata matrisinde elde edilen sayısal sonuçlar, histogramda da gözlenmektedir.

6.28’de programa ait LabVIEW’de oluşturulan blok şeması ve elde edilen sonuçlar da Tablo 6.19’da verilmiştir.




Şekil 6.27. Paralel KTBA-DAA-DVM algoritma yapısı

Bu programda bir tane KTBA ve bir DVM kullanıldığından dolayı programı çalıştırmak için 2 tane çekirdek fonksiyonu seçimi yapılmalıdır. Farklı kombinasyonlu çekirdek fonksiyonları seçimi ile sonuçlar incelenmiştir. Tablodaki çekirdek fonksiyonu seçim sıralaması KTBA ve DVM şeklindedir.

Tablo 6.19. Paralel KTBA-DAA-DVM modeline ait sayısal sonuçlar

Çekirdek Fonksiyonu	Kullanılan Yöntem	Paralel KTBA-DAA-DVM		
		Sınıflandırma Doğruluğu	Süre	Rand İndeksi
Gauss Gauss	Holdout	%96	27.8s	0.92308
	Çapraz Doğrulama	%94.9992	29.3s	0.90720875
Gauss Polinomial	Holdout	%95.5714	29.6s	0.9147586
	Çapraz Doğrulama	%95	17.4s	0.91087025
Polinomial Gauss	Holdout	%96.57144	39s	0.9339772
	Çapraz Doğrulama	%93.85635	25.9s	0.889639
Polinomial Polinomial	Holdout	%91.42856	13.8s	0.8879136
	Çapraz Doğrulama	%91.857125	15.7s	0.863284
Gauss Doğrusal	Holdout	%96.28574	31.4s	0.9281808
	Çapraz Doğrulama	%94.9992	18s	0.90720875
Doğrusal Gauss	Holdout	%96.28574	39s	0.9287154
	Çapraz Doğrulama	%95.14205	27.5s	0.90947475
Doğrusal Doğrusal	Holdout	%95.62172	34.6s	0.909579
	Çapraz Doğrulama	%95.0035075	32.3s	0.90720875
Polinomial Doğrusal	Holdout	%93.57144	29.2s	0.8793614
	Çapraz Doğrulama	%94.142875	23.7s	0.89513975
Doğrusal Polinomial	Holdout	%92.85716	16.8s	0.8670506
	Çapraz Doğrulama	%94	25.1s	0.89264375



Şekil 6.28. Paralel KTBA-DAA-DVM modeline ait LabVIEW blok şeması

Elde edilen sonuçlar, seri KTBA-DAA-DVM ile elde edilen sonuçlarla karşılaştırıldığında DVM'nin Polinomiyal çekirdek fonksiyonu olduğu durum için iyileştirme olduğu görülmektedir. KTBA için Gauss ve DVM için Gauss çekirdek fonksiyonu seçilerek çalıştırılan programda, 140 test verisinin 136'sı ağın performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 4 tanesi ise programa yeni

girilecek veriler hakkında yorum yapmak için kullanılmıştır. Sınıflandırma doğruluğu % 94.8529 olarak bulunan sistem için 100 kişiden yaklaşık 6 tanesinin yanlış sınıflandırılması söz konusudur. Bu aşamada kullanılan 140 tane veriden yaklaşık 8 tanesinin yanlış sınıflandırılması beklenmektedir. Nitekim gerçek ve tahmin sonuçları incelendiğinde 7 kişide hatalı bir sınıflandırma olmuştur. Sisteme sonradan girilen 4 verinin tamamı doğru sınıflandırılmıştır. Ayrıca modelin başarımının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve özgünlük hata matrisi kullanılarak hesaplanmış ve Tablo 6.20’de listelenmiştir.

Tablo 6.20. Paralel KTBA-DAA-DVM modeline ait başarımlar sonuçları

Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
38	4	0.904761	0.926829	0.957894
3	91			

6.7.2. EEG İşaretlerinin MÖ Algoritmaları ile Sınıflandırılması

Ham veriden bazı özelliklerin çıkarılması ve işlem süresinin kısaltılması için boyut azaltma algoritmalarının yanı sıra her bir veri kümesinin maksimum, minimum, ortalama, varyans, standart sapma ve basıklık gibi istatistiksel değerleri ile de yeni özellikli veri elde edilebilir. Uygulamada kullanılan ham EEG verileri [146] veritabanından alınmıştır. Veri 200×4097 boyutunda sağlam ve 200×4097 boyutunda hasta kişilere aittir. Verilerden özellik çıkarmak için her bir veri kümesinin maksimum, minimum, ortalama, varyans, standart sapma ve basıklık değerleri elde edilmiş ve veriler 200×6 sağlıklı ve 200×6 hasta olmak üzere 400×6 boyutuna düşürülmüştür. Boyutu düşürülen EEG verilerinin, önerilen modeller için elde edilen sınıflandırma sonuçlarının ortalama değerleri Tablo 6.21’de verilmiştir.

Tablo 6.21. Önerilen TBA-DAA-DVM seri-paralel modellerine ait sınıflandırma sonuçları

TBA-DAA-DVM Modeli							
Seri				Paralel			
DVM	Sınıflandırma Doğruluğu	Süre (s)	Rand İndeksi	DVM	Sınıflandırma Doğruluğu	Süre (s)	Rand İndeksi
Gauss	%100	9.9206	1	Gauss	%100	1.559	1
Doğrusal	%97.917	8.0108	0.958966	Doğrusal	%99	7.616	0.9874
Polinomial	%88.75	6.606	0.797785	Polinomial	%99	7.539	0.9874

Seri TBA-DAA-DVM modelinde DVM'nin Gauss ve Doğrusal çekirdek fonksiyonu olduğu durumlar için oldukça iyi sonuçlar alınmıştır. Polinomial çekirdek fonksiyonu seçilerek çalıştırılan programda, 80 test verisinin 60'ı ağın performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 20 tanesi ise programa yeni girilecek veriler hakkında yorum yapmak için kullanılmıştır. Seri TBA-DAA-DVM modeli için bir kez çalıştırılan program %88.3333'lük sınıflandırma doğruluğu elde edilmiştir. Bu da 100 kişiden yaklaşık 12 verinin tane yanlış sınıflandırmasına karşılık gelmektedir. Bu aşamada kullanılan 80 tane veriden yaklaşık 10 tanesinin yanlış sınıflandırılması beklenmektedir. Nitekim gerçek ve tahmin sonuçları incelendiğinde toplam 9 kişide hatalı bir sınıflandırma olmuştur. Sisteme sonradan girilen 20 verinin 18 tanesi doğru sınıflandırılmıştır. Ayrıca modelin başarımının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve özgünlük hata matrisi kullanılarak hesaplanmış ve Tablo 6.22'de listelenmiştir.

Tablo 6.22. EEG verilerine ait seri TBA-DAA-DVM modeli için başarımlar sonuçları

Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
31	2	0.939393	0.861111	0.916666
5	22			

Paralel TBA-DAA-DVM modelinde ise Doğrusal çekirdek fonksiyonu seçilerek çalıştırılan programda, 80 test verisinin 60'ı ağın performansını ölçmek için, eğitim ve test aşamasında hiç kullanılmayan 20 tanesi ise programa yeni girilecek veriler hakkında yorum yapmak için kullanılmıştır. Bu model için bir kez çalıştırılan programda %100'lük sınıflandırma doğruluğu elde edilmiştir. Bu da tüm verilerin doğru sınıflandırıldığı anlamına gelmektedir. Ayrıca modelin başarımının değerlendirilmesi için doğruluk, kesinlik, duyarlılık ve özgünlük hata matrisi kullanılarak hesaplanmış ve Tablo 6.23'te listelenmiştir.

Tablo 6.23. EEG verilerine ait paralel TBA-DAA-DVM modeli için başarımlar sonuçları

Hata matrisi		Kesinlik	Duyarlılık	Özgünlük
32	0	1	1	1
0	28			

6.7.3. EK Uygulamalar

Bu tez çalışmasında MÖ algoritmaları ile veri sınıflandırılması haricinde LabVIEW’de EKG işaretlerinden kalp atım hızı tespiti, kan basıncı verilerinden tansiyon tespiti yapılmıştır.


6.7.3.1. EKG İşaretlerinden Kalp Atış Hızı Tespiti

Bu çalışmada EKG işaretlerinden kalp atım hızı tespit edilmiştir. Kalp atım hızı tespiti için iki farklı işaret kullanılmış olup, bu veriler LabVIEW’in kendi veri tabanından alınmıştır. Kullanılan LabVIEW blok şeması Şekil 6.29’da verilmiştir. Veriler iki farklı duruma ait olup, Tablo 6.24’te standart değerler ve bu çalışmada bulunan sonuçlar listelenmiştir. Kalp atış hızının tespitinin yanı sıra PQRS eğrisindeki her bir aralık ve her bir segment arası göz önüne alınarak kişinin bir rahatsızlığı olup olmadığı hakkında yorum yapılabilmektedir [147].

Tablo 6.24. EKG Kalp Atım Hızı (bpm)

Durum	EKG Kalp Atım Hızı (bpm)	
	Genel	Bulunan Sonuçlar
Normal	60-100	77.8
Taşikardi	> 100	114.2

Bulunan sonuçlardan 77.8 bpm ile ilk verinin normal bir EKG’ye sahip olduğu, 114.2 bpm ile ikinci verinin ise kalbin atım sayısının artarak normal değerlerin üzerine çıkmasını ifade eden taşikardi olarak ifade edilebilir. Tam anlamıyla doğru bir yorum için ise hekim deneyimine ihtiyaç olmaktadır.



Şekil 6.29. LabVIEW Kalp atım hızı tespit şeması

6.7.3.2. Kan Basıncı Verilerinden Kan Basıncı Tespiti

Bu çalışmada LabVIEW ortamından alınan üç farklı kan basıncı verisi kullanılarak kan basıncının değerleri tespit edilmiştir. Tespit edilen bu değerler Dünya Sağlık Örgütü Uluslararası Hipertansiyon Komitesinin yayınladığı standartlara göre karşılaştırılmış ve yorumlanmıştır. Bu standartlar Tablo 6.25'te, bulunan değerler ise tablo 6.26'da listelenmiştir. Kullanılan LabVIEW blok şeması Şekil 6.30'de verilmiştir [32].


Tablo 6.25. Dünya Sağlık Örgütü Uluslararası Hipertansiyon Komitesi kan basıncı standartları

Kategori	Sistolik basınç, mmHg	Diyastolik basınç, mmHg
Hipotansiyon	< 90	< 60
Normal	< 130	< 85
Optimal	< 120	< 80
Prehipertansiyon	130-139	85-89
Evre 1 hipertansiyon	140- 159	90-99
Evre 2 hipertansiyon	160-169	100-109

Tablo 6.26. Elde edilen kan basıncı değerleri

Kategori	Sistolik Basıncı, mmHg	Diyastolik Basıncı, mmHg
veri_1	131	86
veri_2	122	72
veri_3	107	64

Elde edilen sonuçlar, standart değerlerle karşılaştırıldığında veri_1 prehipertansiyon, veri_2 normal ve veri_3 optimal kan basıncına sahiptir.



Şekil 6.30. Kan basıncı LabVIEW blok şeması

7. SONUÇLAR VE GELECEK ÇALIŞMALAR

7.1. Sonuçlar

Bu tez çalışmasında, bir biyomedikal işaretin grafiksel programlama temelli LabVIEW ortamında akıllı hesaplama yöntemleri kullanılarak işlenmesiyle; kişinin sağlıklı-hasta seçiminin yapılabilmesi için hekimlere daha hızlı yorum yapma imkânı sağlamak, hastalara daha etkili ve ucuz bir teşhis-tedavi imkânı sunmak amaçlanmıştır. Bu amaçla; EEG ve göğüs kanseri verileri için boyut azaltma algoritmalarıyla (TBA, DAA, KTBA) verilerden özellik seçiminin yapılması ve elde edilen yeni özellikli verilerin DVM ile sınıflandırılması LabVIEW ortamında gerçekleştirilmiştir.

Tezin ilk kısmında, göğüs kanseri verileri için LabVIEW'in çalışma performansı MATLAB ile karşılaştırılmıştır. TBA, DAA ve KTBA ile LabVIEW ortamında boyutları azaltılan veriler holdout yöntemi kullanılarak veri, eğitim ve test verilerine ayrılmıştır. Elde edilen bu veriler, hem LabVIEW hem de MATLAB ortamında DVM ile sınıflandırılmıştır. Sınıflandırma performansları her iki programlama dili için de yaklaşık olarak aynı oranda çıkmıştır. Bu durum, kullanımı gittikçe yaygınlaşan LabVIEW programlama dilinin tercih edilebileceğini göstermiştir. Ayrıca, LabVIEW'in hızlı ve kolay programlanabilir bir yapıya sahip olması, önerilen modellerin daha önce LabVIEW ortamında yapılmamış olması nedeniyle de tez çalışmasında LabVIEW programlama dili kullanılmıştır.

MATLAB ile karşılaştırılarak performans analizi yapılan LabVIEW'de, TBA-DVM, DAA-DVM ve KTBA-DVM yapıları için göğüs kanseri verileri kullanılarak her bir program beşer kez çalıştırılmış ve sınıflandırma doğruluklarının ortalamaları alınmıştır. DVM'de polinomial çekirdek fonksiyonunun kullanıldığı durum için elde edilen ortalama sonuçların diğerlerine göre düşük çıkması, bu sonuçları iyileştirmeye yönelik modellerin önerilmesi ihtiyacını gerektirmiştir. Bu nedenle; seri TBA-DAA-DVM, paralel TBA-DAA-DVM, seri KTBA-DAA-DVM, paralel KTBA-DAA-DVM modelleri önerilmiştir. DVM'de Gauss ve Doğrusal çekirdek fonksiyonunun kullanımı, önerilen seri ve paralel modellerin sınıflandırma performansında TBA-DVM ve KTBA-DVM'ye göre iyileştirme sağlamıştır. Polinomial çekirdek fonksiyonunun kullanımıyla paralel modellerin, önerilen seri TBA-DAA-DVM ve seri KTBA-DAA-DVM modellerine göre daha iyi sonuç verdiği

görülmüştür. Böylece çekirdek fonksiyonu seçim zorluğu giderilmiş, çekirdek fonksiyonuna bağlı kalmadan kullanılan verilerin sınıflandırma performansları artırılmıştır. Ayrıca, geliştirilen sistemin doğruluğunu test etmek ve modellerin ezber bir eğitim yapmadığını göstermek amacıyla, eğitim verileri için hem holdout hem de çapraz doğrulama yöntemleri kullanılarak sınıflandırma performansları incelenmiştir. Elde edilen sonuçların yakın çıkması, geliştirilen sistemin ezber bir eğitim yapmadığını göstermektedir.

Göğüs kanseri verileri kullanılan modellerin başarımını değerlendirmek için doğru tahminlerin toplam sayısının bir ölçüsü olan doğruluk dışında, hasta vakaları belirleyen duyarlılık, sağlıklı vakaları belirleyen özgünlük, gerçek ile tahmini sınıflandırma oranlarının bir ölçüsü olan hata matrisi ve gruplar arası benzerliğin bir ölçüsü olan rand indeksi ölçütleri kullanılmıştır. Önerilen her bir model için sınıflandırma performansları elde edildikten sonra eğitim-test aşamasında hiç kullanılmamış bir veri girilerek, verinin hasta-sağlıklı ayrımı yapılmıştır. Böylece sistem, yeni gelecek bir verinin hasta-sağlıklı tahminin yapabilecek duruma gelmiştir.

Tezin ikinci kısmında EEG verileri kullanılarak sağlıklı-epilepsi tespiti yapılmaya çalışılmıştır. Önerilen seri TBA-DAA-DVM ve paralel TBA-DAA-DVM modelinde, DVM'nin tez çalışmasında kullanılan tüm çekirdek fonksiyonları için başarılı sonuçlar elde edilmiştir. Ayrıca, Polinomial çekirdek fonksiyonu, paralel modelde seri modele göre daha başarılı performans göstermiştir. Sonuç olarak, paralel modelde hangi çekirdek fonksiyonu kullanılırsa kullanılsın başarı oranı oldukça yüksek çıkmıştır. Modelin başarımını değerlendirmek için doğruluk dışında, duyarlılık, özgünlük ve hata matrisi ölçütleri bu veriler için de kullanılmıştır.

Bu tezde ayrıca, EEG ve göğüs kanseri verilerinin sınıflandırılması dışında EKG verilerinden kalp atım hızı tespiti ve kan basıncı verilerinden ise tansiyon tespiti yapılmıştır. EKG verilerinden elde edilen sonuçlar Amerikan Kalp Derneği standartlarına göre değerlendirilmiştir. 60-100 bpm kalp atım hızı normal olarak kabul edilmektedir. Kullanılan EKG verilerinin bir tanesi 77.8 bpm atış hızı ile normal diğeri ise 114.2 bpm atış hızıyla taşikardi grubunda yer almaktadır. Kan basıncı verileri için elde edilen sonuçlar ise Dünya Sağlık Örgütü Uluslararası Hipertansiyon Komitesi standartlarına göre yorumlanmıştır. Elde edilen sonuçlar standart değerlerle karşılaştırıldığında kullanılan veri_1 131/86 mmHg ile prehipertansiyon, veri_2 122/72 mmHg ile normal, veri_3 107/64

mmHg ile optimal kan basıncına sahiptir. Böylece grafiksel programlama dili kullanılarak hızlı ve kolay bir şekilde kalp atış hızı ve kan basıncının ile tespit edilebilmektedir.

Bu tez çalışmasıyla, herhangi bir biyomedikal işarete (Elektroensefalografi-EEG, göğüs kanseri) ait verinin sağlıklı-hasta ayrımının yapılması ve sınıflandırılması için kolay ve etkili bir yöntem, farklı bir programlama diliyle sunulmuştur. Ancak, tez çalışmasında önerilen modellerden elde edilen sonuçlara bakılarak hasta-sağlıklı ayrımı yapılmasına ilave olarak, hekimlerin deneyim ve tecrübeleri de dikkate alınarak verilerin yorumlanması daha doğru ve sağlıklı olacaktır. Önerilen modellerden elde edilecek sonuçların hekimlere yorum yapmada hız kazandıracağı, hastalara ise etkili ve ucuz bir teşhis-tedavi imkânı sağlayacağı düşünülmektedir.

Sonuç olarak, tez çalışmasında yapılan yenilikler aşağıdaki gibi kısaca özetlenebilir:

- MÖ algoritmalarının, yeni bir programla dili olan LabVIEW ortamında gerçekleştirilmesi,
- Kullanılacak çekirdek fonksiyonundan bağımsız iyi sınıflandırma sonucu verecek farklı seri ve paralel modellerin önerilmesi,
- Önerilen modellere yeni bir veri girişi olduğu zaman, verinin hasta kişiye mi yoksa sağlam kişiye mi ait olduğu hakkında seçim yapılabilecek sonuçların elde edilmesi,
- LabVIEW ortamında gerçekleştirilen modeller ile hekimlere yorum yapmada hız kazandıracağı, hastalara ise etkili ve ucuz bir teşhis-tedavi imkânı sağlayacağı söylenebilir.

Bu tez kapsamında, LabVIEW ortamında gerçekleştirilen algoritmalar ve yeni bir veri için elde edilecek durum tespiti literatüre yenilikçi bir katkı sağlamıştır.

7.2. Gelecek Çalışmalar

Yapılan tez çalışması için, gelecekte zamanlarda yapılabilecek çeşitli araştırma ve iyileştirme alanları aşağıda maddeler halinde verilmiştir:

- Son zamanlarda yaygın olarak kullanılan ve pek çok farklı problemin çözümünde başarılı sonuçlar veren, farklı sezgisel optimizasyon yöntemleri (Yapay Arı Koloni Algoritması, Genetik Algoritma, Parçacık Sürü Optimizasyonu ve bunların kendi aralarında yapacakları hibrit algoritmalar) ile çekirdek fonksiyonlarının parametrelerinin tespit edilmesi sağlanabilir,

- Literatürde ve tez çalışmasında kullanılan Gauss, doğrusal, polinomial çekirdek fonksiyonu dışında yeni bir çekirdek fonksiyonu geliştirilebilir,
- Çekirdek fonksiyonlarından ve parametrelerinden bağımsız olarak tüm veri tipleri için iyi sonuçlar verebilen farklı hibrit modeller geliştirilebilir.



8. KAYNAKLAR

- [1] **Mallat, S.**, 1989. A theory for multiresolution signal decomposition: The wavelet representation, *IEEE Trans. Pattern Anal. Mach. Intell.*, 11(7), pp.674–693.
- [2] **Proakis, J.G., and Manolakis, D.G.**, 2010. “Sayısal Sinyal İşleme İlkeler, Algoritmalar ve Uygulamalar”, Eylül.
- [3] **Levkov, C., Mihov, G., Ivanov, R., Daskalov I., Christov, I. and Dotsinsky, I.**, 2005. Removal of power-line interference from the ECG: a review of the subtraction procedure, *BioMedical Engineering OnLine*, **4**, 1–8.
- [4] **Thakor, N.V., and Zhu, Y.S.**, 1991. Applications of adaptive filtering to ECG analysis: Noise cancellation and arrhythmia detection, *IEEE Transactions on Biomedical Engineering*, **38**, 785–794.
- [5] **Gholam-Hosseini, H., Nazeran, H., and Reynolds, K.J.**, 1998. ECG noise cancellation using digital filters, in *Proceedings of International Conference on Bioelectromagnetism*, (Melbourne, Australia), 151–152.
- [6] **Philips, W.**, 1996. Adaptive noise removal from biomedical signals using warped polynomials, *IEEE Transactions on Biomedical Engineering*, **43**, 480–492.
- [7] **Clancy, E.A., Morin, E.L. and Merletti, R.**, 2002. Sampling, noise-reduction and amplitude estimation issues in surface electromyography, *Journal of Electromyography and Kinesiology*, **12**, 1–16.
- [8] **Chang, H.H., and Moura, J.M.F.**, 2010. Biomedical Signal Processing, ed. Myer Kutz, in *Biomedical Engineering and Design Handbook, 2nd Edition, Volume 1*, McGraw Hill. Chapter 22, pp. 559-579.
- [9] **Ramaswamy, P., Guptu, C.N., Luk C.K. and Krishnan, S.M.**, 2004. Multi-Parameter Detection Of Ectopic Heart Beats, *Proceedings of Biomedical Circuits and Systems, 2004 IEEE International Workshop on*, p:-1-4.
- [10] **Mallat, S.**, 1998. A Wavelet Tour of Signal Processing. San Diego, CA: Academic.
- [11] **Coifman, R., Meyer, Y. and Wickerhauser, V.**, 1991. Wavelet Analysis and Signal Processing In Wavelets and Their Applications, Ruskai Jones and Bartlet Publishers.
- [12] **Meyer, Y.**, Wavelets, Algorithms and Applications, SIAM, 1993.
- [13] **Akin, M.**, 2002, Comparison of wavelet transform and FFT methods in the analysis of EEG signals, *Journal of Medical Systems*, 26 (2002), pp. 241-247.

- [14] **Gopinath, R.A., Odegard, J.E., and Burrus C.S.**, 1994. "Optimal wavelet representation of signals and the wavelet sampling theorem," *IEEE Trans. Circuits Syst. II*, vol. 41, no. 4, pp. 262–277, Apr.
- [15] **Vatansever, F., Uysal, F. ve Uzun A.**, 2002. Ayırık Dalgacık Dönüşümü ile Gürültü Süzme, Elektrik-Elektronik-Bilgisayar Mühendisliği Sempozyumu, 18-22 Aralık, Bursa.
- [16] **Jun-Hai, Z. and Su-Fang, Z.**, 2005. Image Denoising Via Wavelet Threshold Single Wavelet And Multiple Wavelets Transform, *International Conference on Machine Learning and Cybernetics*, 5, 3232 – 3236.
- [17] **Graphs, A.**, 1995. An Intruduction to Wavelets, Official Scientific for Engineering Applications, *Macintosh Conference, Worcester, Mass.*
- [18] **Besar, R., Eswaran, C., Sahib, S., and Simpson, R.J.**, 2000. On the Choice of The Wavelets For ECG Data Compression, Acoustics, Speech, and Signal Processing, 2000. ICASSP '00. Proceedings. 2000 IEEE International Conference on 5-9 June 2000, İstanbul/Turkey.
- [19] **Yilmaz, Z., ve Bozkurt, M.R.**, 2013. Ayırık Dalgacık Dönüşümü Kullanarak Aritmilere Ait Özniteliklerin Çıkarılması, *XIV. Akademik Bilişim Konferansı..*
- [20] **Shaker, M.M.**, 2007. EEG Waves Classifier using Wavelet Transform and Fourier Transform, *Journal of Medical, Pharmaceutical Science and Engineering*,1/3.
- [21] **Akay, M.**, 1997 Wavelet applications in medicine. *IEEE Spectrum*, Vol.34, May .pp. 50-56.
- [22] **Kaya, D., ve Turk, M.**, 2017. Biyoelektriksel Kökenli İşaretlerde Rahatsızlık Teşhisinin Yorumlanması, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 29, Sayı 1.
- [23] **Hamzaçelebi, C.**, Yapay Sinir Ağları, Ekim 2011.
- [24] **Elmas, Ç.**, 2003. Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, Ankara.
- [25] **Nilsson, N. J.**, 1998. Introduction to Machine Learning, An Early Draft Of A Proposed Textbook.
- [26] **Kehtarnavaz, N. and Mahotra, S.**, "Digital Signal Processing Laboratory: LabVIEW-Based FPGA Implementation", pp.7.
- [27] **Majdalawieh, O., Gu, J., Bai, T. and Cheng, G.**, 2003. Biomedical signal processing and rehabilitation engineering: A review, in *Proceedings of IEEE Pacific Rim Conference on Communications, Computers and Signal Processing*, (Victoria, Canada), pp. 1004–1007.

- [28] **Sazli, M.H.**, Simüle Kompleks Aritmik EKG Sinyallerinin Kapalı Logografik Rektonlar ve Yeni Temel Lokalizasyon Yöntemleri ile Değerlendirilmeleri ve Bazı Uygulamaları. Ankara Üniversitesi, Fen. Bil. Ens. Elektronik Müh. ABD, Yüksek Lisan tezi, 111s.
- [29] **Lopes da Silva, F.H., and Niedermeyer, E.**,1993.Electroencephalography: Basic principles, clinical applications and related fields, 3rd ed., Lippincott, Ed. Philadelphia, USA: Williams & Wilkins,
- [30] **Chen, J., Schirmer, B.D., and McCallum, R.W.**, 1994. “Serosal and cutaneous recordings of gastric myoelectrical activity in patients with gastroparesis,” Amer. J. Physiol., vol. 266, pp. G90–G98.
- [31] **Cruz, J.A, and Wishart, D.S.**, 2006. Applications of machine learning in cancer prediction and prognosis. Cancer Informat;2:59
- [32] **Kaya, D., Turk, M., and Kaya, T.**, 2017. Neural Network Based Noninvasive Blood Pressure Classification, International Advanced Researches and Engineering Congress, IAREC’2017, November, 16-18, Osmaniye, Turkey.
- [33] **Sazli, M.H.**, 2007. EKG Sinyallerinin Korelasyon Analizi ile Bazı Kalp Aritmilerinin Belirlenmesi, *KSÜ Fen ve Mühendislik Dergisi*, 10(1).
- [34] Vikipedi, Elektrokardiyografi, <http://tr.wikipedia.org/wiki/Elektrokardiyografi>.
- [35] **Çankaya, O.**, Elektrokardiyografi, <http://www.baskent.edu.tr/~bmeweb/20393429.htm>
- [36] **Hanbay, D.**, 2009. An expert system based on least square support vector machines for diagnosis of the valvular heart disease, *Expert Systems with Applications* 36, 4232–4238.
- [37] **Akay, M., Akay, Y.M., and Welkowitz, W.**, 1992. Neural networks for the diagnosis of coronary artery disease, *International Joint Conference on Neural Networks, IJCNN*, 2, pp. 419-424.
- [38] **Golschlager, M.D., and Goldman, M.J.**, 1989. Principles of clinical electrocardiography. Appleton & Lange, USA, 356s.
- [39] **Efeoğlu, M.**, Acil Tıp Eğitimi İçin EKG, EKG Kütüphanesi Sayfası
- [40] **Çekik, R., ve Telçeke, S.**, 2014. EKG Sinyallerinin Kaba Kümeler Teorisi Kullanılarak Sınıflandırılması, *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi A-Uygulamalı Bilimler ve Mühendislik*, Cilt: 15 Sayı:2, Sayfa: 125 – 135.
- [41] **Koçyiğit, Y.**, 2016. Heart sound signal classification using fast independent component analysis, *Turkish Journal of Electrical Engineering & Computer Sciences*, 24: 2949 – 2960.

- [42] **Kocyyigit, Y, Alkan, A, and Erol H., 2008.** Classification of EEG recordings by using fast independent component analysis and artificial neural network, *Journal of Medical Systems February, Volume 32, Issue 1, pp 17–20*
- [43] **Chia-Ping, S., Chih-Chuan, C., Sheau-Ling, H., Wei-Hsin, C., Jia-Ming, C., Chih-Min, C., Feipei, L., and Ming-Jang, C., 2013.** High-Performance Seizure Detection System Using a Wavelet-Approximate Entropy-fSVM Cascade With Clinical Validation, *Clinical EEG and Neuroscience, 44(4) 247-256.*
- [44] **Türk, Ö., ve Özerdem, M. S., 2014.** EEG İşaretlerinin k-NN ile Sınıflandırmasında Dalgacıklara İlişkin Performansların Karşılaştırılması, Tıp Teknolojileri Ulusal Kongresi 25-27 Eylül 2014, Kapadokya.
- [45] **Siuly, Yan, L., and Peng, (Paul) W., 2011.** Clustering technique-based least square support vector machine for EEG signal classification, *Computer Methods and Programs in Biomedicine Volume 104, Issue 3, December, Pages 358-372.*
- [46] **Adeli, H., Zhou, Z., and Dadmehr, N., 2003.** Analysis Of EEG Records In An Epileptic Patient Using Wavelet Transform, *J. Neurosci. Methods, 123 (1), pp. 69-87.*
- [47] **Easwaramoorthy, D. and Uthayakumar, R., 2010.** Analysis of Biomedical EEG Signals Using Wavelet Transform and Multifractal Analysis, *Communication Control and Computing Technologies (ICCCCT) IEEE International Conference.*
- [48] **Siddiqi, A.H., Sevindir, H.K., Yazıcı, C., Kutlu, A. and Aslan, Z., 2010.** Spectral Analysis of EEG Signals by Using Wavelet and Harmonic Transforms, *The Fifth International Symposium on Wavelets Applications to World Problems.*
- [49] **Polat, H., ve Özerdem, M. S., 2014.** Dalgacık Katsayıları ve Yapay Sinir Ağları Kullanılarak EEG İşaretlerinin Sınıflandırılması, Tıp Teknolojileri Ulusal Kongresi 25-27 Eylül 2014, Kapadokya.
- [50] **Tekin, R., Kaya, Y., ve Tağluk, M.E., 2011.** K-means ve YSA temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması, Elektrik-Elektronik- Bilgisayar Sempozyumu 2011, Elazığ.
- [51] **Guo, L., Rivero, D., and Pazos, A., 2010.**"Epileptic Seizure Detection Using Multiwavelet Transform Based Approximate Entropy And Artificial Neural Networks", *Journal Of Neuroscience Method, 193.,156-163.*
- [52] **Fisher, R.S, van Emde Boas, W., and Blume, W.,. 2005.** Epileptic seizures and epilepsy: definitions proposed by the international league against epilepsy (ILAE) and the international bureau for epilepsy (IBE). *Epilepsia.,46(4):470-472.*

- [53] **Agarwal, R., Gotman, J., Flanagan, D., and Rosenblatt, B.,** 1998. Automatic EEG Analysis Using Long-Term Monitoring In The ICU. *Electroencephalogr Clin. Neurophysiol.* 107 (1), 44–58.
- [54] **Kai, F., Jianfeng, Q., Chai, Y., and Yong, D.,** 2014. Classification Of Seizure Based On The Time-Frequency Image Of EEG Signals Using HHT and SVM, *Biomedical Signal Processing and Control* 13 15–22.
- [55] **Kumar T.S., Kanhangad V., and Pachori R.B.,** 2015. Classification of seizure and seizure-free EEG signals using local binary patterns, *Biomedical Signal Processing and Control, Volume 15, January Pages* 33-40.
- [56] **Mohammed, D., and Yan, L.,** 2016. Complex networks approach for EEG signal sleep stages classification, *Expert Systems with Applications Volume* 63, 30 November, Pages 241-248.
- [57] **Tagluk, M.E., Akin, M., and Sezgin, N.,** 2010. Classification Of Sleep Apnea By Using Wavelet Transform And Artificial Neural Networks, *Expert Systems with Applications Volume* 37, Issue 2, March, pp. 1600-1607.
- [58] **Guzel, S, Kaya, T, and Guler, H.,** 2015. LabVIEW-based analysis of EEG signals in determination of sleep stages. In: Signal processing and communications applications conference (SIU), 23rd, IEEE, pp 799–802.
- [59] **Aydin, S.G., Kaya, T., and Güler, H.,** 2016. “Wavelet-based study of valence–arousal model of emotions on EEG signals with LabVIEW”, *Brain Inform.* 2016 Jun; 3(2): 109–117.
- [60] **Ma, Z., Tan, Z.H, and Guo, J.,** 2016. Feature Selection For Neutral Vector in EEG Signal Classification, *Neurocomputing* 174 ,937–945.
- [61] **Magaudda, A., Laganà, A., Calamuneri, A., Brizzi, T., Scalera, C., Beghi, M., Cornaggia, CM., and Di Rosa G.,** 2016. Validation of A Novel Classification Model Of Psychogenic Non-epileptic Seizures By Video-EEG Analysis And A Machine Learning Approach, *Epilepsy Behav.* Jul;60:197-201.
- [62] **Van der Voort, I.R., Osmanoglou, E., Seybold, M., and Heymann M., I.,** 2003. Electrogastrography as a diagnostic tool for delayed gastric emptying in functional dyspepsia and irritable bowel syndrome. *Neurogastroenterol. Motil.* 15:467–473.
- [63] **Quigley, E.M.,** 1996. “Gastric and small intestinal motility in health and disease,”*Gastroenterol.Clin.NorthAmer.*,vol.25,no.1,pp.113–145,Mar.
- [64] **Bhuvaneswari, P.T.V., Nilamani. S, Praveen K.S, and Prudvi R.G,** 2012, Design of Diagnostic System for Functional Gastrointestinal Disorders, *Fourth*

- [65] **Talley, N.J., Stanghellini, V., and Tytgat, G.N.,** 1999, “Functional Gastrointestinal Disorders”, *ISBN journal for Biomedical Signal Processing*, pp.10-32.
- [66] **Chang, Y.,** 2005. “Electrogastrography: Basic knowledge, recording, processing and its clinical applications. Review”. *J Gastroenterol and Hepatology*. 20, pp 502–16.
- [67] **Chen, J.D.Z., Lin, Z., and McCallum, R.W.,** 2000. Noninvasive Feature-Based Detection of Delayed Gastric Emptying in Humans Using *Neural Network*, *IEEE Transactions On Biomedical Engineering*, Vol. 47, No. 3, March.
- [68] **Chang, F.Y.,** Electrogastrography: basic knowledge, recording, processing and its clinical applications, *J Gastroenterol Hepatol*. 2005 Apr;20(4):502-16.
- [69] **Hubka, P., Rosík, V., Ždiňák, J., Tyšler, M., and Hulín, I.,** 2005. Independent Component Analysis of Electrogastrographic Signal, *Measurement Science Review*, Volume 5, Section 2,
- [70] **Gopu, G., Neelaveni, R. and Porkumaran, K.,** 2008. Investigation of Digestive System Disorders using Electrogastrogram, *Proceeding International conference on Computer and Communication Engineering (ICCCE' 08)*, 2, pp.201–205.
- [71] **Ding, W., Qin, S., Miao, L., Xi, N., Li, H., and Wang, Y.,** 2010. Processing and Analysis of Bio-signals from Human Stomach, *Proceedings of the 2010 IEEE International Conference on Robotics and Biomimetics December 14-18, Tianjin, China*.
- [72] **Gopu, G., Porkumaran, K. and Neelaveni, R.,** 2011. Investigation of Digestive System Disorders with Cutaneous Electrogastrogram (EGG) Signal - An Engineering Approach, *European Journal of Scientific Research*, 53/, 210-221.
- [73] **Tokmakçı, M.,** 2007. Analysis of the Electrogastrogram Using Discrete Wavelet Transform and Statistical Methods to Detect Gastric Dysrhythmia, *J Med Syst* 31:295–302 DOI 10.1007/s10916-007-9069-9
- [74] **Calder, S., Cheng, L., K., and Peng, D.,** 2014. A theoretical analysis of the electrogastrogram (EGG), *Conf Proc IEEE Eng Med Biol Soc.*, 4330–4333. doi:10.1109/EMBC.2014.6944582
- [75] **Çelikzencir, E., Acer, Ç.G., Latifoğlu, F., Sezgin, G.C., ve Yurci, M.A.,** 2015. Gastroözofageal Reflü Hastalığında Noninvaziv Elektrogastrogram Sinyallerinin Tanı da Kullanabilirliğinin Değerlendirilmesi, *Tıp Teknolojileri Ulusal Kongresi, 15-18 Ekim 2015, Muğla*.

- [76] **Akın, A.**, 1998. Noninvasive detection of spike activity of the stomach from cutaneous EGG, *Doktora Tezi* Drexel University.
- [77] **Morello R., Capua, C. D, and Lamonaca F.**, 2013. Diagnosis of Gastric Disorders by Non-invasive Myoelectrical Measurement, *Instrumentation and Measurement Technology Conference (I2MTC), IEEE International*.
- [78] **Akın, A., and Sun, H.H.**, 2002. Non-invasive Gastric Motility Monitor: Fast Electrogastrogram (fEGG), *Physiol Meas.* Aug;23(3):505-19.
- [79] **Gopu, G., Neelaveni, R. and Porkumaran, K.**, 2008. Acquisition And Analysis Of EGG For Digestive System Disorders Using A Novel Approach, 5th *International Conference on Electrical and Computer Engineering ICECE*, 20-22 December, Dhaka, Bangladesh.
- [80] **Kourou, K., Exarchos, T.P., Exarchos, K.P., Karamouzis, M.V., and Fotiadis I.D.**, 2005. Machine learning applications in cancer prognosis and prediction, *Computational and Structural Biotechnology* 13, pp.8-17.
- [81] **Polat, K. and Güneş, S.**, 2007. Breast cancer diagnosis using least square support vector machine, *Digital Signal Processing* 17, 694–701.
- [82] **Torre, L., Bray, F., Siegel, R.L., Ferlay, J., Lortet-Tieulent, J., and Jemal, A.**, 2015. CA Cancer J Clin. Mar;65(2):87-108. doi: 10.3322/caac.21262. Epub 2015 Feb 4.
- [83] **Quinlan, J.R.**, 1996. Improved use of continuous attributes in C4.5, *J. Artif. Intell. Res.* 4 77–90.
- [84] **Ster, B., and Dobnikar, A.**, 1996. Neural networks in medical diagnosis: Comparison with other methods, in: *Proceedings of the International Conference on Engineering Applications of Neural Networks (EANN '96)* , pp. 427–430.
- [85] **Bennet, K.P., and Blue, J.A.**, 1997. A support vector machine approach to decision trees, *Math. Report*, vols. 97–100, Rensselaer Polytechnic Institute.
- [86] **Nauck, D., and Kruse, R.**, 1999. Obtaining interpretable fuzzy classification rules from medical data, *Artific. Intell. Med.* Vol.(16),pp. 149–169.
- [87] **Goodman, D.E., Boggess, L., and Watkins, A.**, 2002. Artificial immune system classification of multiple-class problems, in: *Proceedings of the Artificial Neural Networks in Engineering ANNIE 02*, 2002, pp. 179–183.
- [88] **Ogedegbe, G., and Pickering, T.**, 2010. "Principles and techniques of blood pressure measurement". *Cardiology Clinics.* .28 (4). pp. 571–586.

- [89] **Safar, M. E., Bernard, I.L., and Struijker-Boudier, H.,** 2003. "Current Perspectives on Arterial Stiffness and Pulse Pressure in Hypertension and Cardiovascular Diseases," in *Circulation.*, vol. 107, pp. 2864.
- [90] **Killer, S.,** 2014. *Global Public Health Crisis. A Global Brief on Hypertension* World Health Organization, Geneva, Switzerland, 2014.
- [91] **Kachuee, M., Kiani, MM., Mohammadzade, H., and Shabany, M.,** "Cuffless Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring". *IEEE Trans Biomed Eng.* 2017 Apr; **64(4)**: pp.859-869. doi: 10.1109/TBME.2016.2580904. Epub 2016 Jun 14.
- [92] **Lin, R., Ren-Guey, L., Chwan-Lu, T., Heng-Kuan, Z., Chih- Feng, C., and Joe-Air, J.,** 2006. A new approach for identifying sleep apnea syndrome using wavelet transform and neural networks, *Biomedical Engineering Applications, Basis and Communications*, 18 (3).
- [93] **Kara, S., Dirgenali, F., and Okkesim, Ş.,** 2005."Estimating Gastric Rhythm Differences Using A Wavelet Method From The Electrogastragrams Of Normal And Diabetic Subjects" *Instrum. Sci. Technolog.* 33:519–532.
- [94] **Vetterli, M.,** 2001. "Wavelets, approximation, and compression," *IEEE Signal Processing Mag.*, vol. 5, pp. 59–73, Sept.
- [95] **Kock, K.L.,** 2001. Electrogastrography: physiological basis and clinical application in diabetic gastropathy. *Diabet. Techn. Ther;* vol.3 pp.51–62.
- [96] **Gopu, G., Neelaveni, R., and Porkumaran K.,** 2008. Acquisition and Analysis of Electrogastragram for Human Stomach Disorders, *Proceeding International conference on Recent Trends in Computational Science (ICRTCS'08)*, **1**, pp.162–169.
- [97] **Zhu, J.Y., Zheng, W.L., Peng, Y., Duan, R.N., and Lu, B.L.** 2014. EEG-based emotion recognition using discriminative graph regularized extreme learning machine. In: *Neural networks (IJCNN), 2014 international joint conference on IEEE*, pp 525–532.
- [98] **de Sobral Cintra, R.J., Tchervensky, I.V., Dimitrov, V.S., and Mintchev, M.P.,** 2004. Optimal Wavelets for Electrogastrography, *Engineering in Medicine and Biology Society, IEMBS '04. 26th Annual International Conference of the IEEE, San Francisco, CA, USA*.
- [99] **Öztemel, E.,** 2003. *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- [100] **McCulloch, W.S., and Pitts, W.A.** (1943). A logical calculus of the ideas immanent in nervous activity, *Buttetin of Mathematics and Biophysics*, 5, 115-133.
- [101] **Övünç, P.,** 2007. Patern Tanıma için Optimum Performanslı Yeni YSA Yaklaşımları ve Donanımsal Tasarımı, *Doktora Tezi*, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü. İstanbul.

- [102] **Curilem, M., Chacón M., Acuña G., Ulloa S., Pardo, C., Defilippi, C., and Madrid, A.M.,** 2010. Comparison of Artificial Neural Networks and Support Vector Machines for Feature Selection in Electrogastrography Signal Processing, *32nd Annual International Conference of the IEEE EMBS Buenos Aires, Argentina, August 31 - September 4*.
- [103] **Bahadır, İ.,** 2008. Bayes Teoremi ve Yapay Sinir Ağları Modelleriyle Borsa Gelecek Değer Tahmini Uygulaması, *Yüksek Lisans Tezi*, TOBB Ekonomi ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- [104] **İstanbullu, M.,** 2013. Yapay Sinir Ağları ve Destek Vektör Makineleri İle Kemik Erimesinin Teşhisi, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [105] **Kaya, T.,** 2011. "Bir ve İki Boyutlu Sayısal Filtre Tasarımı İçin Akıllı Hesaplama Yöntemleriyle Yeni Bir Pencereleme Fonksiyonunun Geliştirilmesi", Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- [106] **Lee, Y.** 1999. Handwritten digit recognition using k-nearest neighbor, radial basis function, and back-propagation neural network. *IEEE Trans Neural Comput.*;3:521-537
- [107] **Lee, S., Kang, P., and Cho S.,** 2014. "Probabilistic local reconstruction for k-NN regression and its application to virtual metrology in semiconductor manufacturing", *Neurocomputing-131*, 427– 439.
- [108] **Eray, O.,** 2008, Destek Vektör Makineleri ile Ses Tanıma Uygulaması, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli,
- [109] **Kocamaz, A.F.,** 2012. Makine Öğrenmesi Tabanlı Bir Uzman Sistem Tasarımı, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi Bilgisayar Mühendisliği Anabilim Dalı, Edirne.
- [110] **Kwak, N., and Choi, C.H.** 2002. Input feature selection by mutual information based on parzen window *IEEE Trans. Pattern Anal. Mach. Intell.*, 24 (December (12) pp. 1667-1671.
- [111] **İstanbullu, M.,** 2013. Yapay Sinir Ağları ve Destek Vektör Makineleri İle Kemik Erimesinin Teşhisi, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul
- [112] **Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. and Vandewalle, J.** 2002. "Least Squares Support Vector Machines". World Scientific. New Jersey..
- [113] **Nilsson, N.J.,** 1998. Introduction to Machine Learning, An Early Draft Of A Proposed Textbook,

- [114] Labview user manuel, April 2003 Edition Part Number 320999E-01
- [115] **Chen, G. and Hou, R.**, 2007. “A New Machine Double-Layer Learning Method and Its Application in Non-Linear Time Series Forecasting,” in *International Conference on Mechatronics and Automation, ICMA 2007*, pp. 795 –799.
- [116] **Jonas, T.**, 2007. Machine learning-based classifiers in the Direkt Profil grammatical profiling system, Department of Computer Science, Lund Institute of Technology, Lund University, Lund, Sweden 18th January.
- [117] **Kaya, T.**, 2015. Makine Öğrenme Yöntemleri İle Trafik Kazaları İçin Risk Tahmini Yapabilen Web Tabanlı Bir Yazılım, Gazi Üniversitesi Bilişim Enstitüsü, Yüksek Lisans Tezi Bilgisayar Eğitimi Anabilim Dalı, Nisan.
- [118] **Cortes, C., and Vapnik, V.**, 1995. Support-vector network. *Mach Learn.*, 20(3):273-297.
- [119] **Boser, B.E., Guyon, I.M., and Vapnik, V.N.**, 1992. A training algorithm for optimal margin classifiers, *Proceedings of the fifth annual workshop on Computational learning theory, ACM* pp. 144-152.
- [120] **Acharya, U.R., Sree, S.V., and Suri, J.S.**, 2012. Use Of Principal Component Analysis For Automatic Classification Of Epileptic EEG Activities in Wavelet Framework, *Expert Syst. Appl.*, 39 (August (10))Pp. 9072-9078
- [121] **Karagülle, F.** 2008. Destek Vektör Makinelerini Kullanarak Yüz Bulma, Yüksek Lisans Tezi, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Edirne.
- [122] **Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. and Vandewalle, J.**, 2002. “Least Squares Support Vector Machines”. World Scientific. New Jersey.
- [123] **Gürsoy, M.İ.**, 2009. “Destek Vektör Makineleri ile EEG İşaretlerinin Sınıflandırılmasında TBA, BBA VE DAA’nın Performansının Karşılaştırılması”, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Kahramanmaraş.
- [124] **Eren, Ö.**, 2008. Alerjen Proteinlerin Otomatik Sınıflandırılması, Yüksek Lisans Tezi, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- [125] **Kavzoğlu, T., ve Çölkesen, İ.** 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- [126] **Çomak, E.**, 2004. Destek Vektör Makineleri Çoklu Sınıf Problemleri İçin Çözüm Önerileri, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

- [127] **Haciefendiđlu, Ş.**, 2012. “MÖ Yöntemleri ile Golom Hastalığının Teşhisi”, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi , Elektronik ve Bilgisayar Sistemleri Anabilim Dalı, Ağustos.
- [128] <http://machinelearningmastery.com/k-nearest-neighbors-for-machine-learning/>
- [129] **Saeys, Y., Inza, I., and Larrañaga, P.**, 2007. A review of feature selection techniques in bioinformatics *Bioinformatics*, 23, pp. 2507-2517
- [130] **He, X., Ji, M., Zhang, C., and Bao, H.**, 2011. A variance minimization criterion to feature selection using Laplacian regularization *IEEE Trans. Pattern Anal. Mach. Intell.*, 33 (October (10)), pp. 2013-2025
- [131] **Zhu, S., Wang, D., Yu, K., Li, T., and Gong, Y.**, 2010. Feature selection for gene expression using model-based entropy, *IEEE/ACM Trans. Comput. Biol. Bioinform.*, 7 (January (1)), pp. 25-36.
- [132] **Balakrishnama, S., and Ganapathiraju, A.**, Linear Discriminant Analysis - A Brief Tutorial, Institute for Signal And Information Processing.
- [133] **Alkan, Ö.**, 2008. “Temel Bileşenler Analizi Ve Bir Uygulama Örneđi”, Atatürk Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, Yüksek Lisans Tezi, Erzurum.
- [134] **Gopu, G., Neelaveni, R. and Porkumaran, K.**, Analysis of EGG Signals for Digestive System Disorders Using Neural Networks, *13th International Conference on Biomedical Engineering* pp 101-104.
- [135] **Jung, T.-P., Makeig, S., Westerfield, M., Townsend, J., Courchesne, E., and Sejnowski, T.**, 1999. Independent component analysis of single-trial event related potentials. In: *Proceedings of the International Workshop on Independent Component Analysis and Signal Separation*, pp.173–179,
- [136] **Jung, T.-P., Makeig, S., Westerfield, M., Townsend, J., Courchesne, E., and Sejnowski, T.**, 2000. Removal of eye activity artifacts form visual event-related potential in normal and clinical subjects. *Clin. Neurophysiol.* 111:1745–1758,
- [137] **Ikeda, S. and Toyama, K.**, 2000. Independent component analysis for noisy data–MEG data analysis. *Neural Netw.* 13(10):201–215,
- [138] [<http://www.robotiksistem.com/>].
- [139] Engin Meşe Faruk Ünsaçar, Grafik Programlama Dili-Labview. Seçkin Yayıncılık, Kasım 2009.
- [140] <http://www.ni.com/white-paper/4752/en/>
- [141] <http://www.ni.com/en-tr/shop/labview/buy-labview.html>

- [142] **Deshmukh, A., and Gandole, Y.,** 2015. ECG Feature Extraction Using NI LabVIEW Biomedical Workbench, International Journal of Recent Scientific Research Vol. 6, Issue, 8, pp.5603-5607, August.
- [143] **Vakilian, A.R., Iranmanesh F., Nadimi, A.E., and Kahnali, J.A.,** 2011. “Heart Rate Variability and QT Dispersion Study in Brain Death Patients and Comatose Patients with Normal Brainstem Function”, Journal of the College of Physicians and Surgeons Pakistan., Vol.21,no.3,pp.130-133,
- [144] Biomedical User Group Forum; <http://decible.ni.com/content/groups/biomedical-usergroup>.
- [145] <http://ftp.ics.uci.edu/pub/machine-learning-databases/>.
- [146] EEG Data <http://www.meb.uni-bonn.de/epileptologie/science/physik/eegdata.html>.
- [147] **Kaya, D., Türk, M., and Kaya, T.,** 2017. Wavelet-Based Analysis Method for Heart Rate Detection of ECG Signal Using LabVIEW, The 40th Jubilee of International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2017, **May 22-26, 2017**. Opatija, Croatia,

ÖZGEÇMİŞ

Kişisel Bilgiler

İsim Soyisim : Duygu KAYA
Uyruğu : T.C.
Doğum Yeri : Gaziantep
Doğum Tarihi : 28.05.1986
Medeni Hali : Evli
Telefon : 0 424 2370000 Dâhili 5201
Email : dgur@firat.edu.tr

Eğitim Bilgileri

<u>Derece</u>	<u>Üniversite/Okul</u>	<u>Mezuniyet Tarihi</u>
	Fırat Üniversitesi	
Yüksek Lisans	Elektrik-Elektronik Müh. Bölümü/ELAZIĞ	2013
	İnönü Üniversitesi	
Lisans	Elektrik-Elektronik Müh. Bölümü/MALATYA	2010

İş Tecrübesi

2010 yılından beri Fırat Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde araştırma görevlisi olarak görev yapmaktayım.

Yayınlar

Uluslararası Hakemli Dergilerdeki Yayınlar

- 1- Kaya D., Kaya T. and Türk M., Elliptic Filter Based Noninvasive Blood Pressure Analyze with LabVIEW, Turkish Journal of Science & Technology,12(2), 2017.
- 2- Kaya D., Türk M. and Kaya T., Examining the Effect of Dimension Reduction on EEG Signals by K-Nearest Neighbors Algorithm, El-Cezeri Fen ve Mühendislik El-Cezeri Fen ve Mühendislik Dergisi (accepted).

Ulusal Hakemli Dergilerdeki Yayınlar

1. Kaya D., Türk M., Biyoelektriksel Kökenli İşaretlerde Rahatsızlık Teşhisinin Yorumlanması, Fırat Üniversitesi Mühendislik Bilimleri Dergisi, Cilt 29, Sayı (2017).

Uluslararası Konferans ve Sempozyumlar

- 1- Gür D., Kaya T, Turk M., The Detection of Epileptic Seizures Based on Discrete Wavelet Transform and Fourier Transform, IEEE International Symposium on Innovations in Intelligent Systems and Applications, INISTA 2014,Italy.
- 2- Kaya D., Türk M., Comparison of Different Types EEG Signals Based On The Analysis Method, International Artificial Intelligence and Data Processing Symposium, IDAP 2016, Malatya.
- 3- Kaya D., Türk M., Kaya T., Wavelet-Based Analysis Method for Heart Rate Detection of ECG Signal Using LabVIEW, The 40th Jubilee of International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2017, May 22-26, 2017, Opatija, Croatia.
- 4- Kaya D., Türk M. and Kaya T, Neural Network Based Noninvasive Blood Pressure Classification, International Advanced Researches and Engineering Congress, IAREC'2017, November, 16-18, 2017, Osmaniye, Turkey.

Ulusal Konferans ve Sempozyumlar

1. Gür D., Kaya T, Türk M., Normal ve Epileptik EEG Sinyallerinin Filtreleme Yöntemleri ile Analizi, IEEE 22. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, 2014, Trabzon.
2. Kaya D., Kaya T., Güler H., Türk M., Çölyak Hastalığının Tespiti için Sinyal Analiz Metotlarının Uygulanması, URSI-Türkiye 2014 VII. Bilimsel Kongresi, 28-30 Ağustos 2014, ELAZIĞ

Konuşma Dilleri: Türkçe (Ana dil), İngilizce (İyi)

İlgi Alanları: Spor yapmak, seyahat etmek ve müzik dinlemek