

**İDRAR İMGELERİNDEN HÜCRELERİN TANINMASI
VE SAYIMI İÇİN STEGANOĞRAFİK YÖNTEMLER TABANLI
GÜVENLİ BİR KARAR DESTEK SİSTEMİ**

Derya AVCI

Doktora Tezi

Elektrik – Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Mustafa POYRAZ

OCAK-2015

T.C
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İDRAR İMGELERİNDEN HÜCRELERİN TANINMASI VE SAYIMI İÇİN
STEGANOĞRAFİK YÖNTEMLER TABANLI GÜVENLİ BİR KARAR DESTEK SİSTEMİ

DOKTORA TEZİ

Derya AVCI

(102112202)

Tezin Enstitüye Verildiği Tarih : 31 Aralık 2014

Tezin Savunulduğu Tarih : 23 Ocak 2015

Tez Danışmanı :

Prof. Dr. Mustafa POYRAZ (F.Ü)


Diğer Jüri Üyeleri :

Prof. Dr. Yakup DEMİR (F.Ü)

Prof. Dr. Z. Hakan AKPOLAT (F.Ü)

Prof. Dr. M. Kemal LEBLEBİCİOĞLU (ODTÜ)

Doç. Dr. Mustafa TÜRK (F.Ü)



ÖNSÖZ

Bu tez çalışmasında, çoklu idrar hücrelerinin bulunduğu gerçek mikroskopik idrar tortusu imgelerinden hücrelerin otomatik tanınması ve sayılması steganografik yöntemlerle güvenli hale getirilmiş, görüntü işleme, ayrık dalgacık dönüşümü ve akıllı sınıflandırıcılar tabanlı farklı karar destek sistemleri uyarlanmıştır. Bu uyarlanan karar destek sistemlerinin uygulamaları sonucunda elde edilen sonuçlar irdelenmiştir. Bu tez çalışmam boyunca, ilgi ve yardımlarını esirgemeyen danışmanım Sayın Prof. Dr. Mustafa POYRAZ'a ve Sayın Prof. Dr. M. Kemal LEBLEBİCİOĞLU'na, çalışmam boyunca beni sabır ve özveri ile destekleyen eşim Doç.Dr. Engin AVCI'ya, Sayın Yrd.Doç.Dr. Esin AVCI'ya, Nadire AVCI ve Vahit AVCI'ya, değerli büyüğüm Sayın Dr. Levent AVCI'ya, Prof.Dr. Z. Hakan AKPOLAT'a, Prof.Dr. Yakup DEMİR'e ve bu tez çalışmam boyunca benden maddi ve manevi yardımlarını esirgemeyen değerli Fırat Üniversitesi Mühendislik Fakültesi Elektrik – Elektronik Mühendisliği bölüm hocalarıma ve arkadaşlarıma teşekkürlerimi ve şükranlarımı sunarım.

Derya AVCI - 2015

İÇİNDEKİLER

ÖNSÖZ.....	II
İÇİNDEKİLER.....	IV
ŞEKİLLER LİSTESİ.....	X
TABLolar LİSTESİ.....	XV
KISALTMALAR LİSTESİ	XVII
1. GİRİŞ	1
1.1. İdrar Tortusundaki Hücre ve Kristallerin Sınıflandırılmasının Tarihçesi.....	1
1.1.1. İlk İdrar Tortusu İçerisindeki Hücrelerin ve Kristallerin Tanınması ve Sınıflandırılması Çalışmaları	1
1.1.2. İdrar Tortusu İçerisindeki Hücrelerin ve Kristallerin Tanınması ve Sınıflandırılması Çalışmalarının Günümüzdeki Durumu.....	2
1.2. Tezdeki Orijinal Katkıları ve Tezin Organizasyonu.....	6
2. İDRAR TORTUSUNDA GÖRÜLEN HÜCRELER	8
2.1. Organik İdrar Tortuları	8
2.2. İnorganik İdrar Tortuları	15
2.2.1. Asit İdrarda Görülen İnorganik İdrar Tortuları	16
2.2.2. Alkali İdrarda Görülen İnorganik İdrar Tortuları	22
3. TEMEL ÖRÜNTÜ TANIMA TEKNİKLERİ VE KARAR DESTEK SİSTEMLERİ.....	24
3.1. Örüntü Tanıma Kavramı	26
3.1.1. Ön İşlem Süreci	27
3.1.2. Özellik Çıkarma Süreci	28
3.1.3. Sınıflandırma Süreci.....	28
3.2. Karar Destek Sistemleri.....	29
3.2.1. Tıbbi Karar Destek Sistemleri	30
4. SAYISAL İMGE İŞLEME YÖNTEMLERİ.....	34
4.1. İmgenin Elde Edilmesi	35
4.2. Renkli Sayısal İmgeyi Gri Seviye Sayısal İmgeye Dönüştürme İşlemi	36

4.3. Sayısal İmgelerin Filtrelenmesi İşlemi.....	37
4.4. Sayısal İmgelerde Erezyon İşlemi.....	39
4.5. Sayısal İmgelerin Bölütlenmesi İşlemi.....	39
4.5.1. Otomatik Sayısal İmge Eşikleme Teknikleri.....	41
5. STEGANOĞRAFİNİN TEMELLERİ	43
5.1. Bilgi Gizlemenin Alt Alanı Olarak Steganografinin Kullanımı	43
5.1.1. Gizli Kanallar	44
5.1.2. Gerçek Kimliği Saklama	44
5.1.3. Telif Hakkı İşaretlemesi	44
5.1.4. Temel Steganografi Kavramı	45
5.1.4.1. Başlıca Teknik Steganografi Türleri	46
5.1.4.2. Son Bite Ekleme Yönteminin İmge Dosyalarına Uygulanması	46
6. İDRAR TORTUSUNDA YER ALAN HÜCRELER VE KRİSTALLERİN MİKROSKOBİK İMGELERİNİN ÖN İŞLEMİ VE ÖZELLİK ÇIKARIMI İÇİN KULLANILAN YÖNTEMLER	47
6.1. Hu'nun Değişmez Momentleri Yöntemi	47
6.2. Hough Dönüşümü Yöntemi.....	49
6.3. Dalgacık Dönüşümü Yöntemi	50
6.3.1. Sürekli Dalgacık Dönüşümü.....	50
6.3.2. Ayırık Dalgacık Dönüşümü.....	51
6.3.3. Ayırık Dalgacık Dönüşüm Ağacından Entropi Hesaplanması	55
7. MİKROSKOBİK İDRAR TORTUSU İMGELERİNDE YER ALAN HÜCRELERİN SINIFLANDIRILMALARI İÇİN KULLANILAN YÖNTEMLER.....	58
7.1. Yapay Sinir Ağı Sınıflandırıcıları	58
7.1.1. Biyolojik Sinir Ağların Yapısı.....	59
7.1.2. Bir Yapay Sinir Ağlarının Ana Öğeleri.....	60
7.1.3. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları.....	62
7.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcıları	64
7.2.1. UATBÇS Mimarisi.....	65

7.2.2. UATBÇS İçin Geri Yayılımlı Öğrenme Algoritması.....	67
7.3. Çoklu Destek Vektör Makineleri Sınıflandırıcısı.....	68
7.3.1. Doğrusal Ayrılabilen Veriler İçin Destek Vektör Makineleri	69
7.3.2. Doğrusal Ayrılmayan Veriler İçin Destek Vektör Makineleri	71
8. MİKROSKOBİK İDRAR TORTUSU İMGELERİNDE BULUNAN HÜCRELERİN OTOMATİK TANINMASI VE SAYILMASI İÇİN GELİŞTİRİLEN KARAR DESTEK SİSTEMLERİ VE UYGULAMALARI.....	85
8.1. Mikroskobik İdrar Tortusu İmgelerinin Elde Edilmesi	75
8.2. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlanan Değişmez Momentler Tabanlı Karar Destek Sistemleri.....	77
8.2.1. Değişmez Momentler – Yapay Sinir Ağları Yöntemi	78
8.2.1.1. Ön İşlem Süreci	78
8.2.1.2. Özellik Çıkarım Süreci	84
8.2.1.3. Sınıflandırma Süreci	86
8.2.1.4. Test Süreci	89
8.2.2. Değişmez Momentler – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi.....	90
8.2.2.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi	92
8.2.2.2. Test Süreci	93
8.2.3. Değişmez Momentler – Çoklu Destek Vektör Makineleri Yöntemi	94
8.2.3.1. Çoklu Destek Vektör Makineleri Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi	96
8.2.3.2. Test Süreci	96
8.3. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlanan Hough Dönüşüm Tabanlı Karar Destek Sistemleri.....	97
8.3.1. Hough Dönüşümü – Yapay Sinir Ağları Yöntemi	98
8.3.1.1. Ön İşlem Süreci	98
8.3.1.2. Özellik Çıkarım Süreci	99
8.3.1.3. Sınıflandırma Süreci	101
8.3.1.4. Test Süreci	103

8.3.2. Hough Dönüşümü – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi	104
8.3.2.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi	106
8.3.2.2. Test Süreci	107
8.3.3. Hough Dönüşümü – Çoklu Destek Vektör Makineleri Yöntemi	108
8.3.3.1. Çoklu Destek Vektör Makineleri Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi	109
8.4. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı Karar Destek Sistemleri	110
8.4.1. Uyarlamalı Ayrık Dalgacık Dönüşümü - Yapay Sinir Ağları Yöntemi	111
8.4.1.1. Ön İşlem Süreci	111
8.4.1.2. Özellik Çıkarım Süreci	113
8.4.1.3. Sınıflandırma Süreci	114
8.4.1.4. Test Süreci	116
8.4.2. Uyarlamalı Ayrık Dalgacık Dönüşüm - Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi	117
8.4.2.1. Ön İşlem Süreci	118
8.4.2.2. Özellik Çıkarım Süreci	120
8.4.2.3. Sınıflandırma Süreci	121
8.4.4.4. Test Süreci	122
8.4.3. Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı - Destek Vektör Makineleri Yöntemi	123
8.4.3.1. Ön İşlem Süreci	124
8.4.3.2. Özellik Çıkarım Süreci	126
8.4.3.3. Sınıflandırma Süreci	127
8.4.3.4. Test Süreci	128
8.5. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı İstatistiksel Yöntemlerle Güçlendirilmiş Karar Destek Sistemleri	129
8.5.1. UADD-İstatistiksel - Yapay Sinir Ağları Yöntemi	130
8.5.1.1. Ön İşlem Süreci	131
8.5.1.2. Özellik Çıkarım Süreci	132

8.5.1.3. Sınıflandırma Süreci.....	135
8.5.1.4. Test Süreci.....	137
8.5.2. UADD-İstatistiksel - Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi.....	138
8.5.3. UADD-İstatistiksel - Çoklu Destek Vektör Makineleri Yöntemi	140
8.6. Elde Edilen Mikroskobik İdrar Tortusu İmgelerine SBE Tabanlı Steganografi Yönteminin Uygulanması.....	144
9. SONUÇ VE DEĞERLENDİRME.....	150
9.1. Sonuçların Değerlendirilmesi.....	154
9.2. Öneriler.....	156
9.3. Yayınlar.....	156
KAYNAKLAR.....	157
ÖZGEÇMİŞ.....	163

ÖZET

DOKTORA TEZİ

İDRAR İMGELERİNDEN HÜCRELERİN TANINMASI VE SAYIMI İÇİN STEGANOĞRAFİK YÖNTEMLER TABANLI GÜVENLİ BİR KARAR DESTEK SİSTEMİ

Derya AVCI

Fırat Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik – Elektronik Mühendisliği Anabilim Dalı

2015, Sayfa:162

İdrar analizi, insan vücudundaki birçok problem ve hastalığın teşhisinde kullanılmaktadır. El yordamı ile gerçekleştirilen mikroskobik idrar analizi, çok fazla zaman kaybına yol açan, insan gözünün yanılma payına bağlı ve bundan dolayı birçok hatalı sonuçlar ortaya çıkarabilecek bir işlemdir. Bu gibi dezavantajlardan dolayı, günümüzde mikroskobik idrar analizinin bilgisayar algoritmaları kullanılarak otomatikleştirilmesi çalışmaları önem kazanmıştır. Son yıllarda, idrar tortusunda var olan idrar hücrelerinin belirlenmesi ve sınıflandırılması için yapılan çalışmalarda birçok görüntü işleme ve akıllı sınıflandırma algoritmalarının kullanıldığı görülmüştür. Bu çalışmalar sonucunda, idrar hücrelerinin birbirine yapışık olmaları ya da üst üste binmeleri gibi doğru tanıma başarımını azaltan dezavantajlarının olduğu ve bunların giderilmesi gerektiği kanaatine varılmıştır.

Bu tez çalışmasında, çoklu idrar hücrelerinin bulunduğu gerçek mikroskobik idrar tortusu imgelerinden hücrelerin otomatik tanınması ve sayılması steganografik yöntemlerle güvenli hale getirilmiş, görüntü işleme, ayrık dalgacık dönüşümü ve akıllı sınıflandırıcılar tabanlı farklı karar destek sistemleri uyarlanmıştır. Bu uyarlanan karar destek sistemlerinin uygulamaları sonucunda elde edilen sonuçlar irdelenmiştir.

Anahtar Kelimeler: İdrar Hücrelerinin Tanınması, Görüntü İşleme, Steganografi Teknikleri, Ayrık Dalgacık Dönüşümü, Uyarlamalı Özellik Çıkarımı, Yapay Sinir Ağları Sınıflandırıcısı, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı, Destek Vektör Makineleri Sınıflandırıcısı.

ABSTRACT

PhD Thesis

A SAFE DECISION SUPPORT SYSTEM BASED STEGANOGRAPHIC METHODS FOR CELLS RECOGNITION AND COUNTING FROM URINE IMAGES

Derya AVCI

Firat University

Graduate School of Natural and Applied Sciences

Department of Electrical – Electronics Engineering

2015, Page: 162

Urine analysis is used in the diagnosis of many conditions and diseases of the human body. The manual microscopic urine analysis procedure leads to loss a lot of time together tith the problem of the fallibility of the human eye and therefore this process may result in many erroneous conclusions. Nowadays, using computer algorithms to automate the microscopic urine analysis has gained importance due to these disadvantages. Today, many image processing and classification algorithms are used for the determination and classification of cells existing in the urine sediments. The results of these studies showed that there are some problems associated with urine cells, which reduce the recognition performance, such as adherent cells or overlaping cells. It is require to eliminate these disadvantages in order to have a working algorithm.

In this study, many different decision support systems were developed for automatic recognition and counting of cells from real microscobic urine sediment images. These decision support systems has been made more secure by using steganographic methods. They are based on image processing, discrete wavelet transform and intelligent classifiers. Finally, the results obtained from the application of these robust decision support systems were evaluated and compared.

Keywords: Recognition of Urine Cell, Image Processing, Steganography Techniques, Discrete Wavelet Transform, Adaptive Feature Extraction, Artificial Neural Network Classifier, Adaptive Network Based Fuzzy Inference System Classifier, Support Vector Machine Classifier.

ŞEKİLLER LİSTESİ

Şekil 2.1. Eritrositlerin mikroskopik görünümü.....	8
Şekil 2.2. Eritrositlerin mikroskopik görünümü.....	9
Şekil 2.3. Lökositlerin mikroskopik görünümü.....	9
Şekil 2.4. Epitel hücrelerinin mikroskopik görünümü	10
Şekil 2.5. Hyalin silendirlerin mikroskopik görünümü	11
Şekil 2.6. Granüler silendirlerin mikroskopik görünümü.....	11
Şekil 2.7. Lökosit silendirlerin mikroskopik görünümü.....	12
Şekil 2.8. Eritrosit silendirlerin mikroskopik görünümü.....	12
Şekil 2.9. Epitel silendirlerin mikroskopik görünümü	12
Şekil 2.10. Mum silendirlerin mikroskopik görünümü	13
Şekil 2.11. Yağ silendirinin mikroskopik görünümü	13
Şekil 2. 12. Tricomonas vaginalis'in mikroskopik görünümü	14
Şekil 2. 13. Bakteri ve mantarların mikroskopik görünümü	14
Şekil 2. 14. Sperm hücrelerinin mikroskopik görünümü.....	15
Şekil 2. 15. Yabancı artıkların mikroskopik görünümü	15
Şekil 2. 16. Ürik asit kristallerinin mikroskopik görünümü	16
Şekil 2. 17. Kalsiyum oksalat kristallerinin mikroskopik görünümü	17
Şekil 2. 18. Amorf urat kristallerinin mikroskopik görünümü	18
Şekil 2. 19. Sistin kristallerinin mikroskopik görünümü.....	19
Şekil 2. 20. Tirozin kristallerinin mikroskopik görünümü	19
Şekil 2. 21. Lösin kristallerinin mikroskopik görünümü.....	20
Şekil 2. 22. Kolesterol kristallerinin mikroskopik görünümü	20
Şekil 2. 23. Kalsiyum sülfat kristallerinin mikroskopik görünümü	21
Şekil 2. 24. Bilirubin kristallerinin mikroskopik görünümü	21
Şekil 2. 25. Triple fosfat kristallerinin mikroskopik görünümü	22

Şekil 2. 26. Amorf fosfat kristallerinin mikroskopik görünümü	22
Şekil 2. 27. Amonyum ürat kristallerinin mikroskopik görünümü.....	23
Şekil 2. 28. Kalsiyum fosfat kristallerinin mikroskopik görünümü	23
Şekil 3. 1. Temel örüntü tanıma aşamaları	25
Şekil 3. 2. Bir örüntü tanıma sistemi blok diyagramı	27
Şekil 4. 1. (a) RGB renk formatındaki bir sayısal imge (b) Bu sayısal imgenin gri seviyeye dönüştürülmüş hali	37
Şekil 4. 2. Bir median filtre uygulaması.....	38
Şekil 4. 3. (a) Gürültü eklenmiş sayısal imge, (b) 3x3 lük median filtre ile gürültü giderme, (c) median filtre uygulaması sonucunda elde edilen gürültü giderilmiş sayısal imge	38
Şekil 4. 4. (a) Sayısal imge, (b) Sayısal imgeye uygulanmış bir erezyon uygulaması.....	39
Şekil 5. 1. Veri ve Bilgi gizleme yöntemlerinin sınıflandırılması.....	44
Şekil 5. 2. Teknik steganografi türleri	46
Şekil 6. 1. Hough Dönüşümün uygulanışı.....	49
Şekil 6. 2. Ayırık Dalgacık Dönüşümü ayrışım ağacı	52
Şekil 6. 3. Literatürde en çok kullanılan ADD filtre örnekleri	53
Şekil 6. 4. İmge için ADD ayrışımı (a) 1. seviye (b) 2. seviye	54
Şekil 6. 5. İki boyutlu dalgacık dönüşümü	55
Şekil 6. 6. Mikroskopik sayısal idrar tortusu imgelerinden özellik çıkarımı için uyarlanan ayırık dalgacık dönüşüm entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı	57
Şekil 7. 1. Biyolojik bir beyin sinir hücresi.....	60
Şekil 7. 2. Yapay sinir (düğüm) modeli	61
Şekil 7. 3. Yapay sinir ağları için kullanılan etkinlik işlevleri	62
Şekil 7. 4. 2 girişli 9 kurallı Sugeno tip bir UATBÇS mimarisi.....	65
Şekil 7. 5. (a) İki sınıflı bir problem için hiper –düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri	69
Şekil 7. 6. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi	70
Şekil 7. 7.(a) Doğrusal olarak ayrılamayan veri setti, (b) Doğrusal olarak ayrılamayan veri setleri için hiper-düzlemin belirlenmesi	72
Şekil 7. 8. Kernel fonksiyonu ile bir verinin daha yüksek bir boyuta dönüştürülmesi.....	72
Şekil 8. 1. İdrar tortusu imgelerini almak için bu tez çalışmasında kullanılan imge alma düzeneği ...	76

Şekil 8. 2.Mikroskobik idrar hücre imgeleri: (a) eritrosit hücreleri (eh), (b) lökosit hücreleri (lh), (c) trombosit hücreleri (th), (d) deri hücreleri (dh), (e) kristal hücreleri (kh), (f) parazit hücreleri (ph), (g) bakteri ve mantar hücreleri (bmh), (h) sperm hücreleri (sh), (k) yabancı artıklar (ya), (l) inorganik artıklar (ia).....	76
Şekil 8. 3.Birden fazla hücrenin bulunduğu idrar tortusu imgeleri	77
Şekil 8. 4. Bu çalışmada kullanılan DM-YSA sisteminin blok diagramı	79
Şekil 8. 5. (a) Mikroskobik idrar tortusu imgesi, (b) Bu mikroskobik idrar tortusu imgesine Median filtre uygulanması sonucu elde edilen gürültüden arındırılmış imge	80
Şekil 8. 6. (a) Mikroskobik idrar tortusu imgesi, (b) Bu mikroskobik idrar tortusu imgesine parlaklık artırımı uygulanması sonucu elde edilen imge	80
Şekil 8. 7. (a). Mikroskobik idrar tortusu imgesi, (b) Bu mikroskobik idrar tortusu imgesine geliştirilen otomatik eşikleme yöntemi tabanlı bölütleme işlemi uygulanması sonucu elde edilen imge	82
Şekil 8. 8. (a) Boşlukları doldurulduktan sonra elde edilen mikroskobik idrar tortusu imgesi, (b) erosion işleminden sonra elde edilen mikroskobik idrar tortusu imgesi	83
Şekil 8. 9. Çok katmanlı ileri beslemeli yapay sinir ağları.....	87
Şekil 8. 10. DM-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı.....	88
Şekil 8. 11. Bu çalışmada kullanılan DM-UATBÇS sisteminin blok diagramı	91
Şekil 8. 12. Bu çalışmada kullanılan DM-ÇDVM sisteminin blok diagramı	95
Şekil 8. 13. Bu çalışmada kullanılan HD-YSA sisteminin blok diagramı	99
Şekil 8. 14. (a) İdrar tortusunda bulunan kan hücreleri imgesi (b) İdrar tortusunda bulunan kan hücreleri imgesine Hough Dönüşümünün uygulanmış hali (c) Hough Dönüşüm uygulanarak yerleri tespit edilen idrar içindeki kan hücreleri	100
Şekil 8. 15. HD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı	103
Şekil 8.16. Bu çalışmada kullanılan HD-UATBÇS sisteminin blok diagramı.....	105
Şekil 8.17. Bu çalışmada kullanılan HD-ÇDVM sisteminin blok diagramı	108
Şekil 8.18. Bu çalışmada kullanılan UADD-YSA sisteminin blok diagramı.....	112
Şekil 8.19. Bu çalışmada kullanılan UADD-YSA sisteminin özellik çıkarım mekanizması	114
Şekil 8.20. UADD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı.....	116
Şekil 8.21. Bu çalışmada kullanılan UADD-UATBÇS sisteminin blok diagramı	119
Şekil 8.22.Bu çalışmada kullanılan UADD-UATBÇS sisteminin özellik çıkarım mekanizması	121
Şekil 8.23. Bu çalışmada kullanılan UADD-ÇDVM sisteminin blok diagramı.....	125
Şekil 8.24. Bu çalışmada kullanılan UADD-ÇDVM sisteminin özellik çıkarım mekanizması	127

Şekil 8.25. İdrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan UADD-İstatistiksel karar destek sisteminin algoritmik akış diyagramı	131
Şekil 8.26. UADD-İstatistiksel-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı	136
Şekil 8.27. İdrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan UADD-İstatistiksel-UATBÇS karar destek sisteminin algoritmik akış diyagramı	138
Şekil 8. 28. İdrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan UADD-İstatistiksel-ÇDVM karar destek sisteminin algoritmik akış diyagramı	141
Şekil 8. 29. (a) Orijinal mikroskopik idrar tortusu imgesi, (b) SBE stegonografi yöntemi kullanılarak elde edilmiş sayısal imge.....	145

TABLÖLER LİSTESİ

Tablo 6. 1.Sayısal işaret ya da imge işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler	56
Tablo 7. 1.Destek Vektör Makinelerinde kullanılan temel kernel fonksiyonları ve parametreleri.....	74
Tablo 8. 1. YSA eğitimi için kullanılan idrar hücresi imgesinin değişmez moment değerleri (ϕ_i).....	85
Tablo 8. 2.Uyarlanan DM-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri.....	88
Tablo 8. 3.DM-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	89
Tablo 8. 4.Uyarlanan DM-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri.....	92
Tablo 8. 5.DM-UATBÇS sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları.	93
Tablo 8. 6.Kullanılan ÇDVM sınıflandırıcının özellikleri.	96
Tablo 8. 7.DM-ÇDVM sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları.....	97
Tablo 8. 8.Uyarlanan HD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri.....	102
Tablo 8. 9.HD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları.....	104
Tablo 8. 10.Uyarlanan HD-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri.....	106
Tablo 8. 11. HD-UATBÇS sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları.	107
Tablo 8. 12.Kullanılan ÇDVM sınıflandırıcının özellikleri	109
Tablo 8. 13.HD-ÇDVM sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları	110
Tablo 8. 14.Uyarlanan UADD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri	115
Tablo 8. 15. UADD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	117
Tablo 8. 16.Uyarlanan UADD-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri	122
Tablo 8. 17.UADD-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	123
Tablo 8. 18.Uyarlanan UADD-ÇDVM sınıflandırma yöntemi için kullanılan ÇDVM modelinin yapısı ve eğitim parametreleri.....	128

Tablo 8. 19.UADD-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	129
Tablo 8. 20.Uyarlanan UADD-İstatistiksel-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri	136
Tablo 8. 21. UADD-İstatistiksel-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	137
Tablo 8. 22.Uyarlanan UADD-İstatistiksel-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri	139
Tablo 8. 23.UADD-İstatistiksel-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	140
Tablo 8. 24.Uyarlanan UADD-İstatistiksel-ÇDVM sınıflandırma yöntemi için kullanılan ÇDVM modelinin yapısı ve eğitim parametreleri	142
Tablo 8. 25.UADD-İstatistiksel-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları	142
Tablo 8. 26. En yüksek ortalama tanıma ve sayma başarımına sahip ilk 10 karar destek sistemi ve doğru tanıma başarımları.....	143

KISALTMALAR LİSTESİ

ADD : Ayrık Dalgacık Dönüşümü

SBE : Son Bite Ekleme

PSNR : Tepe İşaret Gürültü Oranı

HD: Hough Dönüşümü

DM: Değişmez Momentler

UADD: Uyarlamalı Ayrık Dalgacık Dönüşümü

UATBÇS : Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

ÇDVM: Çoklu Destek Vektör Makinesi

YSA: Yapay Sinir Ağları

DVM: Destek Vektör Makinesi

DM-UATBÇS : Değişmez Momentler – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

DM-YSA: Değişmez Momentler- Yapay Sinir Ağları

DM-ÇDVM: Değişmez Momentler- Çoklu Destek Vektör Makinesi

HD-YSA: Hough Dönüşümü- Yapay Sinir Ağları

HD- UATBÇS : Hough Dönüşümü – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

HD- ÇDVM: Hough Dönüşümü - Çoklu Destek Vektör Makinesi

ÖÇ-1: Özellik Çıkarım Yöntemi-1

ÖÇ-2: Özellik Çıkarım Yöntemi-2

ÖÇ-3: Özellik Çıkarım Yöntemi-3

ÖÇ-4: Özellik Çıkarım Yöntemi-4

ÖÇ-5: Özellik Çıkarım Yöntemi-5

ÖÇ-6: Özellik Çıkarım Yöntemi-6

ÖÇ-7: Özellik Çıkarım Yöntemi-7

ÖÇ-8: Özellik Çıkarım Yöntemi-8

ÖÇ-9: Özellik Çıkarım Yöntemi-9

ÖÇ-10: Özellik Çıkarım Yöntemi-10

ÖÇ-11: Özellik Çıkarım Yöntemi-11

ÖÇ-12: Özellik Çıkarım Yöntemi-12

1. GİRİŞ

İdrar, insan metabolizmasının oluşturduğu klinik açıdan önemli bir vücut sıvısıdır [1]. İdrar tortusu (sedimenti) mikroskobisinde görülen yapıları tanımlamak bazen zordur. Bu nedenle idrar tortusu mikroskobik incelenmesi, gerek bilgi, gerekse tecrübe gerektiren bir iştir. İnceleme sonuçlarının kalitesi, yapan kişinin bilgi ve tecrübesi ile doğrudan ilgilidir. Ayrıca, idrar tortusu mikroskobik incelenmesinin kesin çerçevelerle sınırlanmış kuralları da yoktur. Bu yönüyle de uygulayıcının deneyimleri analizde büyük rol oynar. Bu alanda yapılan çalışmalarda, inceleme kalitesindeki en büyük payın mikroskobun, iyi özelliklerde seçilmesine bağlı olduğu sonucuna varılmıştır. Mikroskop, keşfedildiği günden beri tıbbi tanı alanında vazgeçilmez bir yere sahip olmuştur [2]. Normal ve sağlıklı bedenlerde bulunmayan mikroorganizmaların hasta bünyelerde tespit edilmesi bu mikroorganizmaların ortadan kalkması ile hastalığın belirtilerin de giderilmesi bilinen bir tedavi yöntemidir. Bunun dışında vücutta (özellikle kanda) bulunması gereken hücrelerin gerektiği sayıda bulunmaması gibi durumlar da hastalıkların teşhis ve tedavisinde rol almaktadır. Ayrıca şekli ve özellikleri bilinen hücrelerin şekillerinin bozulması (Amorf Hücre) da hastalıklar için önemli bir belirtidir.

Buradan anlaşılacağı gibi mikroskopinin iki temel kullanım alanı vardır [3]:

- Hücre sayımı,
- Amorf (Şekli Bozulmuş) hücrelerin tespitidir.

Bu bölümün devamında idrar tortusunda yer alan hücrelerin ve kristallerin sınıflandırılması ile ilgili daha önceden yapılmış güncel çalışmalar hakkında bilgi verilmiştir.

1.1. İdrar Tortusundaki Hücre ve Kristallerin Sınıflandırılmasının Tarihçesi

İdrar tortusu içerisindeki hücrelerin ve kristallerin tanınması ve sınıflandırılması çalışmalarının tarihçesini ilk idrar tortusu içerisindeki hücrelerin ve kristallerin tanınması ve sınıflandırılması çalışmaları ve bu tanıma çalışmalarının günümüzdeki durumu şeklinde iki başlık altında incelemekte yarar vardır.

1.1.1. İlk İdrar Tortusu İçerisindeki Hücrelerin ve Kristallerin Tanınması ve Sınıflandırılması Çalışmaları

İdrar tortusu içerisindeki hücrelerin ve kristallerin tanınması ve sınıflandırılmasında en eski yöntem mikroskopla manuel yani insan gözüyle yapılan incelemedir [4], [5]. Bu çalışmalarda iş yoğunluğunun fazla olması, çok fazla zaman harcanması ve dikkat eksikliğinden kaynaklanan yanlışlıklar gibi nedenlerle hatalı sonuçların elde edilmesi

muhtemeldir. Bundan dolayı, günümüzde idrar mikroskobisi ve idrar hücrelerinin doğru tanınması ve sınıflandırılması alanlarında yapılan çalışmalar görüntü işlemeye dayalı otomatik tanıma ve sınıflandırma uygulamalarına kaymıştır. İdrar tortusu içerisindeki hücrelerin ve kristallerin tanınması ve sınıflandırılması alanında yapılan çalışmalar özet olarak verilmiştir.

1.1.2. İdrar Tortusu İçerisindeki Hücrelerin ve Kristallerin Tanınması ve Sınıflandırılması Çalışmalarının Günümüzdeki Durumu

Günümüzde bilimin ve bilgisayar teknolojisinin ilerlemesiyle eğitilebilen ve öğrenebilen çeşitli akıllı tanıma yöntemleri ortaya çıkmış ve bu yöntemler idrar tortuları içerisindeki hücrelerin tanınması ve sınıflandırılması çalışmalarında da kullanılmaya başlanmıştır. Bu şekilde İdrar tortusu içerisindeki hücrelerin ve kristallerin tanınması ve sınıflandırılması için akıllı tanıma sistemleri ortaya çıkmıştır. Bu hücre tanıma ve sınıflandırma yöntemlerine aynı zamanda otomatik hücre tanıma ve sınıflandırma yöntemleri adı verilmektedir.

Günümüzde, otomatik idrar hücre tanıma ve sınıflandırma işlemlerinde kullanılan en yaygın ön işlem ve özellik çıkarım yöntemleri olarak, mikroskobik idrar imgelerinden kenar çıkarma ve bölütleme yöntemleri sayılabilir. Bu yöntemler arasında, Sobel, Log, Robert ve Canny kenar çıkarma yöntemleri verilebilir [6]. Ayrıca, bölütleme yöntemleri olarak, aktif kontür yöntemleri (yılan algoritması, balon algoritması, seviye kümeleme), Hough dönüşümü, otomatik eşikleme, Mumford-Shah modeli yöntemleri v.b. kullanılmıştır [1]. Bu çalışmalarda sınıflandırıcı olarak genellikle, K-NN (K En Yakın Komşuluk), BCO (Bulanık C Ortalamalar), Yapay Sinir Ağları algoritmaları kullanılmıştır [1-9]. Aşağıda bu çalışmalardan önemli olanlarına değinilmiştir.

Luo ve diğerlerinin 2007 yılında yaptığı çalışmada, idrar hücrelerinin mikroskobik imgelerinin bölütlenmesinde Mumford-Shah modeli kullanılmıştır. Ayrıca bu çalışmada, Euler-Lagrange denklemleri kullanılarak, seviye kümeleme şeklinde yeni bir Mumford-Shah bölütleme modeli sunulmuştur. % 80 oranında doğru bölütleme sonuçları elde edilmiştir. Bu çalışmada sınıflandırma yapılmamıştır [1]. Lakatos ve diğerlerinin 2010 yılında yaptığı bir diğer çalışmada, idrar ve kanda görülen hücre zarlarının analizi ve bölütlenmesi için yılan ve balon aktif kontür yöntemleri kullanılmıştır. Bu yöntemlerle ortalama % 83 civarında bir başarımla elde edilmiştir [2].

Cao ve diğerlerinin 2009 yılında yaptığı bir başka çalışmada ise, idrar tortusu içerisindeki kırmızı kan hücrelerinin mikroskopik imgeleri, imge işleme yöntemleri kullanılarak birbirinden ayırt edilme yoluna gidilmiştir[4]. Bu çalışmada, ön işlem ve özellik çıkarım kısmında kırmızı kan hücresi imgelerine sırasıyla, Sobel kenar çıkarma operatörü ve daha sonra Hough dönüşüm bölütleme algoritması uygulanmıştır. Daha sonra bölütlenen bu kırmızı kan hücre imgelerinden elde edilen bu özellik uzayının indirgenmesi işleminde ise TBA Temel Bileşen Analizi (TBA) kullanılmıştır. Daha sonra bu indirgenen özellikler, Doğrusal Ayırışım Analizi (DAA) yöntemi kullanılarak sınıflandırılmıştır. Ortalama test sonucu olarak, % 88'lik bir başarımlı oranı elde edilmiştir.

Yapılan bir başka çalışmada idrar hücre görüntülerinden kist hücrelerinin otomatik belirlenmesi ve tanınması işlemi gerçekleştirilmiştir [9]. Bunun için sırasıyla, dört doğrultuda değişen haritalanmış imge yöntemi, daha sonra bulunan bu imge gri seviyeden, ikili formata dönüştürülerek eşikleme işlemi uygulanır. Bu eşikleme işlemi ile bölütlenmiş imgenin 5'er adet doku ve şekil özelliği çıkarılarak bu özellikler sınıflandırma aşamasında bir karar ağacı sınıflandırıcısına verilerek, kist hücrelerinin sınıflandırılıp, bu hücrelerin idrar imgesi içerisindeki diğer hücrelerden ayırt edilmeleri sağlanmış olur. Bu uygulama çalışması sonucunda, ortalama % 70 oranında sınıflandırma ve test başarımlı elde edilmiştir [9].

Avcı'nın 2012'de yaptığı diğer bir çalışmada, idrar tortusunun görünen bileşenlerinin otomatik tanınması ve sayılması işlemi gerçekleştirilmiştir [9]. Bu çalışmada, kullanılan yöntemler aşağıda sırasıyla verilmiştir:

1. Ön işlem için, idrar imgeleri Gaussian filtreden geçirilmiştir. Daha sonra, eşikleme yöntemi uygulanarak, bu filtrelenen idrar imgeleri bölütlenmiştir.
2. Özellik çıkarımı ve en iyi özelliklerin seçimi için genetik algoritma yöntemi kullanılmıştır. Daha sonra, elde edilen özellikler yapay sinir ağları sınıflandırıcısına verilerek sınıflandırma işlemi gerçekleştirilmiştir.
3. Her bir idrar hücre çeşidi için farklı bir test başarımlı elde edilmesine rağmen ortalama test başarımlı olarak, % 88'lik bir başarımlı oranı elde edilmiştir.

Avcı'nın 2012 yılında yaptığı bir başka çalışmada mikroskopik idrar tortusu imgelerinin bölütlenmesi işlemi geriye yayımlı yapay sinir ağları yöntemi kullanılarak, gerçekleştirilmiştir. Bu çalışmada, idrar tortusunda görülen kristaller, kistler, kırmızı kan

hücreleri, beyaz kan hücreleri ve bakteriler ya da mayaların otomatik sınıflandırılması işlemi için yapay sinir ağları sınıflandırıcısı kullanılmıştır. Bu sınıflandırma işleminden önce, imge eşikleme işlemi gerçekleştirilmiştir. Bu imge eşikleme için bazı kaynaklarda yerel ve bazı kaynaklarda genel eşikleme tavsiye edilmiştir [6], [8].

İdrar analizi, insan vücudundaki birçok problem ve hastalığın teşhisinde kullanılmaktadır [7]. Manuel yani elle (otomatik olmayan) mikroskobik idrar analizi, çok fazla zaman kaybına yol açan, insan gözünün yanılma payına bağlı ve bundan dolayı birçok hatalı sonuçlar ortaya çıkarabilecek bir işlemdir. 2013 yılında idrar içerisindeki deri hücrelerinin otomatik sınıflandırılması konusunda yapılan bir diğer çalışmada ise, daha değişik yöntemler kullanılmıştır. Bu çalışmada, mikroskobik idrar imgelerindeki epitelyum (deri) hücrelerinin belirlenmesi ve tanınması için otomatik bir prosedür ortaya koyulmuştur. Öncelikle imgeler bölütlenmiştir, dokusal (texture) özellikler ortaya çıkarılmıştır, böylelikle özellik çıkarma işlemi gerçekleştirilmiştir. Daha sonra ortaya çıkarılan bu özellikler kullanılarak, beş adet sınıflandırıcı test edilmiştir. Bu çalışma sonucunda çok başarılı sonuçlar elde edilmiştir. Mikroskobik idrar analizi, idrar sistemi ve böbreklerin fonksiyon bozukluğu, enfeksiyon ya da yanması gibi birçok rahatsızlığın erken teşhis bilgisini sağlar [10-12].

Bu idrar analiz yöntemlerinden en ilkel insan gözünün mikroskop yardımıyla elle analiz yöntemleridir [7]. İnsan gözü ile yapılan ilkel gözlemlerde çok zaman harcanması ve yanlış gözlem sonuçlarının çıkma olasılığı yüksektir. Son yıllarda, teknolojinin gelişmesi ile bilgisayar destekli medikal analiz sistemlerinin gelişimi de çok büyük bir ivme kazanmıştır. Artık insan gözüyle yapılan ilkel çalışmalar, yerini bu modern çalışmalara bırakmıştır [12].

Bu çalışmada kullanılan yöntem aşamaları aşağıda maddeler halinde özetlenmiştir:

1. Mikroskop yardımı ile idrar tortusu imgelerinin büyük kümesi oluşturulur.
2. Bu elde edilen mikroskobik idrar tortusu imgeleri, bölütleme işlemine tabi tutulur.
3. Bu bölütlenmiş imgelerin detaylı ayırt edici özelliklerinin ortaya çıkarılması için doku (texture) özellikleri elde edilir.
4. Özellik boyutunun indirgenebilmesi için özellikler arasındaki korelasyon optimum duruma getirilir.

5. Elde edilen bu özellikler, çeşitli sınıflandırıcılara uygulanarak, sınıflandırma işlemi gerçekleştirilmiştir.
6. Elde edilen sonuçlara göre en iyi sınıflandırıcı seçilmiştir.

Bu alanda daha önceden yapılan bazı çalışmalar mevcuttur. Örneğin Li ve diğerleri [13], Gabor tabanlı bir özellik çıkarım yöntemi kullanarak, mikroskobik idrar tortu imgelerinin sınıflandırılması işlemi gerçekleştirilmiştir. Li ve diğerleri [14] ise idrardaki hücrelerin türlerini tespit etmek için dokusal bir imge sınıflandırma çalışması yapılmıştır.

Avcı [9]'nın çalışmasında idrar tortusu imgelerindeki kist hücrelerinin belirlenmesi ve tanınması çalışması yapılmıştır. Bu çalışmada 5'er adet dokusal ve şekilsel özellikler çıkarılarak kist hücreleri sınıflandırılmıştır. Sınıflandırıcı olarak, karar ağaçları sınıflandırıcısı kullanılmıştır.

Ma ve diğerlerinin [8] yaptığı bir başka çalışmada, Yapay Sinir Ağları (YSA) ve Hough dönüşümü kullanılarak, idrar tortusu içerisindeki kan hücrelerinin sayılması işlemi yapılmıştır. Bu çalışmada, idrar tortusu içerisindeki kan hücrelerinin (kırmızı ve beyaz kan hücrelerinin) sayılması için YSA ve Hough dönüşümü temelli bir yöntem sunulmuştur. Bu çalışma sonucunda, kırmızı kan hücreleri için ortalama % 5.28 ve beyaz kan hücreleri için ise % 8.35'lik bir hata oranı elde edilmiştir. Burada, kan hücre imgelerinin bölütlenmesi için Hough dönüşümü, bölütlenmiş bu kan hücre imgelerinin sınıflandırılması için ise YSA sınıflandırıcısı kullanılmıştır.

Daha önceki çalışmalarda bölütlenmiş kan hücrelerinin sınıflandırılması için sırasıyla K-Ortalamlar (K-O), Bulanık C Ortalamalar (BCO), Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları (YSA) sınıflandırıcıları kullanılmıştır [14-16].

Yapılan bir başka çalışmada ise yapay bağışıklık sistemleri temelli mesane kanser teşhisi için çoklu dairesel belirleme çalışması yapılmıştır [9]. Bu çalışmada da belirtildiği gibi, günümüzde mesane kanserinin teşhisinde idrar analizi kullanılmaktadır. Mesane kanseri 19. yy ABD'de kadın ve erkeklerde en yaygın görülen kanser türüdür. Burada kullanılan çoklu-daireli belirleme yöntemi içerisinde Hough dönüşüm ve geometrik karakteristikler kullanılmıştır.

1.2. Tezdeki Orijinal Katkılar ve Tezin Organizasyonu

Bu tez çalışmasında geliştirilmiş ve literatürde ilk defa kullanılan histogram şekline dayalı bir otomatik eşikleme tekniği ile mikroskobik sayısal idrar tortusu imgelerindeki hücrelerin bölütlenme işleminin yüksek hızda ve doğru oranda yapılmıştır.

Bu sistemde kullanılan ve üst üste binen hücre imgelerinin bile birbirinden kolayca ayırt edilip, tanınmasını sağlayan ayrık dalgacık dönüşüm uyarlamalı entropi ve enerji tekniğinin yanı sıra sistemde ilave olarak ortalama değer, standart sapma, ters fark momenti, karışıklık değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değeri gibi istatistiksel özelliklerinde kullanılmıştır.

Bu tez çalışmasında Son Bite Ekleme (SBE) yöntemi uygulanarak, Türkiye'nin neresine gidilirse gidilsin kime ait olduğu belli olan, hiçbir şekilde kayıp olmayacak, daha güvenli imgeler haline getirilmesi sağlanmıştır. Burada elde edilen idrar tortusu imgelerine Son Bite Ekleme (SBE) steganografik güvenlik yöntemi kullanılarak idrar tortusu imgelerinin her biri için ait olduğu hastanın “Adı ve Soyadı”, “ Türkiye Cumhuriyeti (T.C.) Vatandaşlık Numarası”, “Yaşı” ve “Cinsiyeti” gibi kişisel bilgilerinin sayısal imgenin içine gizlenmesi işlemi gerçekleştirilmiştir.

Tezin birinci bölümünde, teze genel bir bakış açısı kazanmaya yönelik olarak temel bilgiler verilmiştir. Diğer bölümlerin organizasyonu ve tezdeki orijinal katkılar ise aşağıda sunulmuştur:

Bölüm 2 de, idrar tortusunda görülen temel hücre çeşitleri sunulmuştur. İdrar tortuları organik ve inorganik olarak ikiye ayrılır. Klinik açıdan önemli olanlar özellikle organik tortulardır. Bu bölümde özellikle, organik idrar tortularından eritrositler, lökositler, epitel hücreleri, silendirler, parazitler, bakteri ve mantarlar, sperm hücreleri, yabancı artıklar ile inorganik idrar tortularından ise sırası ile asit idrarda ve alkali idrarda görülen inorganik idrar tortuları açıklanmıştır.

Bölüm 3 de, temel örüntü tanıma teknikleri ve karar destek sistemleri üzerinde durulmuştur. Buna göre bu bölümde ilk önce örüntü tanıma kavramı tanımlanarak, sahip olduğu her bir bileşeni açıklanmıştır. Örüntü tanıma problemi bir matematiksel olay olarak nitelendirilerek yorumlanmıştır. Örüntü tanıma türleri verilerek, özellikle akıllı örüntü tanıma

yapısı üzerinde durulmuş ve sahip olması gereken özellikler vurgulanmıştır. Daha sonra ise karar destek sistemleri ve tıbbi karar destek sistemleri hakkında bilgi verilmiştir.

Bölüm 4 de, bu tez çalışmasında kullanılan sayısal imge işleme yöntemlerinden bahsedilmiştir. Bu bölümde sırasıyla, imgenin elde edilmesi, renkli sayısal imgeyi gri seviye sayısal imgeye dönüştürme işlemi, sayısal imgelerin filtrelenmesi işlemi, sayısal imgelerde erezyon işlemi, sayısal imgelerin bölütlenmesi işlemi, otomatik sayısal imge eşikleme teknikleri konuları açıklanmıştır.

Bölüm 5 de, temel steganografi yöntemleri vurgulanmıştır. Bu bölümde sırasıyla, bilgi gizlemenin alt alanı olarak steganografinin kullanımı, gizli kanallar, gerçek kimliği saklama, telif hakkı işaretlemesi, temel steganografi kavramı, başlıca teknik steganografi türleri, son bite ekleme yönteminin imge dosyalarına uygulanması konuları irdelenmiştir.

Bölüm 6 da, idrar tortusunda yer alan hücreler ve kristallerin mikroskobik imgelerinin ön işlemi ve özellik çıkarımı için kullanılan yöntemler açıklanmıştır.

Bölüm 7 de, mikroskobik idrar tortusu imgelerinde yer alan hücrelerin sınıflandırılmaları için kullanılan yöntemler anlatılacaktır. Bu bölümde sırasıyla, YSA sınıflandırıcıları, biyolojik sinir ağlarının yapısı, bir YSA'nın ana öğeleri, YSA'da öğrenme ve öğrenme algoritmaları, uyarlamalı ağ tabanlı bulanık çıkarım sistemi sınıflandırıcıları (UATBÇS), UATBÇS mimarisi, UATBÇS için geri yayımlı öğrenme algoritması, ÇDVM sınıflandırıcısı, konuları irdelenmiştir.

Bölüm 8 de, mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için uyarlanan karar destek sistemleri ve uygulamaları konusu irdelenmiştir. Bu bölümde sırasıyla, mikroskobik idrar tortusu imgelerinin elde edilmesi, idrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan değişmez momentler tabanlı karar destek sistemleri, idrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan Hough dönüşüm tabanlı karar destek sistemleri, idrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan uyarlamalı ayırık dalgacık dönüşüm tabanlı karar destek sistemleri, idrar hücrelerinin otomatik tanınması ve sayımı için uyarlamalı ayırık dalgacık dönüşüm tabanlı istatistiksel yöntemlerle güçlendirilmiş karar destek sistemleri konuları açıklanmıştır.

Bölüm 9 da ise, bu tez çalışmasında elde edilen sonuçlar, değerlendirmeler, öneriler ve bu tez çalışmasından çıkan yayınlar verilmiştir.


2. İDRAR TORTUSUNDA GÖRÜLEN HÜCRELER

İdrar tortuları organik ve inorganik olarak ikiye ayrılır. Klinik açıdan önemli olanlar özellikle organik tortulardır [17].


2.1. Organik İdrar Tortuları

1. Eritrositler: Lökositlere göre daha küçük, çekirdeksiz, ortaları soluk, kenarları belirgin hücreler olup iyi korunmuşlarsa açık yeşilimsiye renkte ve yuvarlak görünür. Normal mikroskop sahasında 1-2 tane görülebilir.

İdrarda patolojik olarak; akut glomerulonefrit, böbrek tüberkülozu, sistit, böbrek ve mesane tümör ve taşları, hipertansiyon, kadınlarda menstürasyon günleri ve künt böbrek travmalarında normalden fazla eritrosit görülür. Eritrositler, bazen mantar ve ürat kristalleriyle karıştırılabilir. Bu durumda tortu üzerine bir damla % 3'lük asetik asit ilave edildiğinde eritrositler tamamen erir (Üratlar az erir, mantarlar erimez).




Şekil 2.1. Eritrositlerin mikroskopik görünümü



Şekil 2.2. Eritrositlerin mikroskopik görünümü


2.Lökositler: Normalde her sahada; erkeklerde 2-3 adet, kadınlarda ise 4-5 adet görülebilir. Eritrositlere göre daha büyük ve çekirdekli hücrelerdir. Üriner enfeksiyonlarda bol miktarda idrara geçer. Akut ve kronik apandisitte, pyüride (idrarda iltihap bulunması) idrarda lökosit görülür. Lökositlerin çekirdekleri nedeniyle stoplazmaları granüler yapıdadır. Asit reaksiyonlu idrarda lökositlerin çekirdekleri daha net görülür.



Şekil 2.3. Lökositlerin mikroskopik görünümü

3.Epitel hücreleri: Normalde her sahada 5-6 epitel hücresinin görülmesi normaldir. Kadın idrarında, erkeklere göre daha fazla sayıda epitel hücresi bulunur. Lökositlerden büyük

hücrelerdir. Epitel hücreleri, idrar yollarında bulundukları yerlere göre çeşitli tipte olur. Yassı epitellerin fazla oluşu vaginitlerde ve doğum sonrasında görülür. Kübik epitel hücreleri ise akut ve kronik böbrek yetmezliklerinde görülür. İdrarda çok sayıda epitel bulunduğunda üriner sistemin hangi kısmına ait olduğunu bilmek klinik yönden önemlidir. Epitel hücreleri genel olarak 3'e ayrılır. Kübik, yassı ve silindirik epitel hücreleridir.




Şekil 2.4. Epitel hücrelerinin mikroskopik görünümü

4.Silendirler: Normal idrarlarda bulunmaz. Böbrek glomeruluslarından kan plazma proteinleri geçerse bu proteinler, tübülüslerde sularının emilmesi ve asiditenin artması ile denatüre olarak pıhtılaşır ve tübülüslerin şekillerini alır. Primer filtratın akışına bağlı olarak tübülüslerden idrara geçer. Silendirler iki şekilde görülür.


Gerçek silendirler: Yapılarındaki maddeye göre isim alır.

Hyalin silendir: Parlak, şeffaf, kenarları birbirine paralel, uçları yuvarlaktır. Bazen zor ayırt edilir fakat hiçbir zaman yalancı silendirlerdeki gibi sivri bir ucla sonlanmaz. Diğer silendirlere göre idrarda daha sık görülür.




Şekil 2.5. Hyalin silendirlerin mikroskopik görünümü

Granüler silendir: Bu silendirlerin kenarları düzgün, boyları kısa ve kalın, renkleri koyudur. Granüler silendir, ağır böbrek harabiyetine işaret eder.




Şekil 2.6. Granüler silendirlerin mikroskopik görünümü

Lökosit silendir: Birbirine yapışmış normal veya dejenere lökositler veya hyalin silendir üzerine oturmuş lökositlerden meydana gelmiş silendirdir. Bu silendirleri epitelyal hücre silendirlerinden ayırt etmek güçtür. İdrarda lökosit silendirisinin görülmesi parankim harabiyetine işaret eder.




Şekil 2.7. Lökosit silindirlerin mikroskopik görünümü

Eritrosit silendir: Birbirine yapışmış normal veya dejenere eritrositler veya hyalin silendir üzerine oturmuş eritrositlerden meydana gelmiş silendirdir. Glomerulonefrit, hipertansiyon ve böbrek yaralanmalarında görülür.




Şekil 2.8. Eritrosit silindirlerin mikroskopik görünümü

Epitel silendir: Hyalin silendire epitel girmesiyle oluşur. Böbrek tubulus epitellerinin dökülmesine işaret eder. Çoğunlukla böbreğin parankimal hastalıklarında nadir olarak da akut yaygın nefritin başlangıcında veya kronik parankimatöz nefritte görülür.



Şekil 2.9. Epitel silindirlerin mikroskopik görünümü

Mum silendir: Mat ve homojendir. Sınırları daha belirgin, hyalin silendire göre daha düz ve kısa olup kolay tanınır. Uçları kareli; sanki kırılmış bir görüntü verir. Ağır tubuler hasara işaret eder.



Şekil 2.10. Mum silendirlerin mikroskopik görünümü

Yağ silendiri: Yağ damlacıklarının irili ufaklı bir araya gelerek meydana getirdiği silendirlerdir. Işığı fazla kırmaları ve eterde erimeleri ile diğer elementlerden ayırt edilebilir.



Şekil 2.11. Yağ silendirinin mikroskopik görünümü


Yalancı (pseudo) silendirler: İdrarda bulunmalarının böbrek hastalıkları ile bir ilgisi yoktur. Mukuslar üzerine değişik maddelerin toplanması ile oluşur. Yalancı silendirler, kenarlarının birbirine paralel olmayıp uçlarının sivri bir şekilde sonlanması ve çok uzun olmaları ile gerçek silendirlerden ayırt edilir. Dikkat edilmediği takdirde gerçek silendirlerle karıştırılabilir.

5. Parazitler: Çeşitli parazitlerin kendileri, larvaları ya da yumurtaları görülebilir. En önemlisi vaginitise sebep olan “*Trichomonas vaginalis*”tir. Ucu kamçılı damla şeklinde görülür.




Şekil 2. 12. *Trichomonas vaginalis*'in mikroskopik görünümü

6. Bakteri ve mantarlar: Normalde idrarda bulunmaz. Taze idrar incelemesinde görülürse idrar yollarında bakteri ve mantar enfeksiyonuna işaret eder. Genellikle piyelonefritte görülür. Bakteri ve mantarların bir araya gelmesiyle silendir görünümü oluşabilir.



Şekil 2. 13. Bakteri ve mantarların mikroskopik görünümü

7. Sperm hücreleri: İdrarda uzun süre şekillerini muhafaza eder. Cinsel ilişki sonrası, genital organ hastalıklarında ve sara nöbetlerinde idrarda görülür. Yumurta şeklindedir. Kuyruklu ve başı küçük bir görünüme sahiptir.



Şekil 2. 14. Sperm hücrelerinin mikroskopik görünümü

8. Yabancı artıklar: İdrara dışarıdan karışmış nişasta tanecikleri, saç, tüy, lif, iplik ve pamuk gibi artık maddelerdir [1].



Şekil 2. 15. Yabancı artıkların mikroskopik görünümü

2.2. İnorganik İdrar Tortuları

İnorganik tortuların klinik değeri azdır. Herhangi bir kristalin sürekli olarak yüksek çıkması taş oluşumu bakımından önemlidir. İnorganik maddelerin büyük bir kısmı idrarda erimiş olarak bulunur. Her birinin kendine özgü şekli vardır. Genelde tipik şekilleri olduğundan karışmaz [17].

Oluşum mekanizması: İdrardaki değişikliklere bağlı olarak çözünemez kompleks yapıda inorganik maddeler oluşur. Bu oluşuma neden olan etkenler şunlardır:


- İdrarda tuz artışı

- Metabolik durum
- Diyet
- Sıvı alımı
- pH, sıcaklık
- İdrarın mesanede bekleme süresi

2.2.1. Asit İdrarda Görülen İnorganik İdrar Tortuları


Ürik asit, amorf ürat, kalsiyum oksalat, kalsiyum sülfat, sistin, bilirubin, lösin ve tirozin kristalleri olabilir.[2]

1. Ürik asit kristalleri: Ürik asit, protein yıkım ürünüdür. İdrara geçen ürik asit pH 5,0-5,5 civarında kristalleşebilir. Sarı-kahverengi veya renksizdir. Kama, halter, baklava, prizmatik rozet, kübik, oval, düzensiz, altıgen tabakalar hâlinde görülebilir. İdrarda görülmeleri, patolojik bir değer taşımaz. Kristaller, katı bir madde etrafına toplanarak kolaylıkla taş yapabilir. İdrarda kanla birlikte kümeler hâlinde ürik asit kristalleri görülmesi, genellikle idrar kesesinde veya böbrekte taşa işaret eder. Santrifüj sonrası tüpün dibinde pembe bir çökelti oluşturur. Genelde gut, glomerulonefrit, akut ateşli hastalıklarda görülür.




Şekil 2. 16. Ürik asit kristallerinin mikroskopik görünümü

2.Kalsiyum oksalat kristalleri: En sık görülen kristaldir. pH 6-7 civarında oluşur. Genellikle zarf şeklinde ve oldukça parlak görünür. Nadiren yuvarlak, halter şeklinde görülür. Taze idrarda kümeler hâlinde, eritrosit ve lökosit ile beraber görülmesi taş oluşumu açısından önem taşır. Ispanak, portakal, domates, sarımsak, ve meyan kökü gibi okzalik asit yönünden zengin besinler alındığında görülür.[3]




Şekil 2. 17. Kalsiyum oksalat kristallerinin mikroskopik görünümü

3.Amorf ürat kristalleri: Mikroskopik olarak sarı, pembe, turuncu, tuğla ve balçık renginde çökelti oluşturur. Mikroskopta küçük tanecikler hâlinde ve genellikle küçük topluluklar oluşturmuş hâlde görülür. Silindir şeklinde toplanabilir ve bu durumda granüler silindirlerden güç ayırt edilir. İdrar bekletilirse özellikle amorf fosfat veya üratlar çöker. Bazen idrar kavanozunun yarısını dolduracak şekilde üratlar çökebilir. Yüksek ateş ve sıvı kaybı durumunda görülebilir. [2]



Şekil 2. 18.Amorf ürat kristallerinin mikroskopik görünümü

4.Sistin kristali: İdrarda; renksiz, altıgen şeklinde nadiren görülür. Protein metabolizması bozukluğundan kaynaklanır. Wilson hastalığında görülür.




Şekil 2. 19. Sistin kristallerinin mikroskopik görünümü

5.Tirozin kristali: Sarı, kırmızı ya da renksizdir. Demetlenmiş iğne veya ekin şeklinde ve tek olarak da bulunabilir. Protein metabolizması bozukluğundan kaynaklanır. Protein yıkımı, fosfat zehirlenmesi, karaciğer sirozu, ağır tifo, lösemi gibi hastalıklarda görülür.




Şekil 2. 20. Tirozin kristallerinin mikroskopik görünümü

6. Lösin kristali: Sarı kahverengidir. Küre şeklinde görülür. Protein metabolizması bozukluğundan kaynaklanır.



Şekil 2. 21. Lösin kristallerinin mikroskopik görünümü

7.Kolesterol kristali: Renksizdir. Bir ya da birkaç köşesi kesik veya çentikli, geniş, yassı, dikdörtgen tabakalar şeklinde görülür. Kolesterol dipteki idrar çökeleğinde değil üstteki berrak sıvının üzerinde bir zar hâlinde bulunur. Dondurulmuş, beklemiş idrarlarda nefrotik sendrom, glomerülonefrit, sistit ve pyüri gibi hastalıklarda görülür. [1]



Şekil 2. 22. Kolesterol kristallerinin mikroskopik görünümü

8. Kalsiyum sülfat kristali: İdrarda nadir olarak görülür. Uzun, renksiz iğne ve uzun prizmalar şeklinde görülür.



Şekil 2. 23. Kalsiyum sülfat kristallerinin mikroskopik görünümü


9. Bilirubin kristali: Baklava, iğne ve granüler şekillerde görülür. Sarı, kırmızı ve kahverengidir. Biluribin yüksekliği, sarılık, karaciğer kanseri, karaciğer sirozu, tifo, kızıl, fosfor zehirlenmeleri durumunda görülür.



Şekil 2. 24. Bilirubin kristallerinin mikroskopik görünümü

2.2.2. Alkali İdrarda Görülen İnorganik İdrar Tortuları

1. Triple fosfat (amonyum, magnezyum fosfat): Bu kristaller, renksiz ve kolay tanınır. En tipik şekilleri tabut kapağı veya çatı biçimidir. Prizma, mercek, tüy, kanat, yaprağa benzer şekilleri vardır. Patolojik olarak da daha çok idrar yolu enfeksiyonları ve prostat hipertrofisinde görülür.[1]



Şekil 2. 25. Triple fosfat kristallerinin mikroskopik görünümü

2. Amorf fosfat kristalleri: Bu kristaller, alkali idrarda görülürlerse de nötr reaksiyonlu idrarda da görülmeleri mümkündür. Amorf granüllü büyük kümeler hâlinde görülür.



Şekil 2. 26. Amorf fosfat kristallerinin mikroskopik görünümü

3. Amonyum ürat kristalleri: Genel olarak alkali idrarda olmakla birlikte nötr ve asit idrarda da görülür. Yer elması, şalgam veya at kestanesi şeklindedir.



Şekil 2. 27. Amonyum ürat kristallerinin mikroskopik görünümü

4. Kalsiyum fosfat kristalleri: Renksiz, geniş, ince, düzensiz noktalı tabakalar ve geniş plaklar şeklindedir. Prizmalar birleşerek rozet veya yıldız şeklinde de görülebilir.



Şekil 2. 28. Kalsiyum fosfat kristallerinin mikroskopik görünümü

3. TEMEL ÖRÜNTÜ TANIMA TEKNİKLERİ VE KARAR DESTEK SİSTEMLERİ

Örüntü, bir nesne veya olay kümesindeki elemanların ardışık olarak düzenli bir biçimde birbirlerini takip ederek yenilenmesi olarak tanımlanabilir [17]. Bir başka deyişle örüntü, belli belirsiz varlıklara verilen isimdir. Parmak izi örüntüsü, el yazısı kelimeleri, insan yüzü, ses sinyalleri, DNA dizilişi temel örüntü kavramlarına örnek olarak verilebilir. En basit örnek bir hafta içerisinde ardışık olarak günler veya bir sene içerisinde ardışık olarak gelen aylardır. Bunlar birer örüntüdür. Örüntü tanıma kavramı yapay zekanın temelidir denilebilir. Yüz tanıma sistemleri, optik karakter okuyucular, parmak izi tanıma sistemleri ve DNA çözümleme sistemlerindeki algoritmalarda hep örüntü tanıma kavramları kullanılır. Örüntü tanıma kavramında kullanılan örüntü bir desen veya bir model olabileceği gibi bir fikir ya da bir kavram da olabilir. Bazı desenler belli bir şeyi tekrar ederek meydana gelirler. Örneğin fayans döşeli bir zemindeki gibi sürekli tekrarlanan bir sıra ve desen bir örüntüdür.

Örüntü tanıma son yıllarda bilgisayar görmesi konusu içerisinde yaygınca kullanılan bir kavram haline gelmiştir. Örüntü, varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen isimdir. Örüntü tanıma kavramı, genellikle ilgilenilen verilerin nicel tanımlama şekilleri olarak adlandırılabilir [19]. Bir başka tanımla ile örüntü tanıma, insanların çeşitli ses, imge ve benzeri tüm verilerin biçimsel şekillerinden çıkardıkları dilsel şekillendirmedir [20]. Günümüzde, örüntü tanıma kavramı bilimde, mühendislikte ve günlük hayatta kısacası bilgisayarın girdiği her alanda uygulanabilmektedir. Örüntü tanıma uygulamalarına imgeden anlamlı ifadelerin çıkarılması ve yorumlanması, ayrıca yüz ve ses tanıma gibi belirsizliklere sahip bir çok etkinlik örnek verilebilir. İnsanlardaki örüntü tanıma yapısı, tabi olarak insanın geçmiş tecrübelerine dayalı öğrenme esaslarıyla alakalıdır. Bundan dolayı, insanlar günlük yaşayışlarında karşılaştıkları örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir yüzü veya sesi belirleyebilmek için kullanılan örüntü tanıma kurallarını tam anlamıyla anlamak ve tanımlamak mümkün değildir. İnsanlar bu örüntü tanıma işlemlerinin bir çoğunu oldukça iyi yapmalarına rağmen, bu örüntü tanıma işlemlerinin daha ucuza mal edilmesi, daha iyi olması, hızlı ve otomatik olarak makinaların yapması istenilen özelliklerdir. Örüntü tanıma kavramı, bu şekilde akıllı ve öğrenebilen makinaları gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [21].

Kısacası aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret ya da imge örneklerini, nesneleri bazı belirlenmiş özellikleri, karakterler aracılığı ile

tanımlama veya sınıflandırma işlemine günümüzde örüntü tanıma denilmektedir [22]. Buradaki esas amaç, tanımlanmamış örüntü sınıflarını biçimlendirmek ve tanımlanmış bir sınıfa ait olan örüntüyü belirlemek şeklinde açıklanabilir.

Literatürde örüntü tanıma uygulamaları bir çok alanda yaygın olarak kullanılmaktadır. Bu alanlardan bazıları, imge işleme, işaret işleme, ses tanıma [23], EEG sınıflama [24], DTMF haberleşme işaretlerini tanıma [25] ve radar hedef sınıflama [26] biyomedikal kontrol [27]'dür. Ayrıca, ingilizce el yazısı tanıma, çince el yazısı tanıma, parmak izi tanıma, biyometri tanıma, otomatik navigasyon, mikroskoptaki dataları kullanarak kanserli hücreyi belirleme, uydu verilerini kullanarak arazileri sınıflandırma, uydu verilerini kullanarak bina ve apartmanları tanıma, plaka tanıma, küçük veri dizilerini kümeleme gibi uygulama alanlarında da çokça kullanılmıştır. Mekanizma olarak bir örüntü tanıma kavramı, Şekil 3.1. de gösterildiği gibi üç önemli aşamadan oluşmaktadır [28].



Şekil 3. 1. Temel örüntü tanıma aşamaları

Bunlar:

- **Ön İşlem Aşaması:** Ön işlem aşaması, imge işleme, işaret işleme ve örüntü tanıma sistemlerinin ilk aşamasıdır. Bu aşamada, örüntü tanıma çalışmasında işlenecek olan imge veya işaret istenmeyen gürültülerden arındırılmak üzere filtrelendir, filtrelenen bu veriler çeşitli morfolojik işlemlerden geçirilerek, dönüşüm ve gösterim teknikleri uygulanır, bileşenlerine ayrılır veya modellenir.
- **Özellik Çıkarım Aşaması:** Özellik çıkarım aşaması, imge ve işaretin veri boyutunun azaltıldığı ve tanımlayıcı anahtar özelliklerinin belirlendiği ve aynı zamanda normalize

edildiği örüntü tanıma sistem aşamasıdır. Bu özellik çıkarım aşaması, örüntü tanıma sistemin başarımında en etkili rolü oynayan kısımdır.

- **Sınıflandırma Aşaması:** Sınıflandırma aşaması, elde edilen özellik vektör boyutunun azaltıldığı ve formüle edildiği belirleyici karar aşamasıdır.

3.1. Örüntü Tanıma Kavramı

Örüntü tanıma kavramının biçimsel amacı, gerçek giriş uzayındaki T adet $\{x_k\}_{k=1}^T$, $x \in X \subset \mathbb{R}^T$ gözlemleri veya ölçümleri, birkaç sınıftan $y \in Y \equiv \{s^{(1)}, s^{(2)}, \dots, s^{(L)}\}$ birine sınıflandırmak suretiyle tanımlayabilmektir. Sınıflandırılmış çıkışı, karar uzayındaki her bir $s^{(L)}$ sınıfı temsil etmektedir [29].

Giriş imge ya da işaret uzaylarını sınıflandırmada, imge ya da işaret örüntüsünün boyutunun çok fazla olması ve gürültü gibi engelleyici unsurlar mevcuttur. Bu problemlerin üstesinden gelebilmek için imgeden ya da işaretten özellik çıkarımı yapılır.


Herhangi bir örüntü tanıma sistemine öğrenme yeteneğinin kazandırılabilmesi için genellikle T adet giriş işaret ya da imgesi ve çıkış sınıf türü içeren (t, z) eğitim çiftinden oluşan S eğitim kümesi kullanılır.

$$S = \{(t^{(1)}, z^{(1)}), (t^{(2)}, z^{(2)}), \dots, (t^{(N)}, z^{(N)})\} \quad (3.1)$$

Burada (N) ifadesi eğitim kümesi içindeki i . örüntü – sınıf çiftini göstermektedir.

Örüntü tanıma sistemleri gözlenen veya ölçülen işaret veya imge verilerinin tanımlanmasında bir çok uygulamada önemli bir yerdedir. Şekil 3.2. de temel bir örüntü tanıma sistemi blok diyagramı verilmiştir [22], [30]. Kullanılan algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumdan bir veya birkaçı olabilen bazı fiziksel işaret ve imgeleri ölçerler. Aşağıdaki genel örüntü tanıma sistemi blok diyagramının en önemli görevlerinden biride, elde edilen işaret ya da imge ölçümlerinin hepsinden oluşan giriş

uzayından daha az boyutta özellik çıkartmaktır. Üçüncü süreçte yani sınıflandırma sürecinde ise sınıflandırıcı bu elde edilen özellikleri türlerine göre sınıflandırma işlemini yapmaktadır.



Şekil 3. 2. Bir örüntü tanıma sistemi blok diyagramı

Günümüzde kullanılan örüntü tanıma sistemleri hakkında daha fazla bilgi için [20-22]'e bakılabilir.

3.1.1. Ön İşlem Süreci

Örüntü tanıma sistemlerinin ön işlem sürecinde, algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Ön işlem süreci, örüntünün (nesne, olay, süreç, işaret veya imge) algılandığı, işaret veya imgenin filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır [31].

Ön işlem sürecinde kullanılacak yöntemlerin işlenecek örüntüye uygunluğu, bu süreçten sonra gelecek özellik çıkarma, sınıflandırma ve test süreçlerinde daha etkili sonuçlar vermesini sağlayacaktır. Bundan dolayı ön işlem süreci, bir örüntü tanıma sisteminin doğru tanıma başarımını etkileyen unsurların başında gelmektedir.

3.1.2. Özellik Çıkarma Süreci

Örüntü tanıma sistemlerinin özellik çıkarma süreçlerinde, örüntüden elde edilen özellikler, sınıflandırıcının doğru sınıflandırma performansını büyük ölçüde etkilemektedir. Bundan dolayı, bir örüntü tanıma sisteminde en önemli süreç özellik çıkarmadır. Başka bir deyişle bu süreç örüntü tanıma sisteminin başarımında anahtar rolü oynar [31]. Giriş imge ya da işaret örnekleri arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Literatürde, birçok alanda çok fazla örüntü tanıma çalışmaları yapılmıştır. Bu örüntü tanıma üzerine yapılan güncel çalışmalarda çok başarılı sonuçlar veren işaret ya da imge örüntülerini sınıflandıran sınıflandırıcı türleri kullanılmış olup, ayrıca bu çalışmalarda sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarma üzerine yoğunlaşmıştır [32]. Örüntü tanıma uygulamalarında, özellik çıkarma işlemlerinin yapılmasındaki en önemli amaç işaret ya da imgelerden elde edilen ölçüm veya örnek uzayının daha küçük boyutlara dönüştürülmesini sağlamaktır. Böylelikle sınıflandırıcı daha yüksek doğru tanıma başarımlarına erişir ve karar süreci daha kısa sürede gerçekleşir [20]. Bir örüntü tanıma işleminde işaret ya da imge örüntü özellikleri belirlenirken esas problem verilen gerçek işaret ya da imge örüntüsünden en iyi özellikleri çıkarmaktır.

3.1.3. Sınıflandırma Süreci

Örüntü tanıma işlemlerinin üçüncü süreci sınıflandırma sürecidir. Bu sürecin amacı, işaret ya da imge örüntülerini özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Burada gerçekleştirilmesi gereken en önemli unsur, yapılan örüntü tanıma uygulamasına en uygun sınıflandırıcı türünü seçmektir. Bir önceki özellik çıkarım sürecinde belirlenen özelliklerin iyi seçilmiş olması sınıflandırma sürecinde başarımında büyük rol oynamaktadır.

Örüntü tanıma sistemlerinde kullanılan sınıflandırıcılar temel olarak klasik ve akıllı sınıflandırıcılar olmak üzere ikiye ayrılmaktadır. Bu sınıflandırıcı türleri aşağıdaki gibi açıklanabilir:

- *Klasik Sınıflandırıcılar:* Klasik sınıflandırma algoritmaları genellikle Bayes istatistiksel karar teorisi üzerine inşaa edilmiştir. Bu tür sınıflandırıcıların en büyük dezavantajları, özellik uzayını kullanarak sınıflandırma uzayını oluştururken, istenmeyen etkilerin (gürültü v.b.) meydana gelmesi ve her bir sınıf için hata kriterinin belli olmamasıdır [33]. En yakın komşuluk sınıflandırıcısı, Bayes karar teorisi sınıflandırıcısı, çok değişkenli Gauss modelleri, maksimum olabilirlik, ikili ağaç sınıflandırıcıları ve Fisher'in doğrusal sınıflandırıcıları klasik sınıflandırıcılara örnek olarak verilebilir [28].
- *Akıllı Sınıflandırıcılar:* Akıllı sınıflandırıcılar, parametre eğitimi tabanlı sınıflandırıcı türleridir. Bu sınıflandırıcıların, genelleme yetenekleri, örüntü tanıma uygulamalarının çok büyük boyutlu verileri açısından önemlidir. Bu sınıflandırıcılara örnek olarak, UATBÇS sınıflandırıcıları, bulanık mantık sınıflandırıcıları ve YSA tabanlı sınıflandırıcılar ile DVM sınıflandırıcıları verilebilir. Bu akıllı sınıflandırıcılar, son zamanlarda yapılan örüntü tanıma çalışmalarında diğer klasik sınıflandırıcılara göre daha yüksek doğru sınıflandırma başarımları elde etmiş, çok güçlü sınıflandırıcı türleridir. Bundan dolayı bu tez çalışmasında gerçekleştirilmiş örüntü tanıma ve karar destek uygulamalarında akıllı sınıflandırıcı türlerinden olan, YSA, UATBÇS ve DVM sınıflandırıcıları kullanılarak, bu sınıflandırıcıların doğru sınıflandırma performansları karşılaştırılmıştır.

3.2. Karar Destek Sistemleri

Karar destek sistemi, herhangi bir alanda çalışanların karar vermesine yardımcı olarak kullanılan, karar verme sürecinde kullanıcıların sistemle karşılıklı olarak etkileşimde bulunduğu, bilgisayar tabanlı bir bilişim sistemidir [34]. Bir başka tanıma göre insanların karar vermelerinde yardımcı olan bilgisayar tabanlı bilgi sistemlerine karar destek sistemleri denir.

Karar destek sistemleri, genellikle yapılandırılması tamamlanmamış problemlerin çözümünde kullanılmakla birlikte, yapılandırılmış ve yapılandırılmamış problemler için de kullanılabilir [35]. Karar destek sistemlerinin kullanımıyla, karar vermenin güç olduğu karmaşık sistemlerde daha hızlı ve daha isabetli kararlar verilebilmektedir.

Karar destek sistemleri, verilerin ve modellerin daha etkili kullanımını sağlayarak karmaşık problemlerin çözümüne katkıda bulunurlar. Bunları yaparken karar destek sistemleri

insanların tek başına yapamadıkları ve genellikle hatayla sonuçlanan herhangi bir problemi iyi ifade edememe, yenilikleri ve öncelikleri kestirememe, zayıf olasılık tahmininde bulunma, kendine aşırı güven duyma ve düşünsel olarak bir araya getirme ön yargısı gibi durumlar mevcuttur. Buna karşılık karar destek sistemlerinin karar işlemlerini yapısallaştırma, tekrarlanan kararlar verme, organizasyonel planlama yapma, organizasyonel kontrol yapma, kararları otomatikleştirme yetenekleri mevcuttur.

Karar destek sistemlerinin yararları ise şu şekilde sıralanabilir:

Hızlı cevap verebilme yeteneğinin olması, anında analiz yeteneğinin olması, yeni anlayışlar ve öğrenme yeteneğinin olması, gelişmiş haberleşme yeteneğinin olması, kontrol yeteneğinin olması, maliyeti düşürme yeteneğinin olması, daha iyi karar verebilme yeteneğinin olması, daha etkin grup çalışması yapılabilmesi, zaman tasarrufu, veri kaynaklarını daha iyi kullanma yeteneğinin olmasıdır.

Karar destek sistemleri yapısal olarak, veri besleme sistemleri, tahmin sistemleri, tercih belirleme sistemleri, senaryo geliştirme sistemleri şeklinde çeşitlere ayrılabilir.

Karar destek sistemleri karar vericilere, problem çözme işlemi sırasında bir birinden farklı çözümleri test etme ve verileri tekrar gözden geçirme imkanı verir [36]. Karar destek sistemlerinde her sorun için çözüm seçenekleri formüle edilir ve bilgisayara gönderilir. Bilgisayar bu önerileri karşılaştırarak değerlendirir ve karar vericiye yollar. Karar destek sistemlerinde değerlendirilen öneriler arasından en iyi sonucu veren alternatif yöntem seçilir ya da yeni bilgilere göre yeni alternatif yöntemler hazırlanarak tekrar bilgisayarın değerlendirmesine sunulur [37].

3.2.1. Tıbbi Karar Destek Sistemleri

Günümüzde tıbbi karar destek sistemlerinden sağlık kuruluşlarında, bilişim sistemleri, yönetim hizmetleri, hastalıkların teşhis edilmesi, hekimlerin hastayla ilgili vereceği kararların desteklenmesi, hemşire ve hekimlerin yapacağı işlerde rehberlik, sinyal yorumlama, laboratuvar hizmetleri ve hasta yönetimi gibi çok çeşitli alanlarda yararlanılmaktadır [38].

Tıbbi karar destek sistemleri, hekimlere veya diğer sağlık personeline alacağı tıbbi kararlarda destek sağlayan bilgisayar programlarıdır. Bu sistemler bir bakıma karar desteği sağlamak için tıbbi veri ya da medikal bilgiyle ilgilenen bilgisayar sistemleridir [39].

Günümüzde, hekimler tıbbi veri miktarında meydana gelen artış nedeniyle bu verilerin yönetimini sağlamak ve uzman yokluğunda uygun seçenekler arasında karar verebilmek için karar desteğine ihtiyaç duymaktadırlar. Bundan dolayı, tıbbi konularda yorum yapma özelliğine sahip kompleks bilgisayar programları olan tıbbi karar destek sistemlerini kullanmaktadırlar [40].

Bu tıbbi karar destek sistemleri, hastalığın tespiti, tedavi seçenekleri, hangi ilaç kullanılması gerekliliği konularında uzman alan bilgisine sahiptirler. Bu tıbbi karar destek sistem bilgisayar programlarının temelinde <Eğer- İse > sorgusu vardır. Buna göre bu bilgisayar programları en iyi olasılığı tahmin etmeye çalışırlar. Bu tıbbi karar destek sistem bilgisayar programlarında bulunan değerler tanımlara uyuyorsa o zaman kesin sonuca varılmıştır anlamına gelmektedir [41]. Bu tıbbi karar destek sistemleri, güncel bilgileri kullanarak ve hastaya ait özel bilgileri de dikkate alarak, hekimlerin hastayı en iyi biçimde değerlendirmesi yönünde yardımcı olur. Bu tıbbi karar destek sistem programlarından bazıları, tıpçılar tarafından girilen temel tıbbi bilgileri dikkate alarak teşhis işlemlerini hızlandırmakta, hastalara ilaç tavsiyesinde bulunabilmekte [42] ve hastalara ait özel bilgileri uzman veri tabanı ile karşılaştırarak hasta yönetimi ve konsültasyon işlevini gerçekleştirmektedir [43].

Tıbbi karar destek sistemlerini 3 madde şeklinde sınıflandırabiliriz;

- 1) **Bilgi yönetimi için kullanılan karar destek sistemleri:** Bilgi yönetimi için karar destek sistemleri, hekimlerin ve sağlık personelinin ihtiyaç duyacağı bilgi ve verileri sağlamakla birlikte, özel bir kararın alınmasına yardım etmezler. Böyle bir durumda problemin çözümü için gereksinim duyulan bilgiler temin edildikten sonra, karar verme işlemi hekime bırakılır [42].
- 2) **Uyarı ve dikkatin bir alana odaklanması için kullanılan karar destek sistemleri:** Bu tür karar destek programları, kullanıcıların problemleri ve teşhis yöntemlerini hatırlamaları için tasarlanmaktadır. Bu karar destek sistemlerinde basit bir mantık kullanılmaktadır. Örneğin eczacılık karar destek sistemlerinde ilaç etkileri ilgili uyarılar vererek kullanıcıların dikkatinin bu alana çekilmesini sağlamaktadır. Laboratuvar karar destek sistemlerinde ise normal olmayan parametre değerleri belirlenir veya bu normal olmayan değerlerle ilgili açıklamaların listesini verilir [42]. Tıbbi karar destek sistemleri

hekim ve hemřireleri, yanıt vermedeki gecikmelerin kritik olabileceđi olası ciddi durumlara karřı uyarmak için geliştirilmiş olan sistemlerdir [42]. Böylelikle, insan hayatının söz konusu olduđu tıp alanında hekim ve diđer sađlık personeline tedavi sürecinin muhtemel sonuçları hakkında uyarılarda bulunarak arzulanmayan tehlikeli sonuçların ortaya çıkması önlenmiş olur.

- 3) **Uzman karar destek sistemleri:** Bu karar destek programları, hastaların özel verilerine dayalı tavsiyeler ve deđerlendirmeler sunar. Temel olarak karar teorisine ya da maliyet–fayda yaklaşımına dayanan bir mantıkla hareket eder. Bazen de problemlerin çözümü için sayısal yaklaşımlardan faydalanabilir. Örneđin DxPlain gibi bazı teşhis uzman karar destek sistemleri gerektiğinde farklı teşhisleri veya ek bilgileri önerebilir. İnternist gibi karar destek programları ise hastanın semptomlarını deđerlendirerek en olası teşhisi koyabilir. Bazı karar destek sistemleri ise tıbbi bağlamda hasta kayıtlarını özetler ve yorumlar [42], [43].

Uzman karar destek sistemleri temel olarak üç bölümden oluşmaktadır. Bu bölümlerden birincisi: tıp uzmanları tarafından geliştirilen bilimsel tabandır. Bilimsel taban, belirli hastalık grubuyla ilgili kararların nasıl alınacağını göstermektedir. İkinci bölüm, hastadan alınan bilgilerdir. Üçüncü bölüm kurallara dayalı çıkarımlar/sonuçlar üreten motorlar ise; hastadan elde edilen bilgileri, bilimsel tabanda bulunan bilgileri referans kabul ederek işler ve hekimin kullanımına sunmaktadır.

Günümüze kadar tıp literatüründe kullanılmış birçok tıbbi karar destek sistemleri mevcuttur. Ařađıda kullanılan bu tıbbi karar destek sistemlerinin birkaçından kısaca bahsedilmiştir.

- **Leeds Abdominal Ađrı Karar Destek Sistemi:** De Dombal ve yardımcıları tarafından Leeds Üniversitesinde, Bayesian olasılık teorisinden faydalanarak, abdominal hastalıklarla ilgili belirti sürecini inceleyen bir karar destek sistemi geliştirilmiştir. 1960’ların sonunda geliştirilen bu bilgisayar temelli karar destek sistemi, apandisit, peptik ülser, divertikulus, safra kesesi ađrısı, pankreas, ince barsak sorunları ve nedeni açık olmayan abdominal ađrılar şeklinde sınıflandırılabilir tipte hastalıkları bulunan binlerce hastadan elde edilen bulguları deđerlendirerek, nitelikli

verilerin yardımıyla, farklı koşullarda farklı sonuçların ne olacağı üzerine yorumlar yapmaktaydı [44].

- **Internist Karar Destek Sistemi:** Bir başka tıbbi karar destek sistemi olan İnternist projesi 1970’li yıllarda başlamış ve bugün Caduceus olarak devam etmektedir. Harry E. People, JR ve Jack D. Myres tarafından Pittsburgh üniversitesinde geliştirilmiştir. Bu sistemin amacı, dahiliye alanı ile ilgili birçok hastalığı kolay ve hızlı bir şekilde teşhis etmektir. Bu karar destek sistemi, sezgisel yaklaşımı kullanarak problemin çözümüne ulaşmaya çalışır [45].
- **Mycin Karar Destek Sistemi:** Mycin tıbbi karar destek sistemi, 1970’lerde Stanford Üniversitesinde geliştirilmiştir. Bu tıbbi karar destek sisteminin geliştirilme amacı belli kan enfeksiyonlarının teşhisi ve tedavi yöntemlerinin tespitidir. Bu sistem, doktorların yüzeysel yaptıkları fakat çok önemli olan tahminleri yapmak üzere hazırlanmıştır. Mycin tıbbi karar destek sistemi, bir danışma sistemi olup, enfeksiyon hastalıklarının yönetiminde uygun çözümlere konsantre olunmasını hedeflemiştir. Bu karar destek sistemi, hastalara hangi testler yapılmalı, tedavi yöntemi ne olmalı ya da nasıl bir tedavi planı gerçekleştirilmeli gibi sorulara cevap arar [46].
- **Poems Karar Destek Sistemi:** Poems tıbbi karar destek sistemi operasyon sonrası bakım amacıyla geliştirilmiş bir acil bakım tıbbi uzman sistemidir. Bu karar destek sistemi, 1992 yılında az tecrübeli tıbbi personele operasyon sonrası bakımda olan hastalara ait değişik bulguların değerlendirilmesinde öneride bulunması amacıyla geliştirilmiştir. Poems karar destek sistemi, etkileşimli bir şekilde tıbbi personelin uyguladığı standart stratejiyi kullanarak hastaya ait bilgileri alır. Bu bilgiler hastanın öz-soy geçmişi, hastalığının öyküsü, kontrol bulguları ve test sonuçları bilgileridir. Bu bilgilere dayalı olarak Poems karar destek sistemi muhtemel teşhis sonuçlarını açıklar. Poems tıbbi karar destek sistemi, ayrıca hasta kayıtlarını veri tabanında saklayarak benzer durumların teşhisinde kullanılır [46], [47].

4. SAYISAL İMGE İŞLEME YÖNTEMLERİ

Sayısal imge işleme, bilgisayar algoritmaları kullanarak sayısal görüntüler üzerinde çeşitli işlemlerin yapılmasıdır [48-52]. Sayısal işaret işlemenin bir kolu olarak kabul edilen sayısal imge işleme, analog imge işlemeye göre birçok avantaja sahiptir. Sayısal imge işlemede giriş verilerine uygulanabilecek algoritmalar daha fazladır. Ayrıca analog imge işlemeye göre işlem sırasında ortaya çıkabilecek gürültü artışı ya da işaret bozulması gibi problemler önlenir. İmgeler gri seviye ya da renkli olma durumlarına göre iki ya da daha fazla boyutta tanımlanabildiğinden, sayısal imge işleme çok boyutlu sistemler şekline modellenebilmektedir.

Bu durumda imgenin tanımının yapılması gerekmektedir. Kısaca imge, bir nesnenin temsilidir [49]. Sayısal imge işleme ise bir imgeden başka bir imgenin elde edilmesi için kullanılan tekniklerin bütünüdür. Sayısal imge işleme teknikleri, imgenin insan veya bilgisayar tarafından anlaşılabilmesi ya da yorumlanabilmesini sağlamak için kullanılır.

Sayısal imge işlemede kullanılan birçok teknik, 1960'lı yıllardan günümüze kadar uydu görüntüleme sistemlerinde, tele-foto görüntüleme sistemlerinde, tıbbi görüntüleme sistemlerinde, görüntülü telefon uygulamalarında, karakter tanıma ve fotoğraf iyileştirme uygulamalarında kullanılmıştır [48]. Günümüzde bilgisayar teknolojisinin gelişmesiyle artık imgeler gerçek zamanlı olarak işlenebilmektedir. Televizyon standartlarının birbirine dönüşümündeki kullanımı buna örnek olarak verilebilir. Genel amaçlı bilgisayarların daha hızlı hale gelmeleri ile birlikte, sayısal imge işleme alanında yaygın bir şekilde kullanılır hale gelmişlerdir.

Sayısal imge işleme ve bilgisayar görmesi alanı son yıllarda çok büyük aşamalar kaydetmiştir. Bu aşamalar hem teorik hem de pratik alanlarda olmuş, böylelikle de sayısal imge işleme konusu geniş uygulama imkanı bulmuştur. Bu uygulama alanları örnek olarak, sayısal haberleşme, hava durumu tahmini, çoklu ortam sistemleri, malzeme bilimi, robotik, akıllı algılama sistemleri, video imgelerinin sıkıştırılması, imge kalitesinin artırılması, internet ortamında imgelerin iletilmesi, parmak izi tanıma, yüz tanıma, karakter tanıma, uydu fotoğraflarının incelenmesi, radar imgelerinin değerlendirilmesi, elektronik savaş, röntgen, MR (Manyetik Rezonans) imgelerinin incelenmesi, patolojik doku örneklerinin analizi, mikro canlıların boyutlarının otomatik bulunması ve kan hücrelerinin sayımı gibi örnek uygulamalara literatürde rastlanmaktadır [50].

Sayısal imge işleme, imge ile ilgili bazı temel problemlerin çözümü için geliştirilmiştir [51]. Bu temel problemler, veri transferinin kolaylaştırılması için imge sayısallaştırma, kodlama, depolama, zenginleştirme, restorasyon, bölümlendirme ve imge tanıma şeklinde sınıflandırılmaktadır.

Sayısal imge işleme oldukça karmaşık algoritmaların uygulanmasına olanak verir, bu sayede basit konularda ileri teknoloji içeren performans sağlar ve analog imge işleme işlemleri için imkansız olan gerçekleştirmeleri sunar.

Sayısal imge işlemede kullanılan temel basamaklar aşağıda maddeler halinde verilmiştir. Bu işlemler sırasıyla, imgenin elde edilmesi, imgenin yapılması ile herhangi bir imgeden daha değişik bir imge elde etmek amaçlanmaktadır.

4.1. İmgenin Elde Edilmesi

Sayısal imge işleme adımlarının en başında imgenin elde edilmesi gelmektedir. Temel olarak, sayısal imge işlemede imgeleri işleyebilmek için herhangi bir imgenin ilk önce sayısallaştırılması gerekmektedir. Çünkü işlenmemiş bir imge sayısal değildir ve bu yüzden imgeler bilgisayar analizi için doğrudan uyumlu değildirler. Bilindiği üzere bilgisayar sayısal verilerle çalışmaktadır. Bundan dolayı, bilgisayar ile herhangi bir imge üzerinde işlem yapmaya başlamadan önce imge sayısal biçime çevrilmelidir. İmge sayısallaştırmada, herhangi bir imge piksel adı verilen küçük bölgelere ayrılırlar. Bu sayısallaştırma işlemi, en genel alt bölümlere ayırma şeması şeklinde verilen iki boyutlu bir dizi şeklinde yapılır. İmge birbirinden bağımsız piksellerden oluşacak şekilde yatay çizgiler halinde bölünür. Elde edilen sayısal imgede her piksel bölgesinde girilen rakam o imgede ilgili noktaya ait parlaklığı göstermektedir. Bu dönüştürme işleminin kendisine sayısallaştırma işlemi adı verilir. Bu sayısal imge artık gri seviye imgeler için iki boyutlu, renkli imgeler için üç boyutlu veri dizisi olarak bilgisayarda işlenmek üzere hazırdır. İmge sayısallaştırma işlemleri boyunca, bu pikseller programcı tarafından değiştirilebilir. Daha sonra ise elde edilen bu sayısal imgedeki her pikselin gri seviyesi, ilgili noktanın imge ekranı üzerindeki parlaklığını belirlemek için kullanılır. Böylelikle, bu sayısal imge bilgisayar ekranında insan gözü ile görülebilir bir imgeye dönüşmüş olacaktır.

İki boyutlu sayısal bir imge, iki boyutlu bir ışık yoğunluk fonksiyonu $h(i,k)$ olarak tanımlanır. Burada i ve k uzaysal koordinatları, h fonksiyonu ise imgenin $h(i,k)$ noktasındaki parlaklık değerini göstermektedir. Eğer imge renkli ise h bir vektördür ve imgenin (i,k)

noktasında renk bandına uygun her bir parlaklık değerini içerecektir. $h(i,k)$ sayısal imge olarak adlandırılmaktadır. Sayısal imge diğer bir tanımlama ile gri seviye için iki boyutlu, renkli imgeler için üç boyutlu tam sayılardan oluşmuş bir matristir. Sayısallaştırılmış imgedeki parlaklık değerleri, gri seviye değerleri olarak adlandırılır. Sayısal imgeyi oluşturan her bir (i,k) elemanına piksel denir. Bazı sayısal imgeler, yüzlerce hatta binlerce pikselden oluşabilir. Bir sayısal imgedeki piksel sayısı arttıkça imge kalitesi artarken, azalması durumunda da imge kalitesi azalır. Böylece sayısal bir imge matematiksel olarak şöyle tanımlanır;

$$h(i,k) = \begin{bmatrix} h(0,0) & h(0,1) & \dots & h(0,L-1) \\ h(1,0) & h(1,1) & \dots & h(1,L-1) \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ h(L-1,0) & h(L-1,1) & \dots & h(L-1,L-1) \end{bmatrix} \quad (4.1)$$

$0 \leq h(i,k) \leq T-1$, burada L ve T tam sayı değerleridir ve 2'nin ($L=2^n$, $T=2^m$) kuvvetleri olarak gösterilir.

Bir sayısal imgedeki her bir piksel, üç boyutlu dünyada var olan fiziksel nesnelerin bir bölümüne veya tamamına karşılık gelir. Bu fiziksel nesne kendisini aydınlatan ışığın bir kısmını yansıtırken, diğer bir kısmını da absorbe eder. Nesneden yansıyan ışık, bir algılayıcı kullanılarak nesne imgesinin oluşturulmasında kullanılır. Kaydedilen imgenin her bir piksel değeri kullanılan algılayıcıya bağlıdır ve bu algılayıcının yansıyan ışığın spektrumuna cevabı olarak yorumlanır.

4.2. Renkli Sayısal İmgeyi Gri Seviye Sayısal İmgeye Dönüştürme İşlemi

Sayısal imge işlemede genellikle işlemleri kolaylaştırmak için, üç boyutlu renkli sayısal imgeler iki boyutlu gri seviye imgelere dönüştürülmektedir. Bu tez çalışmasında da kullanılan üç boyutlu renkli sayısal idrar tortusu imgeleri sayısal imge işleme teknikleri uygulanmadan önce bu işlemleri kolaylaştırmak için iki boyutlu gri seviye sayısal imgelere dönüştürülmüştür.

Üç boyutlu renkli sayısal imgelerin iki boyutlu gri seviye imgelere dönüştürülme işlemi Denklem 4.2 ve 4.3 kullanılarak gerçekleştirilmektedir [52].

$$Gri = \frac{R + G + B}{3} \quad (4.2)$$

$$Gri = 0.299 * R + 0.587 * G + 0.114 * B \quad (4.3)$$

Burada sırasıyla Gri, gri seviye piksel değeri, R kırmızı renk matrisi piksel değeri, G yeşil renk matrisi piksel değeri ve B mavi renk matrisi piksel değerleridir.

Şekil 4.1’de RGB renk formatındaki bir sayısal imge ile bu sayısal imgenin gri seviyeye dönüştürülmüş hali gösterilmiştir.



(a)




(b)

Şekil 4. 1. (a) RGB renk formatındaki bir sayısal imge (b) Bu sayısal imgenin gri seviyeye dönüştürülmüş hali


4.3. Sayısal İmgelerin Filtrelenmesi İşlemi

Bu tez çalışmasında kullanılacak olan sayısal imgelere, bozucu dış etki ve gürültülerden arındırmak için filtreleme işlemi uygulanmıştır. Bu amaçla median filtreleme yöntemi tercih edilmiştir. Median filtreleme işlemi, doğrusal olmayan bir imge işleme tekniğidir. Median

filtreleme tekniđi, imgenin kenar karakteristiklerini tamamen ortaya ıkarabilmek amacıyla grltnn temizlenmesi iin kullanılan bir ilemdir [53]. Sayısal imgelere median filtreleme ilemi uygulanırken, imgeyi oluřturan her bir penceredeki pikseller sıralanır ve bir median deęeri seilerek piksellerin deęerlerine gre yerleri deęiřtirilir. řekil 4.2’de bir median filtre uygulaması, řekil 4.3’de ise bu uygulama sonucunda elde edilen imge sırasıyla verilmiřtir [52].



řekil 4. 2. Bir median filtre uygulaması



řekil 4. 3. (a) Grlt eklenmiř sayısal imge, (b) 3x3 lk median filtre ile grlt giderme, (c) median filtre uygulaması sonucunda elde edilen grlt giderilmiř sayısal imge

4.4. Sayısal İmgelerde Erezyon İşlemi

Biyolojide canlıların şekil ve yapılarını inceleyen bilim dalına morfoloji (biçim bilim) adı verilmektedir [52]. Sayısal imge işlemede ise morfoloji, temel küme işlemlerine dayanan, imgedeki sınırlar, iskelet gibi yapıların tanımlanması ve çıkartılması, gürültü giderimi, bölütleme gibi uygulamalar için gerekli bir araçtır. Renkli imgeyi gri seviye imgeye dönüştürme, morfolojik filtreleme, gürültü giderme, erezyon, yayma gibi işlemler sayısal imge işlemenin ön işlem aşamasında en çok kullanılan morfolojik işlemlerdir. Bu işlemler gri tonlu sayısal imgeler üzerinde yapılabileceği gibi, genellikle ikili imgeler üzerinde de yapılan işlemlerdir. Bu tez çalışmasında idrar tortusu imgelerine erezyon işlemi uygulanarak, sayısal imge işlemeye daha uygun hale getirildikleri için bu bölümde erezyon işlemi üzerinde durulmuştur. Morfolojik işlemlerden biri olan erezyon işleminde, Z^2 uzayında verilen A ve B kümeleri için erezyon işlemi Denklem (4.4)'de verilmiştir.

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (4.4)$$

Şekil 4.4'de sayısal imgeye uygulanmış bir erezyon uygulaması verilmiştir [52].



Şekil 4. 4. (a) Sayısal imge, (b) Sayısal imgeye uygulanmış bir erezyon uygulaması

4.5. Sayısal İmgelerin Bölütlenmesi İşlemi

Sayısal imgelerin işlenmesi adımlarından beşincisi ve en zoru imge bölütlemedir. Yapılacak sayısal görüntü işlemenin başarılı olup olmaması, bölütlenmenin başarılı olup olmamasına bağlıdır. Sayısal imge bölütlemenin literatürde, birkaç farklı tanımı mevcuttur. Bu tanımlardan ilkinde, sayısal imge bölütleme işlemi bir sayısal imgenin kendini oluşturan

parçalarına veya nesnelere ayrılmasıdır. İkinci bir tanımda ise, sayısal imge bölütleme işlemi, aynı karakteristiğe sahip alanların çıkartılması, arka plandan ayrılması, belirgin bir hale getirilmesidir. Sayısal imge bölütleme işlemine, bir otobandaki arabaların çekip çıkartılması, birden fazla hücre bulunan bir ortamda istenilen hücrelerin ayırt edilerek çıkarılması veya iç içe nesnelerin ayrılması örnek olarak verilebilir. Toplu hücre imgesi düşünüldüğünde, yapılan ilk işlem bu imgenin bölütlenmesidir. Daha sonra toplu hücre imgesinin alt bölmelerinin potansiyel hücre boyutlarına karşılık gelip gelmediği kontrol edilir. Belirtilen büyüklük bulunamaz ise imgenin o bölmesi üzerinde hücre olmadığı anlaşılır. Sayısal imge bölütleme işlemi, imgeden tüm nesneler ayrıldığı zaman son bulur. Bulunan bölmeler herhangi bir nesne olabileceği gibi farklı bileşenlerde olabilir.

Bu tez çalışmasında sayısal imge bölütleme işlemi için otomatik eşikleme yöntemi kullanıldığı için bu bölümde otomatik eşikleme yöntemleri üzerinde durulmuştur. Sayısal imge eşikleme, bilgisayar görmesi ve sayısal imge işlemede önemli rol oynar. Doğru eşik noktasını otomatik olarak bulmak, sayısal imge işlemenin temel problemlerinden birisidir. Yapılacak sayısal imge bölütlemenin güçlü olabilmesi için eşik noktalarının doğru ve otomatik seçilmesi gerekmektedir.

Genel olarak sayısal imge eşiklemeyi 5 sınıfa ayrılmaktadır [54]. Bunlar, histogram şekil tabanlı, entropi tabanlı, küme tabanlı, nesne özellik tabanlı ve uzaysal korelasyon tabanlı olarak adlandırılmaktadır. En basit şekilde eşikleme yapabilmek için sayısal imge gri seviyeye çevrilir ve bir eşik noktası alınarak sayısal imge eşiklenir.

$$\text{If } h(i,k) > E \text{ then } h(i,k) = 0 \text{ else } h(i,k) = 1 \quad (4.5)$$

Yukarıdaki kuralda $h(i,k)$ gri seviyeli sayısal imgeyi ifade etmektedir. E değeri ise eşik noktası göstermektedir. Yukarıdaki Denklem (4.5)'e göre sayısal imgede, E değerinden büyük olan değerlere 0, küçük ve eşit olan değerlere 1 değeri atanmaktadır.

Bu eşikleme tekniği en basit tekniktir. Bu tekniği uygulayabilmek için her sayısal imge için farklı bir E noktası seçilmesi gerekmektedir ve bu işlem de sistemlerin otomatik çalışmasını engellemektedir. Bundan dolayı otomatik eşikleme tekniklerinin kullanılması şart olmuştur. Histogram tabanlı otomatik eşikleme tekniklerinde, sayısal imgede tepe ve vadi

noktaları belirlenmektedir. Belirlenen tepe ve vadi noktalarına göre bulunan en uygun otomatik eşik değerleri seçilerek eşikleme işlemi yapılmaktadır. Entropi tabanlı otomatik eşikleme sistemlerinde ise Shannon, Cross ve Renyi entropi kullanılmaktadır. Entropi tabanlı otomatik sayısal imge eşikleme teknikleri için kullanılabilecek en iyi entropi türü Renyi entropidir [55].

4.5.1. Otomatik Sayısal İmge Eşikleme Teknikleri

Sayısal imgeleri analiz edebilmek için ilgili sayısal imgeyi bölütlemek gerekmektedir. Örneğin sayısal imgedeki nesneleri sayabilmek için en çok kullanılan teknik sayısal imge bölütlemesidir. Sayısal imge bölütleme işlemi yapıp imgelerin sınırlarını belirleyebilmek için ikili imgelere ihtiyaç duyulmaktadır. Bu noktada otomatik sayısal imge eşikleme yöntemleri devreye girmektedir. Otomatik sayısal imge eşikleme teknikleri 6 ana gruba ayrılmaktadır. Bu teknikler aşağıdaki gibi özetlenmiştir:

- **Histogram Entropisine Dayalı Otomatik Sayısal İmge Eşikleme Teknikleri:** Bu teknikte temel olarak, sayısal imgenin histogramının entropi bilgisi referans alınarak otomatik eşikleme noktası çıkarımı hedeflemektedir. Bu otomatik eşik değeri bulma tekniklerinin bazılarında eşiklenmiş sayısal imgenin entropisi en büyük olacak şekilde eşik değeri belirlenmeye çalışılırken, bazıları ise gri seviyeli sayısal imge ile eşiklenmiş sayısal imge arasındaki en büyük değeri bulmayı hedeflemektedir. Histogram entropisine dayalı otomatik sayısal imge eşikleme yapabilmek için genelde Shanon ve Renyi entropi kullanılmaktadır.
- **Histogram Şekline Dayalı Otomatik Sayısal İmge Eşikleme Teknikleri:** Histogram şekline dayalı otomatik sayısal imge eşikleme tekniklerinde ise histogramdaki vadi ve tepe noktaları bulunmaya çalışılmaktadır. Böylece arka plan ve nesne tespiti yapılabilir. Bu histogram şekline dayalı otomatik sayısal imge eşikleme tekniği kullanan bazı algoritmalar ise histogram kıvrımları ve eğrilerini bulmaya çalışmaktadır. Bu teknikte tek bir eşikleme noktasının referans alınmasının yanı sıra birden fazla eşikleme noktası da referans alınmaktadır. Bu tez çalışmasında da bölütleme aşamasında histogram şekline dayalı otomatik sayısal imge eşikleme tekniği kullanılmıştır.

- **Ölçüm Uzayında Topaklandırmayı Kullanan Otomatik Sayısal İmge Eşikleme Teknikleri:** Bu otomatik eşikleme tekniği iki gruba ayrılmaktadır. İlk grupta çeşitli istatistiksel analizler yaparak sayısal imgelerin otomatik eşiklenmesi hedeflenmektedir. Diğer gruptaki teknikler ise iki Gauss dağılımının karışımı olduğu varsayılarak nesne ve arka planı çıkarmayı amaçlamaktadır.
- **Uzamsal Özellikleri Kullanan Otomatik Sayısal İmge Eşikleme Teknikleri:** Uzamsal özellikleri kullanan otomatik sayısal imge eşikleme tekniklerinden bazılarında sayısal imgenin 2 boyutlu histogramını oluşturup bir ölçütünün optimize edilmesi sağlanarak otomatik eşikleme yapılır. Burada genetik algoritma, parçacık sürü optimizasyon teknikleri gibi optimizasyon teknikleri kullanılarak optimizasyon yapılmaktadır.
- **Yerel Uyarılama Kullanan Otomatik Sayısal İmge Eşikleme Teknikleri:** İlk 5 otomatik eşikleme tekniği tüm imge için tek bir eşikleme noktası saptarken, yerel uyarılmalı teknikler ise her bir piksel için yerel özelliklere bağlı olarak ayrı bir eşik değeri hesaplamaktadır. Bu bilgiler, bölgesel değişiklik ve komşu piksellere bağlı olarak mantıklı karar verebilme yeteneği sağlar. Bu yerel uyarılama kullanan otomatik sayısal imge eşikleme tekniklerinde, otomatik eşik değerinin yerel olarak ayarlanabilmesi için birkaç parametre kullanılması gerekmektedir.

5. STEGANOGRAFINİN TEMELLERİ

Son yıllarda gelişen teknoloji ile birlikte günümüz dünyasının en büyük problemlerinden biri bilgi güvenliğini sağlamak olmuştur. Elektronik ortamdaki verilerin çoğalması ve bu verilere erişimin kolaylaşması, ayrıyeten tüm bu gelişmelerle beraber bilgisayar korsanlığı olaylarının da popüler kültürde yerini alması ve cihazların işlem gücünün ve paralel programlama yeteneğinin artmasıyla beraber, bilgi güvenliğinin sağlanması daha da zor bir hal almıştır. Günümüzde bilgi güvenliğinin sağlanması artık kişisel bir sorun olmaktan çıkıp, uluslararası bir problem haline gelmiştir. Siber savaş ve savunma teknikleri, ülkelerin milli savunma stratejilerin de dahi yerini almıştır.


Bilgi ve veri gizleme teknikleri, eski çağlardan günümüze kadar gelişerek kullanılan tekniklerdir. Bu tekniklerin kullanılmasındaki temel amaç, gönderilecek verileri güvenilir bir kanal oluşturup o kanal vasıtasıyla aktarabilmektir. Son yıllarda bilgisayar ve diğer sayısal ortamlarda birçok bilgi ve veri gizleme tekniği geliştirilmiştir ve geliştirilmeye devam edilmektedir [56]. İki kişi arasında yapılan iletişimin bir başka kişi tarafından fark edilmeyecek şekilde gerçekleştirilmesine bilgi gizleme denir. Çeşitli yerlerde ve gönderilecek bilginin önemli olduğu durumlarda bilgi gizleme sıklıkla kullanılmaktadır [57].

Çeşitli devlet birimlerinde, örneğin askeri ve sivil istihbarat birimlerinde, bu birimlerin kendi aralarındaki iletişimin güvenli olması ve gönderilen gizli bilgi ve verilerin başka kişilerce erişilmemesi istenmektedir. Bu gizli veri ve bilgilerin içeriği şifrelense bile bazen korunamayabilir [58].

Bilgi gizlemenin en önemli alt dallarından biri olan steganografi sayısal ortam bilgi ve verilerinin korunması için kullanılmaktadır. Son yıllarda sayısal ortamdaki veri ve bilginin artmasıyla da steganografinin bu alanda kullanımı da artmıştır.

5.1. Bilgi Gizlemenin Alt Alanı olarak Steganografinin Kullanımı

Günümüzde, veri ve bilgi alışverişinin gizli olarak gerçekleştirilebilmesi için çeşitli yöntemler geliştirilmiştir. Kullanılan çeşitli veri ve bilgi gizleme yöntemleri Şekil 5.1.'de gösterilmektedir [59].



Şekil 5. 1. Veri ve bilgi gizleme yöntemlerinin sınıflandırılması

5.1.1. Gizli Kanallar

Veri ve bilgi gizlemenin alt disiplinlerinden biri olan gizli kanallar yöntemi Anderson ve Petitcola tarafından 1998 yılında tanımlanmıştır [60]. İki kişi arasında gizli bilgilerin el değiştirmesi için iletişimi sağlayan kanala gizli kanal denir. Gizli kanallar bilgi gizlemenin ilk alt basamağı olarak tanımlanmıştır [61]. Herhangi bir gizli kanal iki kişinin karşılıklı anlaşmasını gerektirmektedir. Gizli kanalların kullanım amacı ise, iletişimimizdeki veriyi ve ne amaçla kullanıldığını gizlemektir [62].

5.1.2. Gerçek Kimliği Saklama

Bir iletişim ortamında veri ve bilgi gönderimi sırasında, veriyi veya bilgiyi gönderenin gerçek kimliği saklanarak, verinin ve bilginin bilinmeyen ya da anlaşılamayan biri üzerinden gidiyor olduğunun izleniminin verilmesi işlemine gerçek kimliği saklamak denir. Gerçek kimliği saklama yöntemi kullanılarak veri ve bilgi zarar görmeden karşı tarafa gönderilebilmektedir [63], [64].

5.1.3. Telif Hakkı İşaretleme

Kitap veya basılmış yayınların haksız kazanç şeklinde çoğaltılması ve dağıtımının engellenmesi amacıyla bu dökümanların içine bazı bilgiler gizlenmektedir. Bu gizli bilgiler

sırasıyla, telif hakkı sahibi bilgileri, dökümanların üretildiği tarih, üreticiye nasıl ulaşılabilceği bilgileridir. Bu telif hakkı işaretlemesi yöntemi steganografide kullanılmaktadır. Bu tür basılmış yayın ve dökümanlarda kullanılan gizli damga baskısına filigran ismi verilmektedir. Günümüzde sayısal görüntülerde telif hakkı işaretlemesi, sayısal filigran olarak kullanılmaktadır [65].

Günümüzde telif hakkı işaretlemesi kullanılan görüntüler tarama, parlaklık ve zıtlık ayarlarının değiştirilmesi, kâğıda baskı, özel filtrelerin kullanılması, gibi birçok yöntemle karşı dayanıklı olabilmektedirler. Ancak teknolojinin her alanında olduğu gibi bu sayısal filigran alanında da bazı algoritmalar kullanılarak, bir imgede sayısal bir filigran olup olmadığı ve varsa bu sayısal filigranlar çözülebilmektedir. Telif hakkı işaretlemesi yönteminde kullanılan sayısal filigranlar iki çeşide ayrılmaktadır. Bunlar, görünür filigranlar ve görünmez filigranlardır.

5.1.4. Temel Steganografi Kavramı


Steganografi, bir nesnenin içerisine bir bilginin ya da verinin gizlenmesidir. Günümüzde temel steganografi kavramı, dilbilim ve teknik steganografi olmak üzere iki sınıfa ayrılır. Teknik steganografi de bilgi ya da veri, sayısal imge, ses, video imgeleri üzerine saklanabilir [66].

Temel olarak şimdiye kadar kullanılan steganografik uygulamalarda, yukarıda da bahsedilen sayısal imge, ses, video imgeleri üzerinde gizlenmiş veri ya da bilginin saklanması hedeflenmiştir. Böylelikle bir yerden başka bir yere herhangi bir kanal vasıtasıyla gönderilmek istenen veri ya da bilgi saklanarak, üçüncü kişilerin eline geçmesi önlenmiş olacaktır. Gizlenecek verinin ya da bilginin niteliği herhangi bir ses, imge v.b. sayısal veri olabileceği gibi bir metinde olabilir [67], [68].

Temel olarak günümüzde kullanılan steganografi yöntemleri şifreleme işlemlerinden farklıdır. Steganografi veri veya bilginin gizlenmesi işlemi iken, şifreleme işlemi ise bu veri veya bilginin içeriğinin korunması işlemidir [67, 68]. Son yıllarda steganografik yöntemlerdeki gelişmeler ışığında, bu yöntemlerin kullanım alanları da, filigran ve parmak izi, askeri ve sağlık olarak gün geçtikçe genişlemektedir.

5.1.4.1. Başlıca Teknik Steganografi Türleri

Teknik steganografi temel olarak üç sınıftan oluşmaktadır. Bu teknik steganografi türleri Şekil 5.2’de olduğu gibi özetlenebilir [69]:



Şekil 5. 2. Teknik steganografi türleri

5.1.4.2. Son Bite Ekleme Yönteminin İmge Dosyalarına Uygulanması

Son Bite Ekleme (SBE) ya da En Önemsiz Bit (EÖB) yöntemi, günümüzde imge dosyaları içerisine metinlerin gizlenmesi için kullanılan en yaygın steganografik yöntemdir. Bu yöntemin yaygınlığı, kullanımının son derece pratik olmasından kaynaklanmaktadır. Son bite ekleme yönteminin en önemli dezavantajı olarak, dikkatsizce uygulandığında veri kayıplarının ortaya çıkması söylenebilir. Bu yöntemde, imgeyi oluşturan her pikselin her byte’nın en önemsiz biti olan son biti değiştirilir. Bu son bitin yerine gizlenmesi istenilen veri ya da bilginin bitleri sırasıyla veri ya da bilginin başlangıcından itibaren birer birer yerleştirilmektedir. Böylelikle her biri sekiz bitten oluşan imge piksellerinin sadece son biti değiştirildiği için bu piksellerde insan gözünün algılamayacağı kadar az bir değişim ortaya çıkmaktadır. Bu tez çalışmasında da idrar imge verilerine ait oldukları hasta kayıt metinlerinin gizlenmesinde de bu yöntem kullanılacaktır.

6. İDRAR TORTUSUNDA YER ALAN HÜCRELER VE KRİSTALLERİN MİKROSKOBİK İMGELERİNİN ÖN İŞLEMİ VE ÖZELLİK ÇIKARIMI İÇİN KULLANILAN YÖNTEMLER

Bu bölümde, tezde kullanılan idrar tortusunda yer alan hücre ve kristallerin mikroskopik imgelerinin ön işlemi ve özellik çıkarımı için kullanılan Hu'nun Değişmez Momentleri [70], Hough Dönüşümü ve Dalgacık Dönüşümü Yöntemleri sırasıyla irdelenecektir.

6.1. Hu'nun Değişmez Momentleri Yöntemi

İmge işlemede momentler, imge içerisindeki nesnelerin şekilsel ve dokusal ayırt edici özelliklerinin çıkarılması ile daha iyi bir sınıflandırma performansını elde edebilmek amacıyla özellik vektörleri olarak kullanılmaktadırlar. 1960'lı yıllarda önce, Hu isimli bir bilim adamı cebirsel moment teoreminden yararlanarak, 7 adet değişmez moment geliştirmiştir. Bu Hu'nun geliştirmiş olduğu 7 adet değişmez momentler, dönüşümden, döndürmeden ve ölçeklendirmeden bağımsızdırlar yani değişmezler.

Bu Hu'nun 7 adet değişmez momentleri yöntemi, günümüzde el yazısı karakterlerinin tanınması, uçak ve gemilerin tanınması gibi bazı örüntü tanıma uygulamalarında kullanılmaktadır [71].

Literatürde momentler, daha çok istatistiksel ve mekaniksel işlemlerde kullanılmıştır [72]. Momentler, dağılımların ortalamaları, değişimleri, eğrilikleri ve basıklıkları olarak tanımlanır. Klasik mekanik çalışmalarda momentler, kütlelerin merkezini ve eylemsizliklerini bulmak için kullanılır. Resim işlemede ise, nesnelerin şekil tanımlayıcıları olarak momentler, özellik çıkarımında kullanılır. Hu 1960'larda cebirsel moment teoreminden 7 adet değişmez moment geliştirmiştir [70], [73]. Bu 7 adet Hu değişmez moment değerleri, resimlerdeki dönüşüm, döndürme ve ölçeklendirme değişimlerinin etkilerinden bağımsız olarak sabit kalır. Bu yüzden, Hu değişmez momentleri gemi tanıma, uçak tanıma, el yazısı ve karakter tanıma gibi iki boyutlu örüntü tanıma problemlerine uygulanmıştır [74], [75].

Burada $f(x,y)$ bir resim yoğunluk dağılımı olmak üzere, klasik mekanik sistemlerde, $f(x,y)$ için $(s+v)$ dereceden iki boyutlu momentler Denklem (6.1)'de gösterilmiştir:

$$m_{sv} = \iint x^s y^v f(x, y) \cdot \partial x \cdot \partial y \quad (6.1)$$

Burada, s, v= 0, 1, 2 ... olabilir. Genelde bu momentlerin değerleri, herhangi bir bozulma etkisine karşı değişmezdir. Merkez momentleri Denklem (6.2)'deki gibi tanımlanır:

$$\mu_{sv} = \iint (x - \bar{x})^s (y - \bar{y})^v f(x, y) \cdot \partial(x - \bar{x}) \cdot \partial(y - \bar{y}) \quad (6.2)$$

Burada;

$$\bar{x} = \frac{m_{10}}{m_{00}} \text{ ve } \bar{y} = \frac{m_{01}}{m_{00}} \quad (6.3)$$

Merkezi momentler, döndürme etkisine karşı değişmezdir [76]. Merkezi momentler, genellikle boyutlarına göre momentleri normalize etmek için kullanılır. Bu, Denklem (6.4.)'de görüldüğü gibi μ_{00} ifadesi kullanılarak gerçekleştirilir:

$$\eta_{sv} = \frac{\mu_{sv}}{\mu_{00}^r} \quad (6.4)$$


$$r = 1 + \frac{(s + v)}{2}$$

Merkez momentleri ile normalize edilmiş 7 adet Hu değişmez moment aşağıdaki gibi hesaplanabilir [77]:

$$\begin{aligned}
\varphi_1 &= \eta_{20} + \eta_{02} \\
\varphi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11} \\
\varphi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\
\varphi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2 \\
\varphi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
&+ (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
\varphi_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
\varphi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
&- (\eta_{30} - 3\eta_{12})(\eta_{03} + \eta_{21})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
\end{aligned} \tag{6.5}$$

6.2. Hough Dönüşümü Yöntemi

Hough dönüşüm yöntemi, özellikle döndürme, büyültme ve küçültme işlemlerine karşı dayanıklı özelliklerin çıkarımı konusunda 1962'den beri yaygın olarak kullanılmaktadır. Bu yöntem genellikle, dairelerin ve düz çizgilerin yerlerini tespit etmek için kullanılır. Dairelerin tespitinde merkez ve yarıçapa ihtiyaç duyulur. Hough dönüşümü yöntemi, sınıflandırma işleminde şeklin merkezinin tespitinde çok sayıda parametre gerektirdiğinden dolayı dezavantaj sağlar. Bu dezavantajdan dolayı uygulamalarda Hough dönüşüm yönteminin verimi de düşer.



Şekil 6. 1. Hough Dönüşümün uygulanaşı

Burada OA, OC veya OB en uzun yarıçaplardır. En az 3 nokta ve merkez ile yarıçap tespit edilir ve bunlar düz (doğru) çizgi değildir. Bu yolla kullanılacak nesnelerin merkez dairelerinin koordinatlarının hesabı ile yerleri tespit edilebilir. Aynı koordinat noktası 3 farklı

özellik noktasının birleşmesiyle hesaplanabilir ve en uzun yarıçapın değeri bir nesnenin merkezi dikkate alınarak bulunur.

Günümüzde sayısal imge işleme uygulamalarında (örneğin iris, retina tanıma, plaka okuma v.b. uygulamalar) geometrik şekil bulmada yaygın olarak bu Hough dönüşüm yöntemi kullanılmaktadır. Burada bir kamera ya da göz yardımı ile elde edilen imgelerdeki şekillerin bazı noktalarındaki belirsizlikler, (örneğin şekil çizgilerindeki kopukluklar) şeklin tam olarak tespitini zorlaştırmaktadır. İşte bu belirsiz noktaları belirgin hale getirmek için Hough dönüşümü kullanılmaktadır. Hough dönüşümü kullanılarak şekil tespiti genel olarak aşağıdaki gibi gerçekleştirilir:

1. Verilen imge üzerinde kenarlar çıkarılır.
2. Kenarları çıkarılmış imge eşikleme yöntemi kullanılarak, ikili (siyah-beyaz) imgeye dönüştürülür.
3. Bu ikili imgedeki çıkarılan her kenar pikseli için noktanın üzerinde olabileceği geometrik şekillerin polar koordinattaki değerleri kullanılarak, bir toplam matrisi üzerinde birer artırılarak her kenar pikselin olası şekilleri oylaması sağlanır.
4. En çok oyu alan şekil imge üzerinde olma olasılığı en yüksek olan şekil olarak kabul edilir.

6.3. Dalgacık Dönüşümü Yöntemi

Dalgacık Dönüşümü (DD) yöntemi, Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD) olmak üzere ikiye ayrılır.

6.3.1. Sürekli Dalgacık Dönüşümü

Sürekli Dalgacık Dönüşümü (SDD) yöntemi, sıkıştırmalar, genişlemeler ve dönüşümler ile tüm zaman ve ölçeklerdeki işaretler ya da imgeler ile ana dalgacık arasında uygunluğu sağlayan bir tekniktir.

$$SDD(t, z) = - \int_{-\infty}^{\infty} v(k) \frac{1}{\sqrt{t}} \psi\left(\frac{k-z}{t}\right) dk \quad (6.6)$$


Burada $v(t)$ işaret ya da imge, $\psi(t)$ dalgacıktır, t ölçekleme etmeni olup her seviye için ayrışım filtrelerini ölçeklendirir ve z ise dönüşüm etmeni olup, farklı frekans seviyelerinde ayrışım filtreleri tanımlar. Zamanın bir fonksiyonu olarak dönüşüm sonucu, işaret ya da imge ve dalgacık arasında nasıl karşılıklı bir ilişki (korelasyon) olduğunu gösterir. Eğer dalgacık filtresi işarete ya da imgeye uygun olarak seçilmişse, işaret ya da imge ve dalgacık arasındaki korelasyon seviyesi yüksek olur. Dalgacık filtresi türü işarete ya da imgeye uygun olarak seçilmektedir. SDD’de dalgacık, frekansın büyük olduğu yani sıkışık yerlerde işaretin yüksek frekans detaylarını elde eder. Eğer dalgacık tamamen genişse dalgacığın uzunluğu, işaretin uzunluğu ile daha uygun benzerlik sağlar ve böylece işaretin düşük frekans eğilimleri ortaya çıkar. SDD, Fourier analizi kadar iyi sinüzoidal bileşenleri çözemez, fakat onun Kısa Zamanlı Fourier Dönüşümüne alternatif olan ilgi çekici yanı, geçici olayların yerini saptayabilmesidir [78].

6.3.2. Ayırık Dalgacık Dönüşümü

SDD’nün hesaplama yükünün fazla olması ve dönüşümü sağlamak için kullandığı bilgi miktarının oldukça büyük olmasından dolayı uygulamalarda çokça zorluklarla karşılaşmaktadır. Bundan dolayı SDD’den daha etkili bir yol olarak, Ayırık Dalgacık Dönüşümü (ADD)’nin kullanımı uygulamalarda daha sık tercih edilmektedir.

İşaret ya da imgelerin çözümlenmesinde tek bir dalgacık filtresi kullanılarak belirli bir frekans cevabı elde edilebilir ancak işaret ya da imge filtreden geçtikten sonra işaretin ya da imgenin içindeki bilginin bir kısmı kaybolabilir. Bundan dolayı, tek bir filtre, filtrelenmiş işareten ya da imgeden tekrar asıl işareti ya da imgeyi yeniden elde etmek için kaybolmuş bilginin tekrar kazanımı mümkün olmadığından yeterli değildir. İki filtre kullanılırsa, biri düşük frekans bilgisini, diğeri yüksek frekans bilgisini temsil eder. Bir başka deyişle işaret ya da imge içindeki bilginin tümü içerilmiş olunur. Bu aşamadan sonra bu iki yüksek frekansları geçiren ve düşük frekansları geçiren filtrenin çıkışı asıl işareti ya da imgeyi yeniden elde etmek için birleştirilebilir. Ayrıca, kullanılacak olan ayırık dalgacık filtre kümesi veya filtre bankası, spektrum bilgisini ayırmak için kullanılarak işareti ya da imgeyi daha ayrıntılı frekans bantlarına ayırtırmayı mümkün kılar.

ADD, sadece belirli genişlemelerinde işarete bakar. Böylece ADD'nin hız yönünden etkinliği Hızlı Fourier Dönüşümü gibi sabit pencereleme kısıtlı yeteneklere sahip yöntemlerden daha iyi olur. ADD'yi daha iyi kavrayabilmek ve dalgacıkların yerini tam olarak tespit edebilmek için filtre bankası kavramını iyi irdelemek gerekmektedir. Çünkü filtre bankası dalgacıkların ayrık eşdeğerleridir.




Şekil 6. 2. Ayrık Dalgacık Dönüşümü ayrışım ağacı

Günümüzde, ADD telekomünikasyon, radar hedef tanıma, doku tipi imgelerin sınıflandırılması v.b. birçok bilim alanında kullanılmaktadır [79], [80]. ADD, değişik bir pencereleme tekniğine sahiptir. Bu pencereleme tekniğinde, işaret ya da imgeyi daha iyi analiz edebilmek için yüksek frekanslı kısımlarda daha geniş, düşük frekanslı kısımlarda ise daha dar bir pencereleme boyutu kullanılmaktadır. Bundan dolayı da ADD tarafından kullanılan bu pencereleme tekniği, frekans büyüklüğüne göre uyarlamalı pencereleme tekniği adını almaktadır. Bu durum, işaret ya da imgenin sahip olduğu bütün frekans uzayında optimum bir zaman-frekans çözünürlüğüne yol açmaktadır [79].

Literatürde en çok kullanılan ADD işaretin veya imgenin ölçeklenebilir bir zaman frekans analizini sağlar ve geleneksel işaret ve imge işleme teknikleri tarafından görülmeyen detayları ortaya çıkarır. ADD zaman-ölçek yöntemine dayalı olduğu için, odağa tam olarak ayarlanarak işaretin veya imgenin farklı kısımlarını gözetleyebilen bir matematik mikroskobu görevi görür

[20]. Şekil 6.3. de en yaygın olarak kullanılan ADD filtre tiplerinin bir kısmı verilmiştir. ADD analiz yöntemlerinin geleneksel zaman-frekans yöntemlerine göre üstünlükleri aşağıdaki gibi verilebilir:

- ✓ Eğer analizde spektrumdaki birkaç frekans bandı kullanılacaksa, tüm spektrumu hesaplamaya gerek yoktur.
- ✓ Spektrumun düşük frekans kısımlarında ADD oldukça hızlıdır.
- ✓ Frekans spektrumundaki farklı bölgeler için daha kolay farklı frekans çözünürlükleri seçilebilir.



Şekil 6. 3. Literatürde en çok kullanılan ADD filtre örnekleri.

İmge işlemede ADD yöntemi kullanılması sonucu imge 1. seviyede ayrışım sonucu elde edilen Dikey-Dikey (D-D1) (Yaklaşık), Dikey-Yatay (D-Y1), Yatay-Dikey (Y-D1), Yatay-Yatay (Y-Y1) (Köşegen) olmak üzere 4 alt imge Şekil 6.3 (a)'da verilmiştir. Daha sonra 1. seviyede elde edilen Dikey-Dikey (D-D1) alt imgesine 2. seviye ADD uygulanarak elde edilen sırasıyla Dikey-Dikey (D-D2) (Yaklaşık), Dikey-Yatay (D-Y2), Yatay-Dikey (Y-D2), Yatay-Yatay (Y-Y2) (Köşegen) alt imgeler Şekil 6.3 (b)'de verilmiştir.

1. Seviyede Ayrışım

D - D1	Y - D1
D - Y1	Y - Y1

(a)

2. Seviyede Ayrışım

D-D2	Y-D2	Y-D1
D-Y2	Y-Y2	
D-Y1		Y-Y1

(b)


Şekil 6. 4. İmge için ADD ayrışımı (a) 1. seviye (b) 2. seviye

ADD ayrışımı, Denklem (6.7)'de tanımı verilen Sürekli Dalgacık Dönüşümünde (SDD) ölçeklemenin ayrık zamanda ikinin kuvveti olarak alınması şeklinde yorumlanabilir. ADD yöntemi özellikle imge veya işaret içerisindeki süreksizlikleri belirlemede oldukça etkilidir.

$$ADD(t, z) = \int f(x) \psi_{t,z}^*(x) dx \quad (6.7)$$

Burada sırasıyla t ve z , öteleme ve genişletme katsayılarıdır. Ayrıca $\psi_{t,z}^*(x)$ ifadesi, $\psi(x)$ ana dalgacıktan öteleme ve genişletme faktörleri kullanılarak elde edilmiş yeni dalgacığın karmaşık eşleniğidir [82]:

$$\psi(t, z) = \frac{1}{\sqrt{|t|}} \psi\left(\frac{x-t}{z}\right) \quad (6.8)$$



Şekil 6. 5. İki boyutlu dalgacık dönüşümü

6.3.3. Ayırık Dalgacık Dönüşüm Ağacından Entropi Hesaplanması

Entropi kavramı, işaret ve imge işlemede ve özellikle haberleşme sahasında ilk olarak Shannon tarafından kullanılmıştır [78]. Entropi tabanlı özellikler verilen bir işaret ya da imge gösteriminin özellikleri ile ilgili bilgileri tanımlar. Entropi kavramı, bir sistemin düzenliliğini ölçütüdür. Özellikle, bu amaç için termodinamik fiziğinde yaygın olarak kullanılmaktadır. Günümüzde entropi kavramı, işaret ya da imge işleme yöntemlerinde herhangi bir işaretin ya da imgenin düzensizlik derecesini ölçmek için ideal bir araç olarak kullanılmaktadır [84]. Buna ilaveten, entropi kavramı bir ortamdaki bilginin ortalama miktarını ölçmek amacı ile de kullanılmaktadır [85].

Son yıllarda entropi yöntemi, işaret ve imge işleme alanlarında da yaygın olarak kullanılan bir kavram haline gelmiştir. Bu alanlardan bazıları, JPEG görüntü kodlamada oluşabilecek gürültüyü tespit etmek [86], biyomedikal NMR işaretlerinin dalgacık dönüşüm uzayından istatistiksel bilgileri elde ederek işaretin gürültüsüz şeklini kestirmek [87], entegre devre teknolojisinde karbon üzerindeki elektron enerji kaybını bulmak [88], EEG işaretlerinin


spektral entropilerini kullanarak anestezi derinliği tahmin etmek [89] ve MEG biyomedikal görüntülerin yeniden yapılandırılmasında norm entropi metodu kullanarak yüksek kalitede MEG imgeleri elde etmek [90] şeklinde sıralanabilir.

Sayısal işaret veya imge işlemede yaygın olarak kullanılan entropi hesaplama türleri : Shannon, Norm, Eşik (Threshold), Logaritmik Enerji ve Sure yöntemleridir [91]. Bunun dışında diğer entropi hesaplama teknikleri de bulunmaktadır. Bunlar hakkında ayrıntılı bilgi [92] da bulunabilir. Aşağıdaki entropi yöntemlerinde, s işareti ya da imgeyi ve s_i de işaretin ya da imgenin i . katsayısını göstermektedir. Sayısal işaret ya da imge işleme alanında yaygın kullanılan bu entropi türleri ve bu entropi türlerine ait denklemler aşağıda Tablo 6.1. de verilmiştir.

Tablo 6. 1.Sayısal işaret ya da imge işleme alanında yaygın kullanılan entropi türleri ve bu entropi türlerine ait denklemler

Entropi Türü	Entropiye Ait Denklem
1. Shannon Entropisi	$E(s) = -\sum_i s_i^2 \cdot \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
2. Norm Entropisi	$E(s) = \sum_i s_i ^p$ ve $1 \leq p < 2$ arasında bir değer alır.
3. Logaritmik Enerji Entropisi	$E(s) = \sum_i \log_2(s_i^2)$ ve $\log(0) = 0$ kabul edilerek
4. Eşik Entropisi	$E(s) = \sum_i E(s_i)$ ε pozitif bir eşik değeri olup $ s_i > \varepsilon \Rightarrow E(s_i) = 1$ ve $ s_i \leq \varepsilon \Rightarrow E(s_i) = 0$
5. Sure Entropisi	$ s_i \leq \varepsilon \Rightarrow E(s) = \sum_i \min(s_i^2, \varepsilon^2)$ burada ε pozitif bir eşik değeri olup $1 \leq \varepsilon < 8$ arasında bir değer alır.

Bu tez çalışmasında mikroskobik sayısal idrar tortusu imgelerinden özellik çıkarımı için geliştirilen ayrık dalgacık dönüşüm entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı aşağıda Şekil 6.6’da verilmiştir.



Şekil 6. 6. Mikroskobik sayısal idrar tortusu imgelerinden özellik çıkarımı için geliştirilen ayrık dalgacık dönüşüm entropilerine dayalı özellik çıkarım tekniğinin blok diyagramı

7. MİKROSKOBİK İDRAR TORTUSU İMGELERİNDE YER ALAN HÜCRELERİN SINIFLANDIRILMALARI İÇİN KULLANILAN YÖNTEMLER

Tezin bu bölümünde, kaynaklar [20], [93], [94] da kullanılmış olan YSA sınıflandırıcısı, UATBÇS ve DVM sınıflandırıcısı bu tez çalışmasında kullanılmıştır. Bu modellerde, örüntü tanımada kilit rolü oynayan özellik çıkarımı, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir. Bu adaptif yapı, entropi hesaplama tekniğinin parametrelerine müdahale edilerek sağlanmıştır.

7.1. Yapay Sinir Ağı Sınıflandırıcıları

Yapay sinir ağı(YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır [95]. Ağdaki paralel yapılar, bilgisayarları geleneksel yöntemlerden çok daha farklı kullanarak özellikle seri bilgisayarlarda bilinen yöntemlerle yapılması mümkün olmayan ses ve örüntü tanıma gibi işlevleri rahatlıkla yapmaları, YSA'yı üstün kılmıştır [96-98].

Bir başka deyişle YSA, biyolojik sinir ağlarını taklit eden bilgi işleme yöntemleridir. Bu ağlar birbirine paralel olarak bağlanmış işlem elemanlarının (yapay sinir ağı hücresi, nöron, ünite, birim, düğüm) hiyerarşik bir organizasyonundan oluşmaktadır. Bir sinir ağının en temel bileşeninin beyin yapısından esinlenerek geliştirilmesine karşın, bazı özellikleri insan beyninin fonksiyonlarından farklılık göstermektedir. YSA, her ne kadar temel yapı itibarıyla bir kısım özellikleri insan beyninin fiziki özelliklerinden esinlenerek ortaya atılmış ise de, bazı özelliklerinin ise beyinde biyolojik karşılığı yoktur [20], [96], [99].


İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanmasına rağmen insan beyninin ne olduğu ve nasıl çalıştığı henüz tam olarak keşfedilmiş sayılmaz. Bugün, tüm dünyada sinir ağları ile ilgili birçok araştırma yapılmaktadır. YSA'yı eğitmek uzun süreler aldığından başlıca araştırmalar bu konuya odaklanmıştır. Burada amaç yeni ve daha verimli öğrenme algoritmaları, zamana bağlı olarak değişen modellere karşılık verilen ağlar şeklinde özetlenebilir. Biyolojik beyin, tecrübe ile öğrenme ve bilgiyi kendi kendine yorumlama, hatta

eksik bilgilerden sonuçlar çıkartma kabiliyetine sahiptir. Bu, daha çok biyolojik sistemlerin, hücreler üzerinde dağıtılmış bilgiyi paralel olarak işleme özelliklerinden kaynaklanır. Günümüz teknolojisinde hafıza işlemleri, karmaşık matematiksel hesaplamalar eldeki mevcut bilgisayarlarla hızlı ve doğru yapmak mümkün olsa da, aynı bilgisayarlarla beynin birçok basit fonksiyonunu (görmek, duymak koklamak, ...vs.) yerine getirmek tamamen mümkün olmamakta veya oldukça zor olmaktadır. YSA, bu özellikleri bünyesinde toplayacak şekilde geliştirilmektedir [95].

7.1.1. Biyolojik Sinir Ağların Yapısı

YSA'nın daha iyi anlaşılması için örnek teşkil eden doğal sinir ağı olan biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekmektedir. Biyolojik sinir ağının en temel elemanı olan sinir hücresi, sinir sistemi içerisindeki fonksiyon ve görevlerine göre değişik şekil ve büyüklükte olabilir.

Sinir hücreleri çok kutuplu, iki kutuplu, tek kutuplu, anaksonik olarak adlandırılır. Tüm doğal sinirlerin 4 temel bileşeni vardır. Bunlar, dendritler, soma, akson ve synaps'tır. Nöronun bir ucunda "dendrit" adı verilen ve hücreye diğer hücrelerden veya dışarıdan gelen bilgileri toplayan bağlantı elemanı, diğer ucunda ise tek bir life benzer "akson" adı verilen ve hücreden diğer hücrelere ve dış dünyaya bilgi taşıyan bağlantı elemanı vardır. Akson diğer hücrelerle birleşme esnasında dağınık dallara ayrılmaktadır. Bu iki uçtaki bağlantı noktalarının, elektrofizyolojik olarak hücrelerdeki bilgileri işlemede önemli yeri vardır. Hücrelerin birbiri ile elektrik işaretleri vasıtasıyla irtibat kurduğu belirlenmiştir. İşaretler, bir hücrenin aksonundan, diğerinin dendritine gönderilir. Bir akson birden fazla dendrit ile bağlantı kurabilir. Bu bağlantıların yapıldığı yere "synaps" denir. Temel olarak biyolojik sinir diğer kaynaklardan girişleri alır, soma girişleri genelde doğrusal olmayan bir şekilde işler. Akson işlenmiş girişleri çıkışa aktarır. Sinaps diğer sinirlere çıkışı gönderir.




Şekil 7. 1. Biyolojik bir beyin sinir hücresi

Hücreler, elektrik işaretini hücre duvarlarındaki voltajı değiştirerek üretirler. Bu ise, hücrenin içinde ve dışında dağılmış iyonlar vasıtası ile olur. Hareket potansiyeli akson ucundaki sinapsa ulaştınca, elektriksel uyarıdan kimyasal uyarıya dönüşerek, synaps aralığından postsinaptik sinire geçer. Postsinaptik sinirin zarında kimyasal uyarı elektriksel uyarıya dönüştürülür. Bir hücre, diğer hücreye elektrik enerjisini bu kimyasal iyonlar vasıtasıyla transfer eder [95]. Bir hücrenin etkinliği, hücreye gelen synaps sayısı, synapslardaki iyonların konsantrasyonu ve synapsın sahip olduğu güç olmak üzere üç faktöre bağlıdır. Bir hücre sahip olduğu dürtü miktarınca diğer hücreleri etkiler. Bazı hücreler diğerlerinin dürtülerini pozitif yönde, bazı hücreler de negatif yönde etkiler. İnsan sinir ağı sistemi, bu şekilde çalışan milyonlarca hücrenin bir araya gelmesinden oluşur [20], [85].

7.1.2. Bir Yapay Sinir Ağlarının Ana Öğeleri

YSA, birbirine bağlı çok sayıda işlem elemanlarından oluşmuştur. YSA'daki işlem elemanları(düğüm) basit sinirler olarak adlandırılır. Bir YSA, birbirleriyle bağlantılı, çok sayıda düğümlerden oluşmaktadır. YSA'da işlem elemanı Şekil 7.2. de görüldüğü gibi beş parçadan oluşmaktadır. Bunlar; girişler, ağırlıklar, toplama işlevi, etkinlik işlevi ve çıkışıdır [95].



Şekil 7. 2. Yapay sinir (düğüm) modeli

Şekil 7.2.'de verilen olan bir YSA hücresinin matematiksel ifadesi şu şekildedir;

$$Net = \sum_{i=1}^4 w_i \cdot x_i = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3 + w_4 \cdot x_4$$


$$\checkmark = F(Net) \quad (7.1)$$

YSA Şekil 7.2.'de gösterilen yapıdan türetilmiştir. Biyolojik sinir hücresi gibi, işlem elemanına birden fazla giriş gelmekte ve sadece bir çıkış gitmektedir. Girişler($x_1, x_2, \dots, x_n$) çevreden aldığı bilgiyi sinire getirir. Girişler, kendilerinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir. Bazı durumlarda bir işlem elemanı kendisine de bilgi geri gönderebilir (geri besleme). Bir sinir genellikle geliş güzel bir çok girdileri alır. Bu girdiler elemanlar arasında bulunan bağlantı hatları üzerinde depolanır.

Ağırlıklar ($w_1, w_2, \dots, w_i$), YSA tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bağlantı bir ağırlığı sahiptir. Bu ağırlık bir işlem elemanının diğeri üzerindeki etkisini gösterir. Ağırlığın büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir. Ağırlığın sıfır olması hiç bir etkinin olmaması, negatif olması ise etkinin ters yönde olması demektir. Bu ağırlıklar sabit olabildikleri gibi değişken de olabilirler.

Toplama işlevi(T), bir işlem elemanına gelen net girişi hesaplayan bir fonksiyondur. Net giriş genellikle gelen bilgilerin ilgili bağlantıların ağırlıkları ile çarpılıp toplanması ile belirlenir. Bazı durumlarda toplama işlevi bu kadar basit bir işlem yerine, en az(min), en çok(max), çoğunluk veya birkaç normalleştirme algoritması gibi çok daha karmaşık olabilir.

Etkinlik işlevi(F) de, toplama işlevi tarafından belirlenen net girişi alarak, işlem elemanının çıkışını belirleyen fonksiyondur. Bir etkinlik işlevinin kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermektir. Genellikle türevi alınabilen bir fonksiyon olması tercih edilir. Şekil 7.3. de en çok kullanılan dört tane etkinlik işlevi verilmiştir. Bunlar, lineer, rampa, basamak ve sigmoid fonksiyonudur.



Şekil 7.3. Yapay sinir ağları için kullanılan etkinlik işlevleri

Çıkış(Ç), etkinlik işlevi sonucunun dış dünyaya veya diğer sinirlere gönderildiği yerdir. Her bir düğümde bir çıkış işaretine izin verilir. İşlem elemanları ağın topolojik yapısına bağlı olarak tamamen birbirinden bağımsız ve paralel olarak çalışabilirler.

Genel olarak YSA, sinir ağının dış dünya ile bağlantısını kuran giriş katmanı, gelen bilgileri işleme kabiliyetine sahip ara katmanlar ve sinir ağının kararlarını dış dünyaya aktaran bir çıkış katmanı olmak üzere 3 katmandan oluşur.

7.1.3. Yapay Sinir Ağlarında Öğrenme ve Öğrenme Algoritmaları

Daha önce belirtildiği gibi YSA düğüm veya sinir olarak adlandırılan çok sayıda işlem elemanının bir araya gelmesinden oluşur. Bilgi, işlem elemanları arasındaki bağlantı hatları üzerinde saklanır ve ağırlıklar vasıtası ile gösterilir. Ağ, olaylar hakkında giriş ve çıkışlar arasındaki ilişkiyi, elde bulunan mevcut örneklerden genellemeler yaparak öğrenir ve bu

genelleme ile yeni oluşan ve ortaya çıkan daha önce hiç görülmemiş olaylar hakkında karar verir.

Sinir ağlarında istenen sonucun elde edilmesi için ağın uyarlanabilir olması gerekir. Bunu sağlamak için uygun değerli ağırlıklar ve doğru bağlantılar seçilmelidir. Ağ bu şartları karşılayabilmek için sistemin davranışlarını öğrenmeli ya da kendi kendini örgütlemelidir. Öğrenme kalıcı yenilemeler için gözlemlenebilir veya eğitim faaliyetlerinden çıkan sonuçlar olarak tanımlanabilir.

Öğrenme işlemini gerçekleştirebilmesi için YSA'nın sahip olduğu bütün ağırlıkların, ilgili problemde öğrenilmesi istenen özellikleri genelleştirecek şekilde doğru değerlere sahip olması gerekir. Bu doğruluk ne kadar artarsa ağın sınıflandırma kabiliyeti dolayısı ile öğrenme işlemi o kadar iyi olur. Öğrenme, giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir. Genellikle bağlantılara başlangıç değerleri olarak rastgele ağırlıklar atanır. Bu ağırlıklar eldeki örnekler incelendikçe bir kurala göre değiştirilerek doğru ağırlık değerleri bulunmaya çalışılır. Ağların eğitimi için kullanılan öğrenme kuralları genellikle danışmanlı öğrenme, danışmansız öğrenme ve pekiştirerek öğrenme olarak üç başlık altında toplanabilir [85], [95], [96], [100].

- **Danışmanlı Öğrenme:** YSA'da gerçek çıkış istenen çıkışla kıyaslanır. Danışmanlı öğrenmede, dışarıdan bir eğiticinin sinir ağına müdahalesi söz konusudur. Eğitim işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitim kümesi olarak tanımlanır. YSA giriş / çıkış ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil etmektedir. Girilen değerle istenilen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenilen değerın altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır.
- **Danışmansız Öğrenme:** Bu yöntemde sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Ağ, kendine gösterilen örnekleri alır ve belli bir kritere göre sınıflandırır. Ağ, kendi öğrenme kriterlerini kendisi oluşturur ve rastgele ağırlıklarla çalışmaya başlar. Herhangi bir giriş uygulandığında, giriş vektörüne Öklid uzaklığı en az olan sinir seçilir ve bu sinire gelen bağlantı giriş ağırlıkları giriş vektörüne yaklaşacak şekilde yenilenir.

- **Pekiştirerek Öğrenme:** Bu yöntemin diğer yöntemden farkı, eğiticinin ağın üretmesi gereken sonuç yerine, onun ürettiği sonucun sadece doğru veya yanlış olduğunu söylemesidir. Bu yöntem, ilgili örnek için beklenen çıkışın oluşturulamadığı durumlarda çok faydalıdır.

YSA; sinirler, bağlantılar ve aktarım işlevlerine bağlı olduğu için, farklı mimariler, yapılar ya da sinir ağları arasında bir benzerlik bulunmaktadır. Çeşitliliğin çoğunluğu farklı öğrenme kurallarından ve bu kuralların bir ağı yapısını nasıl değiştirdiğinden kaynaklanmaktadır.

7.2. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcıları

UATBÇS, yapı olarak YSA ve bulanık mantık sistemlerini içermektedir. UATBÇS, bulanık çıkarım sistemindeki giriş çıkış bilgi çiftlerinden ve eğer-ise kurallarından oluşmaktadır. Sistem eğitiminde ise YSA öğrenme algoritmalarından oluşmaktadır. UATBÇS ismi, Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sisteminin baş harflerinden oluşmuştur. Bazı kaynaklarda UATBÇS, TSK bulanık kuralları ile sinirsel bulanık denetleyici olarak geçmektedir. TSK ise Sugeno bulanık modeli anlamında, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak kullanılmaktadır. Bir başka deyişle karma sinir ağları olarak da anılmaktadır [95].

UATBÇS sınıflandırıcıların bazı üstün özellikleri aşağıdaki gibi tanımlanabilir:

1. Öğrenme yeteneği,
2. Paralel işlem,
3. Yapılandırılmış bilgi temsili,
4. Diğer sınıflandırma ve tasarım yöntemleriyle daha iyi bütünleşme.


UATBÇS'nin yapısındaki bulanık çıkarım sisteminin mimarisinin kolaylıkla anlatılabilmesi için x ve y olmak üzere iki girişi ve f gibi bir çıkışı olduğu kabul edilirse, birinci derece Sugeno bulanık modeli için iki bulanık “EĞER-OHALDE” kuralı (7.2)'deki gibi olur.

Kural1:EĞER $x=A_1$ ve $y=B_1$ ise O HALDE $f_1 = p_1x+q_1y+r_1$

Kural2:EĞER $x=A_2$ ve $y=B_2$ ise O HALDE $f_2 = p_2x+q_2y+r_2$ (7.2)

7.2.1. UATBÇS Mimarisi

Sinirsel bulanık sistemler, YSA'nın paralel hesaplayabilme ve öğrenme kabiliyeti ile bulanık mantığın uzman bilgisini kullanarak sonuçlar çıkarabilme özelliklerinin birleşiminden oluşur. UATBÇS mimarisi içerisindeki, her katmana ait düğüm işlevleri ve dolayısıyla katmanların işlevleri sırasıyla Şekil 7.4'de iki girişli ve tek çıkışlı beş katmandan oluşan bir UATBÇS sınıflandırıcısı verilmiştir.



Şekil 7. 4. 2 girişli 9 kurallı Sugeno tip bir UATBÇS mimarisi

Bu UATBÇS yapısı aşağıda da görüldüğü gibi 5 katmandan oluşmaktadır. Burada x ve y giriş, z ise çıkış olarak alınırsa temel kural yapısı şu şekilde yazılabilir:

$$\text{Eğer } x \text{ } A_1 \text{ ve } y \text{ } B_1 \text{ ise } f_1 = p_1x + q_1y + r_1 \quad (7.3)$$

Burada p, q ve r lineer çıkış parametreleridir. Bu yapı, 5 katman ve 9 adet eğer-ise kuralı kullanılarak oluşturulmuştur:

1.Katman: Bu katmanda her bir düğüm A_i ve B_i gibi bir bulanık kümeyi ifade eder. Bu katmandaki düğümlerin çıkış giriş örneklerine ve kullanılan üyelik işlevine bağlı olan üyelik dereceleridir. Hücre sayısı, iki giriş ve bu iki girişin her birine üç üyelik fonksiyonu tanımlandığına göre altı adettir ($i=6$ 'dır). Buna göre,

$$O_{1,i} = \mu_{A_i}(x), \quad i=1,2,3 \text{ için}$$

$$O_{1,i} = \mu_{B_{i-3}}(y), \quad i=4,5,6 \text{ için} \quad (7.4)$$

Bu katmanın çıkışı kuralların varsayım (eğer) kısımlarının üyelik fonksiyonlarına olan üyelik dereceleridir. Kullanılan üyelik fonksiyonu Denklem 7.5'de verilmiştir.

$$\mu_{A_i}(x), \mu_{B_{i-3}}(y) = \exp(-(x_i - c_i)/(a_i))^2 \quad (7.5)$$

2. Katman: Her bir düğümün çıkışı bir kuralın ateşleme seviyesini temsil eder. Burada kuralların kesinlik dereceleri cebirsel çarpım kullanılarak bulunur. Genelleştirilmiş bulanık VE'yi (AND) yerine getiren t-norm operatörlerden herhangi biri, bu katmandaki düğümler için düğüm işlevi olarak kullanılabilir (Denklem 7.6).

$$O_{2,i} = w_i = \mu_{A_i}(x) * \mu_{B_i}(y), \quad i=1,2,3,\dots,9 \quad (7.6)$$

3. Katman: Bu katmanda kuralların normalizasyon işlemi yapılmaktadır. Denklem 7.7'de görüldüğü gibi, i. düğüm için i. kuralın ateşleme seviyesinin, bütün kuralların ateşleme seviyelerinin toplamına eşittir.

$$O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + \dots + w_9), \quad i=1,2,3,\dots,9 \quad (7.7)$$

4. *Katman*: Bu katmandaki her i düğümü, düğüm işlevi ile uyarlamalı bir düğümdür. Her i düğümü sonuç ağırlık değerini hesaplar. Normalize edilmiş her bir kural kendine ait çıkış fonksiyonu ile çarpılır (Denklem 7.8).

$$O_{4,i} = \bar{w}_i * f_i = w_i * (p_i x + q_i y + r_i) \quad (7.8)$$

Burada $\bar{w}_i$, 3.katmanın çıkışı ve $\{p_i, q_i, r_i\}$ ayar edilebilmesi için gerekli olan, ayar değişken kümesidir.

5. *Katman*: Bu katmanda sadece bir düğüm vardır. 4. Katman çıkışlarının toplanarak UATBÇS çıkışının sayısal değerinin bulunduğu kısımdır. Ağın gerçek çıkışı Denklem(7.9)'da verilmiştir.

$$O_{5,i} = \text{toplam çıkış} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7.9)$$

7.2.2. UATBÇS İçin Geri Yayılımlı Öğrenme Algoritması

Jang (1993) bir UATBÇS sistemi için geriye yayılımlı öğrenme algoritması geliştirmiştir. Geri yayılımlı öğrenme algoritmasında ağın çıkışından elde edilen hata değeri giriş katmanına kadar geriye doğru yansıtılarak gerekli ağırlık değişkenlerinin ayarlanması gerçekleştirilir. Amaç E hata ölçütünü öğrenme işlemi sonunda bütün giriş örnekleri için sıfıra götürmektir. Ağın çıkışında hata, istenen değer d ile gerçek çıkış f arasındaki farktır ve Denklem (7.10)'daki gibi ifade edilir,

$$e = d - f \quad (7.10)$$

Ağ parametrelerinin optimizasyonu için geri yayılımlı öğrenme algoritması eğim düşüm (gradient descent) ve en küçük kareler (least square) yöntemi uygulanarak hata ölçütü E

aşağıda verildiği gibi hesaplanır. Hata ölçütü kullanılarak hata geriye doğru katman katman yansıtılır.

$$E = \frac{1}{2} e^2 \quad (7.11)$$

7.3. Çoklu Destek Vektör Makineleri Sınıflandırıcısı

DVM, ilk defa Vapnik tarafından geliştirilmiştir [101]. DVM, istatistiksel öğrenme teorisine dayanmaktadır. DVM'nin uygulama alanları günümüzde çeşitlilik kazanmakla birlikte ilk olarak optik karakter tanıma alanına uygulanmış, uzaktan algılama, bilgisayar görmesi, örüntü tanıma gibi birçok veri madenciliği alanında kullanılmıştır.

DVM, sınıflandırmada ve örüntü tanımada yaygın şekilde kullanılır. Klasik sınıflandırma yöntemlerini yetersiz kaldığı yerlerde kullanılır. Eğer veri setindeki değişkenler arasında herhangi bir örüntü yoksa DVM'ye başvurulur. Sınıflama regresyon ve aykırı değer belirlemek için kullanılabilecek eğitici bir sınıflandırma metodudur. Eğitim verisi üzerinde öğrenme yaparak yeni veri üzerinde doğru tahmin yapmayı hedeflemektedir.

Eğitim setlerinde girdi ve çıktılar eşlenerek işlem yapılır. Eşler aracılığıyla test setinde ve yeni veri setinde girdi değişkenini sınıflayacak karar fonksiyonları elde edilir. Girdi verilerini lineer ve nonlineer olarak ayırma yeteneğine sahiptir. DVM sınıflandırıcısının giriş uzayı, özellik uzayı olarak adlandırılan bir yüksek boyutlu iç çarpım uzayına dönüştürülür. Bu özellik uzayı, DVM'nin genelleme kabiliyetini arttırmak için en uygun ayırım düzlemlerini belirler. Bu uygun ayırım düzlemlerini bulmada çeşitli optimizasyon ve istatistiksel öğrenme tekniklerinden yararlanılmaktadır [72].


Yüksek doğruluk, karmaşık karar sınıflarını modelleyebilme, çok sayıda bağımsız değişkenle çalışabilme, hem doğrusal ayrılan hem de doğrusal olarak ayrılamayan verilere uygulanabilme, diğer sınıflandırma metotlarına göre ezber sorunun daha az olması DVM'nin avantajlarıdır. Buna karşılık Bulanık mantık gibi olasılıksal tahminler üretememe, kernel fonksiyonları için Mercer koşulu zorunluluğu DVM'nin dezavantajlarıdır.

7.3.1. Doğrusal Ayrılabilen Veriler İçin Destek Vektör Makineleri

İstatistiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayanmaktadır. Aynı zamanda nonparametrik sınıflandırıcılardır. Dağılım hakkında herhangi bir ön bilgi ve varsayımına sahip değildir.

DVM ile sınıflandırmada genellikle $\{-1,+1\}$ şeklinde sınıf etiketleri ile gösterilen iki sınıfa ait örneklerin, eğitim verisi ile elde edilen bir karar fonksiyonu yardımıyla birbirinden ayrılması amaçlanır. Söz konusu karar fonksiyonu kullanılarak eğitim verisini en uygun şekilde ayırabilecek hiper-düzlem bulunur.

Şekil 7.5(a)'da gösterildiği üzere iki sınıflı verileri birbirinden ayırabilen birçok hiper-düzlem çizilebilir. Ancak DVM'nin amacı kendisine en yakın noktalar arasındaki uzaklığı maksimuma çıkaran hiper-düzlemi bulabilmektir. Şekil 7.5(b)'de görüldüğü üzere sınırı maksimuma çıkararak en uygun ayrımı yapan hiper-düzleme optimum hiper-düzlem ve sınır genişliğini sınırlandıran noktalar ise destek vektörleri olarak adlandırılır.



Şekil 7. 5. (a) İki sınıflı bir problem için hiper –düzlemler, (b) Optimum hiper-düzlem ve destek vektörleri


Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM'nin eğitimi için k sayıda örnekten oluşan eğitim verisine $\{x_i, y_i\}$ $i=1,2,3,\dots,k$ olduğu kabul edilirse, optimum hiperdüzleme ait eşitsizlikler aşağıdaki gibi olmaktadır.

$$wx_i + b \geq 1 \text{ her } y=1$$

$$wx_i + b \leq -1 \text{ her } y=-1$$

(7.12)

Yukarıdaki denklemde y -1 ile 1 olarak etiketlenmektedir. W ağırlık vektörünü, b ise eğilim değerini göstermektedir. Optimum hiper düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak iki hiper düzlemin belirlenmesi gerekmektedir. Bu hiper düzlemleri oluşturan noktalar destek vektörleri olarak adlandırılır ve bu düzlemler $w \cdot x_i + b = \pm 1$ şeklinde ifade edilir.



Şekil 7. 6. Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi

Optimum hiper-düzlemin sınırlarının maksimuma çıkarılması için $\|w\|$ ifadesinin minimum hale getirilmesi gerekmektedir. Bu duruma en uygun hiper-düzlemin belirlenmesi için aşağıdaki sınırlı optimizasyon probleminin çözülmesi gerekmektedir.

$$\min \left[\frac{1}{2} \|w\|^2 \right]$$

Buna bağlı sınırlamalar ise;

$$y_i(w \cdot x_i + b) - 1 \geq 0 \text{ ve } y_i \in \{1, -1\}$$

(7.13)

Şeklinde ifade edilir. Bu optimizasyon problemi Lagrange denklemleri kullanılarak çözülebilir. Bu işlem sonrasında

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^k \alpha_i$$

(7.14)

Eşitliği elde edilmektedir. Sonuçta, doğrusal olarak ayrılabilen iki sınıflı bir problem için karar fonksiyonu aşağıdaki gibi yazılabilir.

$$f(x) = \text{sign} \left(\sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b \right) \quad (7.15)$$

7.3.2. Doğrusal Ayrılmayan Veriler İçin Destek Vektör Makineleri


Görüntülerin sınıflandırılmasında olduğu gibi birçok problemde verilerin doğrusal olarak ayrılması Şekil 7.7.(a)'dan da görüldüğü gibi mümkün değildir. Bu durumda eğitim verilerinin bir kısmının optimum hiper-düzlemin diğer tarafında kalmasından kaynaklanan problem Şekil 7.7.(b)'deki gibi pozitif bir yapay değişkenin (ξ_i) tanımlanması ile çözülür. Sınırın maksimum hale getirilmesi ve yanlış sınıflandırma hatalarının minimum hale getirilmesi arasındaki denge pozitif değerler alan ve C ile gösterilen bir düzenleme parametresi $0 < C < \infty$ tanımlanmasıyla kontrol edilebilir. Düzenleme parametresi ve yapay değişken kullanılarak doğrusal olarak ayıramayan veriler için optimizasyon problemi:

$$\min \left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \delta_i \right] \quad (7.16)$$

Buna bağlı sınırlamalar ise


$$\begin{aligned} y_i(w \cdot \varphi(x_i) + b) - 1 &\geq 1 - \xi_i \\ \xi_i &\geq 0 \quad \text{ve} \quad i = 1, \dots, N \end{aligned} \quad (7.17)$$

Şeklinde ifade edilir.



Şekil 7. 7.(a) Doğrusal olarak ayrılamayan veri seti, (b) Doğrusal olarak ayrılamayan veri setleri için hiper-düzlemin belirlenmesi.

Bahsedilen optimizasyon probleminin çözümü için Şekil 7.7’de görüleceği üzere girdi uzayında doğrusal olarak ayrılamayan veri, özellik uzayı olarak tanımlanan yüksek boyutlu bir uzayda görüntülenir. Böylece verilerin doğrusal olarak ayrımı yapılabilmekte ve sınıflar arasındaki hiper-düzlem belirlenebilmektedir.



Şekil 7. 8. Kernel fonksiyonu ile bir verinin daha yüksek bir boyuta dönüştürülmesi

DVM matematiksel olarak $K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ şeklinde ifade edilen bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrımına imkan sağlamaktadır. Sonuç olarak, kernel fonksiyonu kullanarak doğrusal olarak ayrılamayan iki sınıflı bir problemin çözümü ile ilgili karar kuralı aşağıdaki şekilde yazılabilir (Osuna vd., 1997):

$$f(x) = \text{sign} \left(\sum_i \alpha_i y_i \phi(x) \cdot \phi(x_i) + b \right) \quad (7.18)$$

DVM ile gerçekleştirilecek bir sınıflandırma işlemi için kullanılacak kernel fonksiyonu ve bu fonksiyona ait optimum parametrelerin belirlenmesi esastır. Literatürde kernel fonksiyonu olarak en sık kullanılan polinom, radyal tabanlı fonksiyon, Pearson VII (PUK) fonksiyonu ve normalleştirilmiş polinom kernelleri Tablo 7.1’de formülleri ve parametreleriyle birlikte sunulmuştur. Tablodan görüleceği üzere her kernel fonksiyonu için bazı parametrelerin kullanıcı tarafından belirlenmesi gerekir. PUK kerneli için belirlenmesi gereken parametre sayısı iki iken, diğer fonksiyonlar için sınıflandırmaya esas olacak model oluşumunda bir parametrenin belirlenmesini gerektirmektedir.

Kernel fonksiyonları karşılaştırıldığında polinom ve radyal tabanlı kernellerin daha sade ve anlaşılabilir olduğu ifade edilebilir. Matematiksel olarak basit görünse de, polinomun derecesindeki artış algoritmanın karmaşık bir hal almasına neden olmaktadır. Bu da hem işlem süresini önemli ölçüde artırmakta hem de bir noktadan sonra sınıflandırma doğruluğunu düşürmektedir. Buna karşın radyal tabanlı fonksiyonun kernel boyutu (γ) olarak ifade edilen parametresindeki değişimlerin sınıflandırma performansına etkisinin daha az olduğu görülmüştür [Hsu vd., 2010]. Normalleştirilmiş polinom fonksiyonu ise veri setinin normalleştirilmesi yerine polinom kernele ait matematiksel ifadenin normalleştirilmesi amacıyla önerilmiştir [Arnulf vd. (2001)]. Normalleştirilmiş polinom kernelinin polinom kernelinin genelleştirilmiş bir hali olduğu söylenebilir. Diğer taraftan, PUK kerneli Pearson genişliği olarak bilinen (σ , ω) iki parametresi ile diğer kernel fonksiyonlarına göre daha karmaşık bir matematiksel yapıya sahiptir. Bu iki parametre sınıflandırma doğruluğuna etki etmekte ve hangi parametre çiftinin en iyi sonuç vereceği önceden bilinmemektedir. Bu nedenle PUK kernelinin kullanımında en uygun parametre çiftinin belirlenmesi önemli bir aşamadır.

Tablo 7. 1. Destek Vektör Makinelerinde kullanılan temel kernel fonksiyonları ve parametreleri

Kernel Fonksiyonu	Matematiksel İfadesi	Parametre
Polinom Kerneli	$K(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi (d)
Normalleştirilmiş Polinom Kerneli	$K(x, y) = \frac{((x \cdot y) + 1)^d}{\sqrt{((x \cdot x) + 1)^d ((y \cdot y) + 1)^d}}$	Polinom derecesi (d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	Kernel boyutu (γ)
Pearson VII (PUK) Kerneli	$\frac{1}{1 + \left(\frac{2 \cdot \sqrt{\ x - y\ ^2} \sqrt{2^{(1/\omega)} - 1}}{\sigma} \right)^2}^\omega$	Pearson genişliği parametreleri (σ, ω)

Kernel fonksiyonuna özgü parametrelerin yanında tüm DVM için düzenleme parametresi C 'nin kullanıcı tarafından belirlenmesi gerekir. Bu parametre için olması gerekenden çok küçük veya çok büyük değerler seçilmesi durumunda optimum hiper-düzlem doğru belirlenemeyeceğinden sınıflandırma doğruluğunda ciddi düşüş beklenir. Diğer taraftan $C = \infty$ olması durumunda DVM modeli sadece doğrusal olarak ayrılabilen veri setleri için uygun hale gelir. Buradan da görüleceği üzere parametreler için uygun değerlerin seçimi DVM sınıflandırıcısının performansını direkt olarak etkileyen bir faktör durumundadır. Genellikle deneme ve hata stratejisi kullanılmasına karşın, çapraz doğrulama yaklaşımı başarılı sonuçlara ulaşılmasına olanak sağlamaktadır. Çapraz doğrulama yaklaşımında amaç oluşturulan sınıflandırma modelinin performansının belirlenmesidir. Bu amaçla veri seti iki kısma ayrılır. Birinci kısım sınıflandırmaya esas olan model oluşumunda eğitim verisi olarak kullanılırken ikinci kısım modelin performansının belirlenmesi amacıyla test verisi olarak işleme konur. Eğitim seti ile oluşturulan modelin test veri setine uygulanması sonucunda doğru sınıflandırılan örneklerin sayısı sınıflandırıcısının performansını gösterir. Dolayısıyla çapraz geçerlilik yöntemi kullanılarak en iyi sınıflandırma performansının elde edildiği kernel parametrelerinin belirlenmesi ve sınıflandırmaya esas olacak modelin oluşturulmuştur.

8. MİKROSKOBİK İDRAR TORTUSU İMGELERİNDE BULUNAN HÜCRELERİN OTOMATİK TANINMASI VE SAYILMASI İÇİN GELİŞTİRİLEN KARAR DESTEK SİSTEMLERİ VE UYGULAMALARI

Tezin bu bölümünde, mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için uyarlanan karar destek sistemleri ve uygulamalarından bahsedilecektir. Sırasıyla, mikroskobik idrar tortusu imgelerinin elde edilmesi, daha sonra bu idrar tortusu imgelerini kullanarak, idrar hücrelerinin otomatik tanınması ve sayımı için uyarlanan değişmez momentler tabanlı, Hough dönüşüm tabanlı, uyarlamalı ADD tabanlı ve Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı İstatistiksel Yöntemlerle Güçlendirilmiş karar destek sistemleri yöntemlerinin uygulanması konuları irdelenecektir. En son olarak da elde edilen idrar tortusu imgelerine SBE steganografik güvenlik yöntemi kullanılarak idrar tortusu imgelerinin her biri için ait olduğu hastanın “Adı ve Soyadı”, “ Türkiye Cumhuriyeti Vatandaşlık Numarası”, “Yaşı” ve “Cinsiyeti” gibi kişisel bilgilerinin gizlenmesi işleminin nasıl yapıldığı açıklanacaktır.


8.1. Mikroskobik İdrar Tortusu İmgelerinin Elde Edilmesi

Bu tezde yapılacak çalışmalarda kullanılmak üzere Elazığ Eğitim Araştırma Hastanesinin mikrobiyoloji laboratuvarından değişik türde hastalığa sahip, bir bölümü de sağlam olan yaklaşık 180 adet hastanın her birinden 10 ml’den oluşan idrar verileri alınmıştır. Alınan bu gerçek idrar tortusu verileri her bir adımda 1 ml’lik sıvı çekmeye ayarlanmış otomatik pipet yardımı ile her biri 1 ml lik sıvı alabilen 10 bölümlü sayma lamına alınmıştır. Daha sonra 10 bölümünün her birine 1 ml idrar tortusu alınan bölümlü sayma lamı mikroskobun odağına getirilerek, mikroskop üzerindeki kamera ile bu 10 bölümün her birindeki idrar tortularının 512 x 512’lik fotoğrafları çekilerek, her bir hastadan 10 tane olmak üzere, toplam 1800 idrar tortu imgesi elde edilmiştir. Şekil 8.1’de bu tez çalışmasında kullanılan imge alma düzeneği görülmektedir.




Şekil 8.1. İdrar tortusu imgelerini almak için bu tez çalışmasında kullanılan imge alma düzeneği

Daha sonra bu idrar tortusu imgeleri, değişik karakteristik özellik gösteren hastaların tümü için başarılı tanıma ve sayma sonuçları vermek üzere uyarlanan karar destek sistemlerinin etkinliğini artırmak için eğitim ve test aşamalarında kullanılmıştır. Şekil 8.2’de elde edilen idrar tortusu imgelerinden birkaçı verilmiştir.




Şekil 8.2. Mikroskobik idrar hücre imgeleri: (a) eritrosit hücreleri (eh), (b) lökosit hücreleri (lh), (c) trombosit hücreleri (th), (d) deri hücreleri (dh), (e) kristal hücreleri (kh), (f) parazit hücreleri (ph), (g) bakteri ve mantar hücreleri (bmh), (h) sperm hücreleri (sh), (k) yabancı artıklar (ya), (l) inorganik artıklar (ia)

Ayrıca Şekil 8.3’de, elde edilen birden fazla hücrenin bulunduğu idrar tortusu imgeleri verilmiştir.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 8.3. Birden fazla hücrenin bulunduğu idrar tortusu imgeleri

8.2. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlanan Değişmez Momentler Tabanlı Karar Destek Sistemleri

Bu bölümde, Bölüm 8.1’de bahsedilen elde edilmiş gerçek idrar tortusu imgeleri kullanarak, tez çalışmaları ile uyarlanan Değişmez Momentler Tabanlı Karar Destek Sistemi (DMTKDS) tanıtılacaktır. Daha sonra sırasıyla bu karar destek sisteminde YSA, UATBÇS ve DVM sınıflandırıcılarının doğru tanıma ve sayma performans değerlendirmeleri yapılacaktır.

8.2.1. Değişmez Momentler – Yapay Sinir Ağları Yöntemi


Bu bölümde, mikroskopik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için uyarlanan Değişmez Moment – Yapay Sinir Ağları (DM-YSA) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan DM-YSA algoritması Şekil 8.3’den de görüldüğü gibi temel olarak ön işlem aşaması, özellik çıkarım aşaması, sınıflama ve test yani karar süreci olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:

8.2.1.1. Ön İşlem Süreci

Bu çalışma DM-YSA yapısı kullanılarak, tanınması istenilen mikroskopik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)’dır.

Ön işlem aşamasında, Bölüm 4’de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskopik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskopik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskopik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. En son olarakta belirginleştirilen bu idrar tortu imgesindeki hücreler otomatik pencereleme yöntemi kullanılarak tek tek tespit edilmiştir.



Şekil 8.4. Bu çalışmada kullanılan DM-YSA sisteminin blok diagramı

Bu süreçteki işlemler aşağıda kısaca özetlenmiştir:

1. Median Filtre Kullanılarak Gürültü İndirgenmesi İşleminin Gerçekleştirilmesi

Bu katmanda Median filtre yöntemi kullanılarak mikroskopik idrar tortusu imgelerinden gürültü indirgenmesi yapılmıştır. Aşağıda Şekil 8.5.(a)'da bir mikroskopik idrar tortusu imgesi, Şekil 8.5.(b)'de ise bu mikroskopik idrar tortusu imgesine Median filtre uygulanması sonucu elde edilen gürültüden arındırılmış imge görülmektedir:



Şekil 8.5. (a) Mikroskopik idrar tortusu imgesi, (b) Bu mikroskopik idrar tortusu imgesine Median filtre uygulanması sonucu elde edilen gürültüden arındırılmış imge

2. Parlaklık Artırma İşleminin Gerçekleştirilmesi

Gürültüden arındırılan gri düzeydeki idrar tortusu imgelerinde piksel değerlerini daha belirgin hale getirerek, imgedeki nesneleri ön plana çıkarabilmek amacıyla bu katmanda parlaklık artırımı işlemi yapılmıştır. Gri düzeydeki idrar tortusu imgelerinin bu işlem gerçekleştirilmeden önceki ve bu işlem sonundaki durumları sırasıyla aşağıda Şekil 8.6.(a) ve (b)'de verilmiştir.



Şekil 8. 6. (a) Mikroskopik idrar tortusu imgesi, (b) Bu mikroskopik idrar tortusu imgesine parlaklık artırımı uygulanması sonucu elde edilen imge

3. Geliştirilen Otomatik Eşikleme Yöntemi Kullanılarak Bölütleme İşleminin Gerçekleştirilmesi

Bu katmanda, geliştirilen histogram tabanlı sayısal imge eşikleme yöntemi kullanılarak bölütleme işlemi yapılmıştır. Bu tez çalışmasında geliştirilen otomatik eşikleme yönteminde temel amaç, otomatik olarak histogramdaki vadi noktalarını bulup bu vadi noktalarını referans olarak eşikleme işlemini gerçekleştirmektir. Burada, vadi noktalarını bulabilmek için istatistiksel tabanlı yeni bir algoritma önerilmiştir. Bu algoritmaya göre sayısal imgenin histogramı n adet pencereye bölünüp bu pencereler histogramın tümünden elde edilen istatistiksel sonuçlarla karşılaştırılarak bulunur. Algoritma 8 bitlik sayısal imgeler üzerinde değerlendirilmiştir. Algoritma aşağıdaki gibidir.

Adım 1: Sayısal imgenin histogramı elde edilir.

Adım 2: Histogram n adet eşit parçaya ayrılır. Uygulamalarda histogram 8 adet parçaya ayrılmıştır.

Adım 3: Histogramın her parçasının standart sapması hesaplanır.

Adım 4: Her parçanın kendi içerisinde maksimum farkı hesaplanır.

Adım 5: Hesaplanan maksimum fark parçaların standart sapmasından büyükse farktaki eksilen nokta vadi noktası olarak hesaplanır.

Adım 6: Vadi noktaları değerlerin karekökü kadar ötelenerek eşik noktaları hesaplanır.

Yukarıdaki algoritmanın matematiksel ifadesi aşağıdaki gibidir.

$$\max \text{ fark} = \sum_{i=1}^{256/n} \sum_{j=i+1}^{256/n} \max(|x_i - x_j|) \quad (8.1)$$

$$x' = \frac{1}{N} \sum_{i=1}^N x_i \quad (8.2)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x')^2} \quad (8.3)$$

$$\text{maxfark} > \sigma \} \text{esik}_s = j + k \quad (8.4)$$

H_n histogram parçası, x_i histogramdaki piksel değerleri, x' ise histogram değerlerinin aritmetik ortalaması, σ ilgili histogramın standart sapması ve k ise eşikleme katsayısı olarak hesaplanmaktadır. İlgili algoritmada k katsayısı $\sqrt{2^8}$ yani 16 olarak alınmıştır. Denklem (8.3) ve (8.4)'de standart sapmanın formülü gösterilmektedir.

Adım 6'da ötelemeden kasıt toplama işlemidir. Resim 8 bit olduğu için, resme ait piksel değerleri 0 ile 255 arasında 256 adet piksel değeri almaktadır. 256 değerinin karekökü 16 olduğu için bulunan vadi değerlerine 16 eklenmektedir. Algoritmayı test etmek için aşağıdaki 3 adet gri seviyeli resim kullanılmıştır.

Bu amaç için imgenin gri seviye histogramında yer alana vadi noktaları esas alınmaktadır. Bu yöntem gri seviye imgelerde çok iyi sonuçlar vermektedir. Literatürde, farklı bölütleme teknikleri mevcuttur [76], [101]. Aşağıda gri düzeydeki idrar tortusu imgelerinin bu işlem gerçekleştirilmeden önceki ve bu işlem sonundaki durumları sırasıyla Şekil 8.7.(a) ve (b)'de verilmiştir.



Şekil 8. 7. (a). Mikroskobik idrar tortusu imgesi, (b) Bu mikroskobik idrar tortusu imgesine geliştirilen otomatik eşikleme yöntemi tabanlı bölütleme işlemi uygulanması sonucu elde edilen imge

4. Morfolojik ve Mantıksal İşlemler

Bazen bir imgedeki nesne ile arka planı birbirinden ayırt etmek için uygun eşik değerini seçmek yeterli olmayabilir. Bu durumda, ilave işlemler yapmak gerekir. İmge işlemede

gereksiz arka plan çizgileri bazı teknikler kullanılarak yok edilebilir. İşte bu teknikler, bazı morfolojik ve mantıksal operatörler kullanılarak gerçekleştirilir. Bu çalışmada, morfolojik ve mantıksal operatörler olarak, erosion ve nesnelerdeki boşlukları doldurma operatörleri kullanılmıştır. Bu morfolojik ve mantıksal işlemler yapılmadan ve yapıldıktan sonraki örnek bir idrar tortusu imgesi Şekil 8.8.(a) ve (b)'de verilmiştir.



Şekil 8. 8. (a) Boşlukları doldurulduktan sonra elde edilen mikroskobik idrar tortusu imgesi, (b) erosion işleminden sonra elde edilen mikroskobik idrar tortusu imgesi

5. Otomatik Pencereleme Yönteminin Uygulanması

Bu işlem, belirginleştirilmiş her bir idrar tortu imgesindeki hücrelerin tek tek tespit edilerek bundan sonraki işlemlerin bu tekli hücreler üzerinde gerçekleştirilmesi için gereklidir. Bunun için kullanılan otomatik pencereleme algoritması aşağıda maddeler halinde verilmiştir:

Adım 1: Renkli mikroskobik idrar hücre imgesi, gri seviye imgeye çevrilir.

Adım 2: Geliştirilen otomatik eşikleme algoritması kullanılarak, gri imge siyah beyaz imge haline getirilir.

Adım 3: Sekizli zincir kodlama kullanılarak, hücrelerin lokasyon bilgisi B adında bir veri yapısına kaydedilir.

Adım 4: B veri yapısında tutulan lokasyon bilgileri kullanılarak, hücreler tek tek imgeden çıkarılır.

Bundan sonra özellik çıkarım, sınıflandırma ve test süreçlerinde yapılacak işlemler, otomatik pencereleme tekniği ile pencerelenerek tespit edilmiş tekli idrar hücreleri kullanılarak gerçekleştirilecektir.

8.2.1.2. Özellik Çıkarım Süreci


Özellik çıkarım süreci örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar yapılmaktadır [76-102].

1. Hu'nun 7 Adet Değişmez Moment Değerinin Hesaplanması

Bu süreçte, Bölüm 8.1'de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1'de belirtilen ön işlem ve otomatik pencereleme aşamaları sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20'ser adedi alınmıştır. Böylece 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Dolayısıyla her bir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, her bir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Özellik çıkarım sürecinde elde edilen bu imgelerin her biri için 7'ser adet Hu değişmez moment değeri hesaplanmıştır. Böylelikle 2000×7 'lik bir özellik vektörü elde edilmiş olup bu özellik vektörü, sınıflandırma aşamasında YSA sınıflandırıcısının girişlerine verilmiştir. Tablo 8.1'de örnek olarak 120° lik döndürmeyle elde edilmiş idrar hücresi imgesinin hesaplanan değişmez moment değerleri (ϕ_i) gösterilmiştir.

Tablo 8. 1. YSA eğitimi için kullanılan idrar hücresi imgesinin değişmez moment değerleri (ϕ_i)

Ön işlemden önce	Ön işlemden sonra
	
Eritrosit hücresi (eh) $\phi = [2.6500 \ 16.2760 \ 19.4347 \ 32.9802 \ 59.4368 \ 41.9241 \ 60.0753]$	
	
Lökosit hücresi (lh) $\phi = [2.5126 \ 9.9357 \ 12.1359 \ 20.5206 \ 37.5438 \ 26.3319 \ 37.4706]$	
	
Trombosit hücresi (th) $\phi = [2.5921 \ 8.8748 \ 10.9724 \ 15.1892 \ 23.2813 \ 15.3046 \ 28.7753]$	
	
Deri hücresi (dh) $\phi = [1.5548 \ 5.3618 \ 6.2677 \ 7.8117 \ 15.2380 \ 10.5412 \ 16.1356]$	
	
Kristal hücresi (kh) $\phi = [2.5826 \ 13.3253 \ 12.6522 \ 17.9356 \ 15.7382 \ 40.8638 \ 55.4324]$	
	
Parazit hücresi (ph) $\phi = [2.5891 \ 9.0958 \ 17.4068 \ 19.2826 \ 37.6518 \ 23.9309 \ 40.3354]$	
	
Bakteri ve mantar hücreleri (bmh) $\phi = [1.1534 \ 3.3469 \ 4.0387 \ 5.5930 \ 10.4441 \ 7.4666 \ 12.6033]$	
	
Sperm hücresi (sh) $\phi = [0.1734 \ 1.9552 \ 0.9257 \ 0.7044 \ 0.6259 \ 1.6899 \ 2.8547]$	
	
Yabancı artıklar (ya) $\phi = [2.5920 \ 13.9600 \ 12.6824 \ 18.2685 \ 34.0544 \ 26.1750 \ 37.0423]$	
	
İnorganik artıklar (ia) $\phi = [1.5543 \ 4.6325 \ 5.2218 \ 5.9191 \ 11.4984 \ 8.2387 \ 14.6672]$	

8.2.1.3. Sınıflandırma Süreci

Sınıflandırma sürecinde, özellik çıkarım sürecinde elde edilen özellikler YSA sınıflandırıcının girişlerine verilmiştir. Sınıflandırma sürecinin amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.

1. YSA Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi


Bölüm 7’de YSA’nın sınıflandırıcı olarak kullanımı hakkında detaylı bilgi verildiği için burada sadece bu tez çalışmasında kullanılan eğiticili YSA öğrenme algoritmalarından geriye yayılım öğrenme algoritması hakkında bilgi verilecektir.

Geriye Yayılım Yapay Sinir Ağları

Geriye yayılım ağı, çok katmanlı ileri yön bağlamalı bir ağıdır. Giriş ile çıkış katmanları arasında, birden fazla katmanın kullanıldığı YSA sistemidir. Gizli katman olarak isimlendirilen bu ara katmanlarda, aracısız giriş alamayan ve aracısız çıkış veremeyen işlem elemanları vardır. Şekil 8.9’da çok katmanlı algılayıcı YSA’nın genel yapısı verilmiştir [20], [99].

Çok katmanlı ağlarda veriler, giriş katmanı tarafından kabul edilirler. Ağ içindeki işlemler sonucunda çıkış katmanında oluşan cevap ile giriş verisine karşı istenen cevap karşılaştırılır. Hesaplanan cevap ile istenen cevap arasında herhangi bir farklılık varsa, katmanlar arasında bulunan ağırlıklar bu farkı azaltacak şekilde yeniden düzenlenir [96]. YSA’nın girişindeki veriler, ağırlıklar uygun noktaya ulaşana kadar değişmez. Hesaplanan çıkış cevapları, istenen cevaplarla karşılaştırılarak, sonuçta hata işareti elde edilir [20]. Hata işareti, ara katmanlardan çıkış katmanına olan ağırlıkları değiştirmekte de kullanılır. Çok sayıda ara katmana sahip sistemlerde her katmanın hata işaretleri, bir önceki katmanın düzeltilmiş hata işaretlerinden çıkartılarak işlem tekrarlanır. Sonuç olarak ağırlık düzeltme işlemi çıkış seviyesine bağlı ağırlıklardan başlar ve işlem ters yönde giriş seviyesine varana kadar devam eder. Sistem, sonuçta yine hatalar yapar, fakat bu hatalardan bir şeyler öğrenip istenen cevabı bulana kadar

işlem tekrarlanır. Bu yöntem hata geriy yayılma algoritması denir. Denklem (8.1)'de bu algoritmanın öğrenme sürecinde kullanılan matematiksel yapı verilmiştir.



Şekil 8. 9. Çok katmanlı ileri beslemeli yapay sinir ağları

$$w_{ij}(t+1) = w_{ij}(t) + \varepsilon \cdot h_j \cdot y_i + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1)) \quad (8.1)$$

Burada, öğrenme oranı $0 < \alpha < 1$ ve momentum katsayısı $0.001 < \varepsilon < 10$ dur. h_j ise j . katmandaki hata işaretidir. Bu değer ağı verilen giriş için istenen çıkış değerindeki sapmadan kaynaklanmaktadır.


Hata geri yayılım algoritması eğitici bir öğrenmedir. Eğitici öğrenmede, dışardan bir eğiticinin sinir ağına müdahalesi söz konusudur. Eğitici, sinir ağının ilgili girdi için üretmesi gereken sonucu sinir ağı sistemine verir. YSA'ya girdi/çıkıktı ikilisinden oluşan örnekler sunulur. Bu ikili, ağın öğrenmesi gereken özellikleri temsil eder. Bu algoritmanın detayları [20], [85] de bulunabilir.

Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. DM-YSA sınıflandırma yöntemi için kullanılan ileri beslemeli çok katmanlı YSA'nın eğitim parametreleri ve yapısı Tablo 8.2'de gösterilmiştir. Bunlar, bir kaç farklı deneme ile, yani gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri, en iyi

başarım için seçilmiştir. Şekil 8.10'da ise bu yöntem ile elde edilen özellikler ile kullanılan YSA'nın eğitim başarımı görülmektedir.

Tablo 8. 2.Uyarlanan DM-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 7 Gizli : 10 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayılım
Toplam karesel hata	0.0000001



Şekil 8. 10. DM-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı

8.2.1.4. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 7'lik özellik vektörü ise sınıflandırma sürecinde eğitilmiş YSA sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen DM-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.3'de verilmiştir.


Tablo 8. 3.DM-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	174	26	87.00
Trombosit hücreleri (th)	182	18	91.00
Eritrosit hücreleri (eh)	172	28	86.00
Deri hücreleri (dh)	178	22	89.00
Kristal hücreleri (kh)	184	16	92.00
Parazit hücreleri (ph)	180	20	90.00
Bakteri ve mantar hücreleri (bmh)	180	20	90.00
Sperm hücreleri (sh)	182	18	91.00
Yabancı artıklar (ya)	186	14	93.00
Inorganik artıklar (ia)	180	20	90.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1798	202	89.90

8.2.2. Değişmez Momentler–Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlanan Değişmez Moment – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım sistemi (DM-UATBÇS) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan DM-UATBÇS algoritması Şekil 8.11’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test yani karar süreci olmak üzere dört kısımdan meydana gelmiştir.



Şekil 8.11. Bu çalışmada kullanılan DM-UATBÇS sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.2.1’deki ile aynı olduğu için bu bölümde sadece sistemin sınıflandırma kısmı açıklanacaktır.

8.2.2.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi

Sınıflandırma sürecinde, özellik çıkarım sürecinde elde edilen bu imgelerin her biri için 7'şer adet Hu değişmez moment değeri hesaplanmıştır. Böylelikle 2000 x 7'lik bir özellik vektörü elde edilmiş olup bu özellik vektörü, sınıflandırma aşamasında UATBÇS sınıflandırıcısının girişlerine verilmiştir.

Burada, Bölüm 7'de bahsedilen Uyarlamalı UATBÇS sınıflandırıcısı kullanılmıştır. Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. DM-UATBÇS sınıflandırma yöntemi için kullanılan eğitim parametreleri ve yapısı Tablo 8.4'de gösterilmiştir. Bu giriş üyelik fonksiyon tipi, her bir giriş için giriş üyelik fonksiyonu sayısı ve öğrenme oranı gibi eğitim parametreleri, en iyi başarımlar için birkaç farklı deneme ile seçilmiştir. Tablo 8.5'de ise bu yöntem ile elde edilen özellikler ile kullanılan UATBÇS sınıflandırıcısının doğru tanıma başarımı görülmektedir.

Tablo 8. 4.Uyarlanan DM-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri

UATBÇS Modelinin Yapısı	
Katman sayısı	5
Katmanlardaki nöron sayısı	Giriş : 7 Kural sayısı : 128 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metodu ile hesaplandı
Eğitim Parametreleri	
Öğrenme kuralı	Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Toplam karesel hata (sse)	0.000000001

8.2.2.2. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 7'lik özellik vektörü ise sınıflandırma sürecinde eğitilmiş UATBÇS sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen DM-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.5’de verilmiştir.


Tablo 8.5. DM-UATBÇS sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları.

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	182	18	91.00
Trombosit hücreleri (th)	186	14	93.00
Eritrosit hücreleri (eh)	176	24	88.00
Deri hücreleri (dh)	180	20	90.00
Kristal hücreleri (kh)	188	12	94.00
Parazit hücreleri (ph)	180	20	90.00
Bakteri hücreleri (bh)	181	19	90.50
Mantar hücreleri (mh)	184	16	92.00
Yabancı artıklar (ya)	188	12	94.00
Inorganik artıklar (ia)	182	18	91.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımları (%)
	1827	173	91.35

8.2.3. Değişmez Momentler – Çoklu Destek Vektör Makineleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlanan Değişmez Moment – Çoklu Destek Vektör Makineleri (DM-ÇDVM) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir. Burada kullanılan ÇDVM sınıflandırıcısı ile ilgili temel bilgiler Bölüm 7’de verilmiştir.

Burada kullanılan DM-ÇDVM algoritması Şekil 8.12’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama, test yani karar süreci olmak üzere dört kısımdan meydana gelmiştir.



Şekil 8. 12. Bu çalışmada kullanılan DM-ÇDVM sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.2.1'deki ile aynı olduğu için bu bölümde sadece sistemin sınıflandırma kısmı açıklanacaktır.

8.2.3.1. Çoklu Destek Vektör Makineleri Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi

Sınıflandırma sürecinde, özellik çıkarım sürecinde elde edilen bu imgelerin her biri için 7'şer adet Hu değişmez moment değeri hesaplanmıştır. Böylelikle 2000 x 7'lik bir özellik vektörü elde edilmiş olup bu özellik vektörü, sınıflandırma aşamasında ÇDVM sınıflandırıcısının girişlerine verilmiştir.

Tablo 8. 6.Kullanılan ÇDVM sınıflandırıcısının özellikleri.

Kullanılan Çekirdek Fonksiyon Tipi : Radyal Tabanlı Fonksiyon (RTF)
Hata Tolerans Sabiti (C): 10
Çekirdek Fonksiyonu Parametresi (σ): 4

Burada, Bölüm 7'de bahsedilen ÇDVM sınıflandırıcısı kullanılmıştır. Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. DM-ÇDVM sınıflandırma yöntemi için kullanılan eğitim parametreleri ve yapısı Tablo 8.6'da gösterilmiştir. Bunlar, yani kullanılan çekirdek fonksiyon tipi, hata tolerans sabiti ve çekirdek fonksiyon parametresi değerleri bir kaç farklı deneme ile en iyi başarımlar için seçilmiştir. Tablo 8.7'de ise bu yöntem ile elde edilen özellikler ile kullanılan ÇDVM sınıflandırıcısının doğru tanıma başarımları görülmektedir.

8.2.3.2. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 7'lik özellik vektörü ise sınıflandırma sürecinde eğitilmiş ÇDVM sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen DM- ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.7'de verilmiştir.

Tablo 8. 7.DM-ÇDVM sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımı

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	183	17	91.50
Trombosit hücreleri (th)	188	12	94.00
Eritrosit hücreleri (eh)	177	23	88.50
Deri hücreleri (dh)	181	19	90.50
Kristal hücreleri (kh)	188	12	94.00
Parazit hücreleri (ph)	181	19	90.50
Bakteri ve mantar hücreleri (bmh)	182	18	91.00
Sperm hücreleri (sh)	186	14	93.00
Yabancı artıklar (ya)	188	12	94.00
Inorganik artıklar (ia)	184	16	92.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1838	162	91.90

8.3. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlanan Hough Dönüşüm Tabanlı Karar Destek Sistemleri

Bu bölümde, Bölüm 8.1’de bahsedilen elde edilmiş gerçek idrar tortusu imgeleri kullanılarak, tez çalışmaları ile uyarlanan HDTKDS tanıtılacaktır. Daha sonra sırasıyla bu karar destek sisteminde YSA, UATBÇS ve DVM sınıflandırıcılarının doğru tanıma ve sayma performans değerlendirmeleri yapılacaktır.

8.3.1. Hough Dönüşümü – Yapay Sinir Ağları Yöntemi


Bu bölümde, mikroskopik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için uyarlanan Hough Dönüşümü– Yapay Sinir Ağları (HD-YSA) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan HD-YSA algoritması Şekil 8.13’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:

8.3.1.1. Ön İşlem Süreci

Bu çalışmada HD-YSA yapısı kullanılarak, tanınması istenilen mikroskopik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph),), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)’dır.

Ön işlem aşamasında, Bölüm 4’de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskopik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskopik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskopik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. Burada ayrı bir otomatik pencereleme yöntemi kullanılmayıp, pencereleme işlemi Hough dönüşüm işlemi içerisinde gerçekleştirilmiştir.



Şekil 8. 13. Bu çalışmada kullanılan HD-YSA sisteminin blok diagramı

Bu aşamalardan ön işlem süreci Bölüm 8.2.1’deki ile aynı olduğu için bu bölümde sadece sistemin özellik çıkarımı ve sınıflandırma süreçleri açıklanacaktır.


8.3.1.2. Özellik Çıkarım Süreci

Özellik çıkarım süreci örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü

sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır.

Bu süreçte ise Bölüm 8.1’de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1’de belirtilen ön işlem aşaması sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20’şer adedi alınmıştır. Böylelikle 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Böylelikle herbir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Şekil 8.14.(a), (b) ve (c)’de sırasıyla bir idrar tortusunda bulunan kan hücreleri imgesi, idrar tortusunda bulunan kan hücreleri imgesine Hough Dönüşümünün uygulanmış hali ve bu imgeye Hough Dönüşümü uygulanarak yerleri tespit edilen idrar içindeki kan hücreleri verilmiştir.



Şekil 8. 14. (a) İdrar tortusunda bulunan kan hücreleri imgesi (b) İdrar tortusunda bulunan kan hücreleri imgesine Hough Dönüşümünün uygulanmış hali (c) Hough Dönüşüm uygulanarak yerleri tespit edilen idrar içindeki kan hücreleri

Bu özellik çıkarım sürecinde yukarıda bahsedilen ön işlemde geçirilmiş idrar tortusu imgelerine sırasıyla Hough Dönüşümü (HD) yöntemi uygulanarak elde edilen pencerelenmiş idrar hücre imgelerinin sırasıyla matematiksel denklemleri Bölüm 3’de verilmiş olan Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri hesaplanmıştır. Böylelikle 2000 x 6’lık bir özellik vektörü elde edilmiş olup bu özellik vektörü, sınıflandırma aşamasında YSA sınıflandırıcısının girişlerine verilmiştir.

Burada hesaplanacak norm entropi p parametre değerinin $0 < p \leq 2$ arasında olması gerekmektedir. Bu parametre değeri Şekil 8.13’de de belirtildiği gibi 0.1’lik adımlarla uyarlamalı olarak artırılarak elde edilen uyarlamalı norm entropi değeri özellik vektörü içerisinde sınıflandırma aşamasında kullanılan YSA sınıflandırıcısının girişlerine verilmiştir. Bu parametre uyarlama işlemi YSA sınıflandırıcısının eğitimi sonucunda bulunan hata değerinin arzu edilen hata değerine eşit çıkmasına ya da bu hata değerinin altına inmesine kadar devam ettirilmiştir.

8.3.1.3. Sınıflandırma Süreci


Sınıflandırma süreci için kullanılacak 2000 adet farklı imgeden elde edilmiş Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerlerinden oluşmuş özellik vektörü YSA sınıflandırıcısının girişlerine verilmiştir. Sınıflandırma sürecinin amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.

Burada Hough Dönüşümü (HD)’nin kullanılması ile tekli idrar hücrelerinin herbiri için bulunan Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri ile üst üste binmiş idrar hücreleri için bulunan Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri birbirlerinden çok farklı çıkmaktadır. Bu da, YSA sınıflandırıcısının girişlerine verilen özelliklerin çok etkili olmasını ve dolayısıyla bu yöntemin idrar imgelerindeki hücrelerin doğru sınıflandırılması ve tanınması başarımının artmasını sağlamıştır.

Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. HD-YSA sınıflandırma yöntemi için kullanılan ileri beslemeli çok katmanlı YSA'nın eğitim parametreleri ve yapısı Tablo 8.8'de gösterilmiştir. Bunlar, bir kaç farklı deneme ile, yani gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri, en iyi başarımlar için seçilmiştir. Şekil 8.15'de ise bu yöntem ile elde edilen özellikler ile kullanılan YSA'nın eğitim başarımları görülmektedir.

Tablo 8. 8.Uyarlanan HD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 6 Gizli : 10 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayılım
Toplam karesel hata	0.0000001



Şekil 8. 15. HD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımı

8.3.1.4. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000×6 'lık özellik vektörü ise sınıflandırma sürecinde eğitilmiş YSA sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen HD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.9'da verilmiştir.


Tablo 8. 9.HD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	185	15	92.50
Trombosit hücreleri (th)	188	12	94.00
Eritrosit hücreleri (eh)	178	22	89.00
Deri hücreleri (dh)	182	18	91.00
Kristal hücreleri (kh)	188	12	94.00
Parazit hücreleri (ph)	181	19	90.50
Bakteri ve mantar hücreleri (bmh)	182	18	91.00
Sperm hücreleri (sh)	187	13	93.50
Yabancı artıklar (ya)	188	12	94.00
Inorganik artıklar (ia)	184	16	92.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1843	157	92.15

8.3.2. Hough Dönüşümü – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için uyarlanan Hough Dönüşümü– Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (HD-UATBÇS) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan HD-UATBÇS algoritması Şekil 8.16’ dan da görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:



Şekil 8.16. Bu çalışmada kullanılan HD-UATBÇS sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.4.1'deki ile aynı olduğu için bu bölümde sadece sistemin sınıflandırma ve test kısımları açıklanacaktır.

8.3.2.1. Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi

Burada, Bölüm 7’de bahsedilen Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UATBÇS) sınıflandırıcısı kullanılmıştır. Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. HD-UATBÇS sınıflandırma yöntemi için kullanılan eğitim parametreleri ve yapısı Tablo 8.10’da gösterilmiştir. Bu giriş üyelik fonksiyon tipi, her bir giriş için giriş üyelik fonksiyonu sayısı ve öğrenme oranı gibi eğitim parametreleri, en iyi başarımlar için birkaç farklı deneme ile seçilmiştir. Tablo 8.11’de ise bu yöntem ile elde edilen özellikler ile kullanılan UATBÇS sınıflandırıcısının doğru tanıma başarımı görülmektedir.

Tablo 8. 10.Uyarlanan HD-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri

UATBÇS Modelinin Yapısı	
Katman sayısı	5
Katmanlardaki nöron sayısı	Giriş : 6 Kural sayısı : 64 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metodu ile hesaplandı
Eğitim Parametreleri	
Öğrenme kuralı	Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Toplam karesel hata (sse)	0.000000001

Sınıflandırma süreci için kullanılacak 2000 adet farklı imgeden elde edilmiş Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerlerinden oluşmuş özellik vektörü UATBÇS sınıflandırıcısının girişlerine verilmiştir. Sınıflandırma sürecinin amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.

8.3.2.2. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 6'lık özellik vektörü ise sınıflandırma sürecinde eğitilmiş UATBÇS sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen sistemin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.11'de verilmiştir.


Tablo 8. 11. HD-UATBÇS sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	183	17	92.50
Trombosit hücreleri (th)	188	12	94.00
Eritrosit hücreleri (eh)	180	20	89.00
Deri hücreleri (dh)	183	17	91.00
Kristal hücreleri (kh)	186	14	94.00
Parazit hücreleri (ph)	183	17	90.50
Bakteri ve mantar hücreleri (bmh)	183	17	91.00
Sperm hücreleri (sh)	186	14	93.50
Yabancı artıklar (ya)	192	8	94.00
Inorganik artıklar (ia)	186	14	92.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1850	150	92.50

8.3.3. Hough Dönüşümü – Çoklu Destek Vektör Makineleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlanan Hough Dönüşümü – Çoklu Destek Vektör Makineleri (HD-ÇDVM) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir. Burada kullanılan ÇDVM sınıflandırıcısı ile ilgili temel bilgiler Bölüm 7’de verildiği için burada çok detaylı verilmeyecektir.

Burada kullanılan HD-ÇDVM algoritması Şekil 8.13’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreci olmak üzere dört kısımdan meydana gelmiştir.



Şekil 8.17. Bu çalışmada kullanılan HD-ÇDVM sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.4.1'deki ile aynı olduğu için bu bölümde sadece sistemin sınıflandırma ve test kısımları açıklanacaktır.

8.3.3.1. Çoklu Destek Vektör Makineleri Sınıflandırıcısı Kullanılarak Gerçekleştirilen Sınıflandırma İşlemi

Sınıflandırma süreci için kullanılacak 2000 adet farklı imgeden elde edilmiş Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerlerinden oluşmuş özellik vektörü ÇDVM sınıflandırıcısının girişlerine verilmiştir.

Böylelikle 2000 x 6'lık bir özellik vektörü elde edilmiş olup bu özellik vektörü, sınıflandırma aşamasında ÇDVM sınıflandırıcısının girişlerine verilmiştir.

Tablo 8.12.Kullanılan ÇDVM sınıflandırıcısının özellikleri

Kullanılan Çekirdek Fonksiyon Tipi : Radyal Tabanlı Fonksiyon (RTF)
Hata Tolerans Sabiti (C): 10
Çekirdek Fonksiyonu Parametresi (σ): 4

Burada, Bölüm 7'de bahsedilen ÇDVM sınıflandırıcısı kullanılmıştır. Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. HD-ÇDVM sınıflandırma yöntemi için kullanılan eğitim parametreleri ve yapısı Tablo 8.12'de gösterilmiştir. Bunlar, yani kullanılan çekirdek fonksiyon tipi, hata tolerans sabiti ve çekirdek fonksiyon parametresi değerleri bir kaç farklı deneme ile en iyi başarımlar için seçilmiştir. Tablo 8.13'de ise bu yöntem ile elde edilen özellikler ile kullanılan ÇDVM sınıflandırıcısının doğru tanıma başarımı görülmektedir.

Tablo 8. 13.HD-ÇDVM sisteminin mikroskobik idrar hücresi çeşitlerini doğru tanıma başarımı

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	190	10	95.00
Trombosit hücreleri (th)	192	8	96.00
Eritrosit hücreleri (eh)	183	17	91.50
Deri hücreleri (dh)	183	17	91.50
Kristal hücreleri (kh)	184	16	92.00
Parazit hücreleri (ph)	183	17	91.50
Bakteri ve mantar hücreleri (bmh)	183	17	91.50
Sperm hücreleri (sh)	186	14	93.00
Yabancı artıklar (ya)	191	9	94.00
Inorganik artıklar (ia)	180	10	90.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1855	145	92.75

8.4. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlamalı Ayırık Dalgacık Dönüşüm Tabanlı Karar Destek Sistemleri

Tezin bu bölümünde, Bölüm 8.1’de bahsedilen elde edilmiş gerçek idrar tortusu imgeleri kullanılarak, İdrar Hücrelerinin Otomatik Tanınması ve Sayımı için Uyarlamalı Ayırık Dalgacık Dönüşüm Tabanlı Karar Destek Sistemleri tanıtılacaktır. Bu karar destek

sistemlerinin yapısında 3 adet uyarlamalı ayırık dalgacık tabanlı model kullanılmıştır. Bu modellerde, örüntü tanımda kilit rolü oynayan özellik çıkarımı, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir. Bu adaptif yapı, entropi hesaplama tekniğinin parametrelerine müdahale edilerek sağlanmıştır.

8.4.1. Uyarlamalı Ayırık Dalgacık Dönüşümü - Yapay Sinir Ağları Yöntemi


Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlamalı Ayırık Dalgacık Dönüşüm – Yapay Sinir Ağları (UADD-YSA) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan UADD-YSA algoritması Şekil 8.18’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:

8.4.1.1. Ön İşlem Süreci

Bu çalışmada UADD-YSA yapısı kullanılarak, tanınması istenilen mikroskobik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph),), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)’dır.

Ön işlem aşamasında, Bölüm 4’de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskobik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskobik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskobik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. En son olarakta belirginleştirilen bu idrar tortu imgesindeki hücreler, otomatik pencereleme yöntemi kullanılarak tek tek tespit edilmiştir.



Şekil 8.18. Bu çalışmada kullanılan UADD-YSA sisteminin blok diagramı


Bu aşamalardan ön işlem süreci Bölüm 8.2.1’deki ile aynı olduğu için bu bölümde sadece sistemin özellik çıkarımı ve sınıflandırma süreçleri açıklanacaktır.

8.4.1.2. Özellik Çıkarım Süreci

Özellik çıkarım süreci örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır.

Bu süreçte ise Bölüm 8.1’de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1’de belirtilen ön işlem ve otomatik pencereleme aşamaları sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20’şer adedi alınmıştır. Böylelikle 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Böylelikle herbir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Bu özellik çıkarım sürecinde yukarıda bahsedilen ön işlemde geçirilmiş ve otomatik pencereleme yöntemi kullanılarak pencerelenmiş herbir idrar hücre imgesine Ayrık Dalgacık Dönüşümü (ADD) yöntemi uygulanarak Bölüm 6’da da belirtildiği gibi 1. seviyede ayrışım sonucu Dikey-Dikey (D-D1) (Yaklaşık), Dikey-Yatay (D-Y1), Yatay-Dikey (Y-D1), Yatay-Yatay (Y-Y1) (Köşegen) olmak üzere 4 alt imge elde edilmiştir. Daha sonra bu dört alt imgenin her biri için sırasıyla Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri elde edilerek, $4000 \times 4 \times 6$ boyutlarında özellik vektörü oluşturulmuştur. Bu 4000×24 ’lük özellik vektörünün, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000×24 adedi sınıflandırma sürecinde, geriye kalan diğer 2000×24 adedi ise test sürecinde kullanılmıştır. Şekil 8.19’da bu çalışmada kullanılan UADD-YSA sisteminin özellik çıkarım mekanizması verilmiştir.



Şekil 8.19. Bu çalışmada kullanılan UADD-YSA sisteminin özellik çıkarma mekanizması

8.4.1.3. Sınıflandırma Süreci

Özellik çıkarma sürecinde elde edilen ve sınıflandırma süreci için kullanılacak 2000 x 24 boyutundaki özellik vektörü YSA sınıflandırıcının girişlerine verilmiştir. Burada hesaplanacak norm entropi p parametre değerinin $0 < p \leq 2$ arasında olması gerekmektedir. Bu parametre değeri Şekil 8.18’de de belirtildiği gibi 0.1’lik adımlarla uyarlamalı olarak artırılarak elde edilen uyarlamalı norm entropi değeri özellik vektörü içerisinde sınıflandırma aşamasında kullanılan YSA sınıflandırıcının girişlerine verilmiştir. Bu parametre uyarlama işlemi YSA sınıflandırıcısının eğitimi sonucunda bulunan hata değerinin arzu edilen hata değerine eşit çıkmasına ya da bu hata değerinin altına inmesine kadar devam ettirilmiştir.


Burada, Ayırık Dalgacık Dönüşümü’nün (ADD) kullanılması ile tekli idrar hücrelerinin herbiri için bulunan Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri ile üst üste binmiş idrar hücreleri için bulunan Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E)

değerleri birbirlerinden çok farklı çıkmaktadır. Bu da, YSA sınıflandırıcısının girişlerine verilen özelliklerin çok etkili olmasını ve dolayısıyla bu yöntemin idrar imgelerindeki hücrelerin doğru sınıflandırılması ve tanınması başarımının artmasını sağlamıştır.

Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. UADD-YSA sınıflandırma yöntemi için kullanılan ileri beslemeli çok katmanlı YSA'nın eğitim parametreleri ve yapısı Tablo 8.14'de gösterilmiştir. Burada belirtilen gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri gibi eğitim parametreleri bir kaç farklı deneme ile en iyi başarımlar için seçilmiştir. Şekil 8.20'de ise bu yöntem ile elde edilen özellikler ile kullanılan YSA'nın eğitim başarımı görülmektedir.

Tablo 8.14. UADD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 6 Gizli : 10 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayılım
Toplam karesel hata	0.0000001



Şekil 8.20. UADD-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarıımı

8.4.1.4. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000×24 'lük özellik vektörü ise sınıflandırma sürecinde eğitilmiş YSA sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen UADD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.15’de verilmiştir.

Tablo 8. 15. UADD-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	192	8	96.00
Trombosit hücreleri (th)	186	14	97.00
Eritrosit hücreleri (eh)	190	10	92.00
Deri hücreleri (dh)	188	12	91.50
Kristal hücreleri (kh)	192	8	93.00
Parazit hücreleri (ph)	188	12	92.50
Bakteri ve mantar hücreleri (bmh)	192	8	92.00
Sperm hücreleri (sh)	188	12	96.00
Yabancı artıklar (ya)	191	9	97.50
Inorganik artıklar (ia)	192	8	93.00
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1899	101	94.95

8.4.2. Uyarlamalı Ayrık Dalgacık Dönüşüm - Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi


Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlamalı Ayrık Dalgacık Dönüşüm – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-UATBÇS) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan UADD- UATBÇS algoritması Şekil 8.21’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir.

8.4.2.1. Ön İşlem Süreci

Bu çalışmada UADD-UATBÇS yapısı kullanılarak, tanınması istenilen mikroskopik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)'dır.

Ön işlem aşamasında, Bölüm 4'de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskopik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskopik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskopik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. En son olarakta belirginleştirilen bu idrar tortu imgesindeki hücreler, otomatik pencereleme yöntemi kullanılarak tek tek tespit edilmiştir.




Şekil 8.21. Bu çalışmada kullanılan UADD-UATBÇS sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.4.1'deki ile aynı olduğu için bu bölümde sadece sistemin özellik çıkarım sürecinden kısaca bahsedilerek, sınıflandırma ve test süreçleri detaylı bir şekilde açıklanacaktır.

8.4.2.2. Özellik Çıkarım Süreci

Bu süreçte ise Bölüm 8.1’de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1’de belirtilen ön işlem ve otomatik pencereleme aşamaları sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20’şer adedi alınmıştır. Böylelikle 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Böylelikle herbir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Bu özellik çıkarım sürecinde yukarıda bahsedilen ön işlemde geçirilmiş ve otomatik pencereleme yöntemi kullanılarak pencerelenmiş herbir idrar hücre imgesine Ayrık Dalgacık Dönüşümü (ADD) yöntemi uygulanarak Bölüm 6’da da belirtildiği gibi 1. seviyede ayrışım sonucu Dikey-Dikey (D-D1) (Yaklaşık), Dikey-Yatay (D-Y1), Yatay-Dikey (Y-D1), Yatay-Yatay (Y-Y1) (Köşegen) olmak üzere 4 alt imge elde edilmiştir. Daha sonra bu dört alt imgenin her biri için sırasıyla Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri elde edilerek, $4000 \times 4 \times 6$ boyutlarında özellik vektörü oluşturulmuştur. Bu 4000×24 ’lük özellik vektörünün, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000×24 adedi sınıflandırma sürecinde, geriye kalan diğer 2000×24 adedi ise test sürecinde kullanılmıştır. Şekil 8.22’de bu çalışmada kullanılan UADD-UATBÇS sisteminin özellik çıkarım mekanizması verilmiştir.



Şekil 8.22. Bu çalışmada kullanılan UADD-UATBÇS sisteminin özellik çıkarım mekanizması

8.4.2.3. Sınıflandırma Süreci

Özellik çıkarım sürecinde elde edilen ve sınıflandırma süreci için kullanılacak 2000×24 boyutundaki özellik vektörü UATBÇS sınıflandırıcının girişlerine verilmiştir. Burada hesaplanacak norm entropi p parametre değerinin $0 < p \leq 2$ arasında olması gerekmektedir. Bu parametre değeri Şekil 8.21’de de belirtildiği gibi 0.1’lik adımlarla uyarlamalı olarak artırılarak elde edilen uyarlamalı norm entropi değeri özellik vektörü içerisinde sınıflandırma aşamasında kullanılan UATBÇS sınıflandırıcının girişlerine verilmiştir. Bu parametre uyarlama işlemi UATBÇS sınıflandırıcısının eğitimi sonucunda bulunan hata değerinin arzu edilen hata değerine eşit çıkmasına ya da bu hata değerinin altına inmesine kadar devam ettirilmiştir.

Bu giriş üyelik fonksiyon tipi, her bir giriş için giriş üyelik fonksiyonu sayısı ve öğrenme oranı gibi eğitim parametreleri, en iyi başarımlar için birkaç farklı deneme ile seçilmiştir. Bu eğitim parametreleri, Tablo 8.16’da verilmiştir.

Tablo 8.16. UADD-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri

UATBÇS Modelinin Yapısı	
Katman sayısı	5
Katmanlardaki nöron sayısı	Giriş : 24 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metodu ile hesaplandı
Eğitim Parametreleri	
Öğrenme kuralı	Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Toplam karesel hata (sse)	0.000000001

Sınıflandırma süreci için kullanılacak 2000 adet farklı imgeden elde edilmiş Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerlerinden oluşmuş özellik vektörü UATBÇS sınıflandırıcının girişlerine verilmiştir. Sınıflandırma sürecinin amacı, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara minimum hata ile eşlemektir. Sınıflandırıcının başarımında iyi belirlenmiş özellikler kilit rolü oynarlar.

8.4.2.4. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 24'lük özellik vektörü ise sınıflandırma sürecinde eğitilmiş UATBÇS sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen UADD-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.17'de verilmiştir.

Tablo 8.17.UADD-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	192	8	96.00
Trombosit hücreleri (th)	189	11	94.50
Eritrosit hücreleri (eh)	192	8	96.00
Deri hücreleri (dh)	185	15	92.50
Kristal hücreleri (kh)	198	2	99.00
Parazit hücreleri (ph)	189	11	94.50
Bakteri ve mantar hücreleri (bmh)	192	8	96.00
Sperm hücreleri (sh)	190	10	95.00
Yabancı artıklar (ya)	192	8	96.00
Inorganik artıklar (ia)	191	9	95.50
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1910	90	95.50

8.4.3. Uyarlamalı Ayırık Dalgacık Dönüşüm Tabanlı - Destek Vektör Makineleri Yöntemi


Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için Uyarlamalı Ayırık Dalgacık Dönüşüm –Çoklu Destek Vektör Makineleri (UADD-ÇDVM) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir.

Burada kullanılan UADD-ÇDVM algoritması Şekil 8.23’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:

8.4.3.1. Ön İşlem Süreci

Bu çalışmada UADD-ÇDVM yapısı kullanılarak, tanınması istenilen mikroskobik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph),), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)'dır.

Ön işlem aşamasında, Bölüm 4'de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskobik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskobik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskobik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. En son olarak da belirginleştirilen bu idrar tortu imgesindeki hücreler, otomatik pencereleme yöntemi kullanılarak tek tek tespit edilmiştir.




Şekil 8.23. Bu çalışmada kullanılan UADD-ÇDVM sisteminin blok diagramı

Bu aşamalardan ön işlem ve özellik çıkarım süreçleri Bölüm 8.4.1'deki ile aynı olduğu için bu bölümde sadece sistemin özellik çıkarım sürecinden kısaca bahsedilerek, sınıflandırma ve test süreçleri detaylı bir şekilde açıklanacaktır.

8.4.3.2. Özellik Çıkarım Süreci

Bu süreçte ise Bölüm 8.1’de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1’de belirtilen ön işlem ve otomatik pencereleme aşamaları sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20’şer adedi alınmıştır. Böylelikle 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Böylelikle herbir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Bu özellik çıkarım sürecinde yukarıda bahsedilen ön işlemde geçirilmiş ve otomatik pencereleme yöntemi kullanılarak pencerelenmiş herbir idrar hücre imgesine Ayrık Dalgacık Dönüşümü (ADD) yöntemi uygulanarak Bölüm 6’da da belirtildiği gibi 1. seviyede ayrışım sonucu Dikey-Dikey (D-D1) (Yaklaşık), Dikey-Yatay (D-Y1), Yatay-Dikey (Y-D1), Yatay-Yatay (Y-Y1) (Köşegen) olmak üzere 4 alt imge elde edilmiştir. Daha sonra bu dört alt imgenin her biri için sırasıyla Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerleri elde edilerek, $4000 \times 4 \times 6$ boyutlarında özellik vektörü oluşturulmuştur. Bu 4000×24 ’lük özellik vektörünün, herbir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000×24 adedi sınıflandırma sürecinde, geriye kalan diğer 2000×24 adedi ise test sürecinde kullanılmıştır. Şekil 8.22’de bu çalışmada kullanılan UADD-ÇDVM sisteminin özellik çıkarım mekanizması verilmiştir.



Şekil 8.24. Bu çalışmada kullanılan UADD-ÇDVM sisteminin özellik çıkarım mekanizması

8.4.3.3. Sınıflandırma Süreci

Özellik çıkarım sürecinde elde edilen ve sınıflandırma süreci için 2000 adet farklı imgeden elde edilmiş Uyarlamalı Norm Entropi (UNE), Shannon Entropi (SE), Logaritmik Enerji Entropi (LEE), Eşik Entropi (EE), Sure Entropi (SUE) ve Enerji (E) değerlerinden oluşmuş 2000 x 24 boyutundaki özellik vektörü ÇDVM sınıflandırıcısının girişlerine verilmiştir. Burada hesaplanacak norm entropi p parametre değerinin $0 < p \leq 2$ arasında olması gerekmektedir. Bu parametre değeri Şekil 8.23’de de belirtildiği gibi 0.1’lik adımlarla uyarlamalı olarak artırılarak elde edilen uyarlamalı norm entropi değeri özellik vektörü içerisinde sınıflandırma aşamasında kullanılan ÇDVM sınıflandırıcısının girişlerine verilmiştir. Bu parametre uyarlama işlemi ÇDVM sınıflandırıcısının eğitimi sonucunda bulunan hata değerinin arzu edilen hata değerine eşit çıkmasına ya da bu hata değerinin altına inmesine kadar devam ettirilmiştir.

Tablo 8. 18. UADD-ÇDVM sınıflandırma yöntemi için kullanılan ÇDVM modelinin yapısı ve eğitim parametreleri

Kullanılan Çekirdek Fonksiyon Tipi : Radyal Tabanlı Fonksiyon (RTF)
Hata Tolerans Sabiti (C): 10
Çekirdek Fonksiyonu Parametresi (σ): 4

Burada, Bölüm 7’de bahsedilen ÇDVM sınıflandırıcısı kullanılmıştır. Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. HD-ÇDVM sınıflandırma yöntemi için kullanılan eğitim parametreleri ve yapısı Tablo 8.18’de gösterilmiştir. Bunlar, yani kullanılan çekirdek fonksiyon tipi, hata tolerans sabiti ve çekirdek fonksiyon parametresi değerleri bir kaç farklı deneme ile en iyi başarımlar için seçilmiştir. Tablo 8.19’da ise bu yöntem ile elde edilen özellikler ile kullanılan ÇDVM sınıflandırıcısının doğru tanıma başarımları görülmektedir.

8.4.3.4. Test Süreci

Özellik çıkarım sürecinde elde edilmiş diğer 2000 x 24’lük özellik vektörü ise sınıflandırma sürecinde eğitilmiş ÇDVM sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen UADD-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.19’da verilmiştir.

Tablo 8. 19.UADD-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Bu çalışmada kullanılan mikroskobik idrar hücre çeşitleri	Doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Doğru sınıflandırma oranı (%)
Lökosit hücreleri (lh)	193	7	96.00
Trombosit hücreleri (th)	190	10	94.50
Eritrosit hücreleri (eh)	192	8	96.00
Deri hücreleri (dh)	185	15	92.50
Kristal hücreleri (kh)	198	2	99.00
Parazit hücreleri (ph)	190	10	94.50
Bakteri ve mantar hücreleri (bmh)	192	8	96.00
Sperm hücreleri (sh)	190	10	95.00
Yabancı artıklar (ya)	191	9	96.00
Inorganik artıklar (ia)	191	9	95.50
	Toplam doğru sınıflandırılmış mikroskobik idrar hücre sayısı	Toplam yanlış sınıflandırılmış mikroskobik idrar hücre sayısı	Ortalama Tanıma Başarımı (%)
	1912	88	95.60

8.5. İdrar Hücrelerinin Otomatik Tanınması ve Sayımı İçin Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı İstatistiksel Yöntemlerle Güçlendirilmiş Karar Destek Sistemleri


Tezin bu bölümünde, Bölüm 8.1’de bahsedilen elde edilmiş gerçek idrar tortusu imgeleri kullanılarak, İdrar Hücrelerinin Otomatik Tanınması ve Sayımı için Uyarlamalı Ayrık Dalgacık Dönüşüm Tabanlı İstatistiksel Yöntemlerle Güçlendirilmiş (UADD-İstatistiksel) Karar Destek Sistemleri tanıtılacaktır. Bu karar destek sistemlerinin yapısında seçilen en iyi istatistiksel özellikler (uyarlamalı norm entropi, ortalama değer, standart sapma, ters fark momenti, karışıklık değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değeri) kullanılmıştır. UADD-İstatistiksel karar destek

sisteminde kullanılacak en iyi dalgacık dönüşüm filtre türünü belirlemek için, db1 (daubechies1), db2 (daubechies2), db3 (daubechies3), bior1.3 (biorthogonal1.3), bior2.2 (biorthogonal2.2), bior2.4 (biorthogonal2.4), coif1 (coiflets1), coif2 (coiflets2), coif3 (coiflets3), sym2 (symlets2), sym3 (symlets3) ve sym4 (symlets4) olmak toplam 12 farklı dalgacık filtre türünün her biri ile elde edilen doğru hücre tanıma ve sayma performansı karşılaştırılmıştır.

Önerilen bu UADD-İstatistiksel Karar Destek Sistemlerinin etkinliğini göstermek için 3 adet farklı sınıflandırıcı tabanlı model kullanılmıştır. Bu modellerde, örüntü tanımda kilit rolü oynayan özellik çıkarımı, sınıflayıcının başarımına bağlı olarak adaptif bir şekilde ayarlanabilmektedir. Bu adaptif yapı, entropi hesaplama tekniğinin parametrelerine müdahale edilerek sağlanmıştır.

8.5.1. UADD-İstatistiksel - Yapay Sinir Ağları Yöntemi

Bu bölümde, mikroskopik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir. Şekil 8.25’de idrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel karar destek sisteminin algoritmik akış diyagramı verilmiştir.



Şekil 8.25. İdrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel karar destek sisteminin algoritmik akış diyagramı

Burada kullanılan UADD-İstatistiksel-YSA algoritması Şekil 8.25’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. Aşağıda bu süreçler sırasıyla verilmiştir:

8.5.1.1. Ön İşlem Süreci

Bu çalışmada UADD-İstatistiksel-YSA yapısı kullanılarak, tanınması istenilen mikroskobik idrar hücre imgeleri: eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit

hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph),), bakteri ve mantar hücreleri (bmh), sperm hücreleri (sh), yabancı artıklar (ya), inorganik artıklar (ia)'dır.

Ön işlem aşamasında, Bölüm 4'de anlatılan imge işleme teknikleri kullanılmıştır. Bu aşamanın birinci kısmında yukarıda bahsedilen mikroskobik idrar tortu imgelerinin gürültüyü gidermek için Median filtreleme işlemi gerçekleştirilmiştir. Daha sonra gürültüden arındırılmış bu mikroskobik imgelerin parlaklık artırımı gerçekleştirilerek, imgelerdeki nesnelerin arka plandan daha iyi ayırt edilmesi sağlanmıştır. En son işlem olarak parlaklığı artırılmış bu imgeler, geliştirilen otomatik eşikleme yöntemi kullanılarak bölütlenmiştir. Böylece her bir mikroskobik imgedeki idrar hücresi ile arka plan birbirinden ayrılmış ve böylece bütün idrar hücre şekilleri çok belirgin bir halde elde edilmiştir. En son olarakta belirginleştirilen bu idrar tortu imgesindeki hücreler, otomatik pencereleme yöntemi kullanılarak tek tek tespit edilmiştir. Bu aşamalardan ön işlem süreci Bölüm 8.2.1'deki ile aynı olduğu için bu bölümde sadece sistemin özellik çıkarımı ve sınıflandırma süreçleri açıklanacaktır.

8.5.1.2. Özellik Çıkarım Süreci

Özellik çıkarım süreci örüntü tanımanın en önemli kısmı olup, bir anlamda örüntü tanıma sisteminin başarımında anahtar rolü oynar. Örüntü sınıfları arasında ayrımı gerçekleştirmek için örüntü özelliklerinin çıkarılması gerekir. Günümüzde, çok başarılı sonuçlar veren örüntü sınıflandırıcı türleri mevcut olup, sınıflandırıcının da doğrudan başarımını etkileyen özellik çıkarımı üzerine çalışmalar odaklanmıştır.

Bu süreçte ise Bölüm 8.1'de bahsedilen 1800 adet idrar tortu imgesinden Bölüm 8.2.1.1'de belirtilen ön işlem ve otomatik pencereleme aşamaları sonucunda elde edilen tekli idrar hücreleri kullanılmıştır. Yapılan uygulama çalışmalarının hızını ve güvenilirliğini artırmak amacıyla bir önceki aşamada elde edilen bu tekli idrar hücrelerinin herbirinden rastgele seçilen 20'ser adedi alınmıştır. Böylelikle 10 farklı idrar hücre tipinden toplam $10 \times 20 = 200$ adet hücre elde edilmiştir. Daha sonra bu elde edilen 200 adet hücrenin her biri 0° ile 160° arasında 40 derecelik açılarla döndürülerek, aynı idrar hücresinin birbirinden farklı 4 adet imgesi elde edilmiştir. Ayrıca elde edilen her bir imge 5 farklı büyüklükte ölçeklendirilmiştir. Buna göre her bir idrar hücresi türü için farklı açı ve ölçekte $4 \times 5 \times 20 = 400$ adet imge elde edilmiştir. Böylelikle herbir idrar hücre çeşidi için elde edilen 400 adet farklı imge olmak üzere toplam $400 \times 10 = 4000$ adet imge kullanılmıştır. Bu 4000 adet imgenin, herbir idrar

hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 adedi ise test sürecinde kullanılmıştır.

Özellik çıkarım sürecinde, UADD-İstatiksel karar destek sisteminde kullanılacak en iyi dalgacık dönüşüm filtre türünü belirlemek için, db1 (daubechies1), db2 (daubechies2), db3 (daubechies3), bior1.3 (biorthogonal1.3), bior2.2 (biorthogonal2.2), bior2.4 (biorthogonal2.4), coif1 (coiflets1), coif2 (coiflets2), coif3 (coiflets3), sym2 (symlets2), sym3 (symlets3) ve sym4 (symlets4) ayrık dalgacık filtre tipi ayrı ayrı kullanılarak toplam 12 farklı özellik çıkarım yöntemi elde edilmiştir. Bu özellik çıkarım yöntemleri aşağıda verilmiştir:

- **Özellik Çıkarım Yöntemi-1 (ÖÇ-1)** : Bu özellik çıkarım yönteminde db1 (daubechies1) ayrık dalgacık dönüşüm filtresi kullanılarak, uyarlamalı norm entropi, ortalama değer, standart sapma, ters fark momenti, karışıklık değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değerleri hesaplanarak özellik vektörü oluşturulmuştur.
- **Özellik Çıkarım Yöntemi-2 (ÖÇ-2)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak db2 (daubechies2) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-3 (ÖÇ-3)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak db3 (daubechies3) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-4 (ÖÇ-4)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak bior1.3 (biorthogonal1.3) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-5 (ÖÇ-5)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak bior2.2 (biorthogonal2.2) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-6 (ÖÇ-6)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak bior2.4 (biorthogonal2.4) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-7 (ÖÇ-7)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak coif1 (coiflets1) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.

- **Özellik Çıkarım Yöntemi-8 (ÖÇ-8)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak coif2 (coiflets2) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-9 (ÖÇ-9)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak coif3 (coiflets3) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-10 (ÖÇ-10)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak sym2 (symlets2) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-11 (ÖÇ-11)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak sym3 (symlets3) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.
- **Özellik Çıkarım Yöntemi-12 (ÖÇ-12)** : Bu özellik çıkarım yönteminde ayrık dalgacık dönüşüm filtresi olarak sym4 (symlets4) kullanılarak ÖÇ-1'deki ile aynı tür özellikler elde edilmiştir.

Bu özellik çıkarım sürecinde yukarıda bahsedilen özellik çıkarım yöntemlerinin herbiri için ön işlem den geçirilmiş ve otomatik pencereleme yöntemi kullanılarak pencerelenmiş her bir idrar hücre imgesinden ilgili ayrık dalgacık dönüşüm filtre türü kullanılarak Bölüm 6'da da belirtildiği gibi 1. seviyede ayrışım sonucu Dikey-Dikey (D-D1) (Yaklaşık), Dikey-Yatay (D-Y1), Yatay-Dikey (Y-D1), Yatay-Yatay (Y-Y1) (Köşegen) olmak üzere 4 alt imge elde edilmiştir. Daha sonra bu dört alt imgenin her biri için sırasıyla uyarlamalı norm entropi, ortalama değer, standart sapma, ters fark momenti, karşılıklı değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değerleri elde edilerek, 4000 x 4 x 10 boyutlarında özellik vektörü oluşturulmuştur. Bu 4000 x 40'lık özellik vektörünün, her bir idrar hücre imgesinden eşit sayıda alınmak üzere rastgele seçilmiş 2000 x 40 adedi sınıflandırma sürecinde, geriye kalan diğer 2000 x 40 adedi ise test sürecinde kullanılmıştır. Özellik çıkarım sürecindeki bu işlemler yukarıda verilen her bir özellik çıkarım yöntemi için tekrarlanmıştır.

8.5.1.3. Sınıflandırma Süreci


Özellik çıkarım sürecinde elde edilen özellik çıkarım yöntemlerinin herbiri için sınıflandırma süreci için kullanılacak 2000×40 boyutundaki özellik vektörü YSA sınıflandırıcısının girişlerine verilmiştir. Burada hesaplanacak norm entropi p parametre değerinin $0 < p \leq 2$ arasında olması gerekmektedir. Bu parametre değeri Şekil 8.25’de de belirtildiği gibi 0.1’lik adımlarla uyarlamalı olarak artırılarak elde edilen uyarlamalı norm entropi değeri özellik vektörü içerisinde sınıflandırma aşamasında kullanılan YSA sınıflandırıcısının girişlerine verilmiştir. Bu parametre uyarlama işlemi YSA sınıflandırıcısının eğitimi sonucunda bulunan hata değerinin arzu edilen hata değerine eşit çıkmasına ya da bu hata değerinin altına inmesine kadar devam ettirilmiştir. Sınıflandırma sürecindeki bu işlemler yukarıda verilen herbir özellik çıkarım yöntemi için tekrarlanmıştır.

Burada, Ayırık dalgacık Dönüşümünün (ADD) kullanılması ile tekli idrar hücrelerinin herbiri için bulunan uyarlamalı norm entropi, ortalama değer, standart sapma, ters fark momenti, karşıtlık değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değerleri ile üst üste binmiş idrar hücreleri için bulunan uyarlamalı norm entropi, ortalama değer, standart sapma, ters fark momenti, karşıtlık değeri, enerji değeri, yerel homojenlik değeri, küme gölge değeri, küme önem değeri, maksimum olasılık değerleri birbirlerinden çok farklı çıkmaktadır. Bu da, YSA sınıflandırıcısının girişlerine verilen özelliklerin çok etkili olmasını ve dolayısıyla bu yöntemin idrar imgelerindeki hücrelerin doğru sınıflandırılması ve tanınması başarımının artmasını sağlamıştır.

Uygulama için, MATLAB ortamında programlar gerçekleştirilmiştir. UADD-İstatistiksel-YSA sınıflandırma yöntemi için kullanılan ileri beslemeli çok katmanlı YSA’nın eğitim parametreleri ve yapısı Tablo 8.20’de gösterilmiştir. Burada belirtilen gizli katman nöron sayısı, momentum ve öğrenme oranlarının değerleri ve etkinleştirme fonksiyonlarının türleri gibi eğitim parametreleri bir kaç farklı deneme ile en iyi başarımlar için seçilmiştir. Şekil 8.26’da ise bu yöntem ile elde edilen özellikler ile kullanılan YSA’nın eğitim başarımları görülmektedir.

Tablo 8. 20. UADD-İstatistiksel-YSA sınıflandırma yöntemi için kullanılan YSA modelinin yapısı ve eğitim parametreleri

YSA yapısı	
YSA modeli	Çok katmanlı ileri beslemeli
Katman sayısı	3
Katmanlardaki nöron sayısı	Giriş : 40 Gizli : 50 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metoduna göre hesaplandı
Etkinleştirme fonksiyonları	Logaritmik sigmoid
YSA eğitim parametreleri	
Öğrenme kuralı	Hata geri yayılım
Toplam karesel hata	0.0000001



Şekil 8.26. UADD-İstatistiksel-YSA sınıflandırma yöntemi için kullanılan YSA modelinin eğitim başarımları

8.5.1.4. Test Süreci

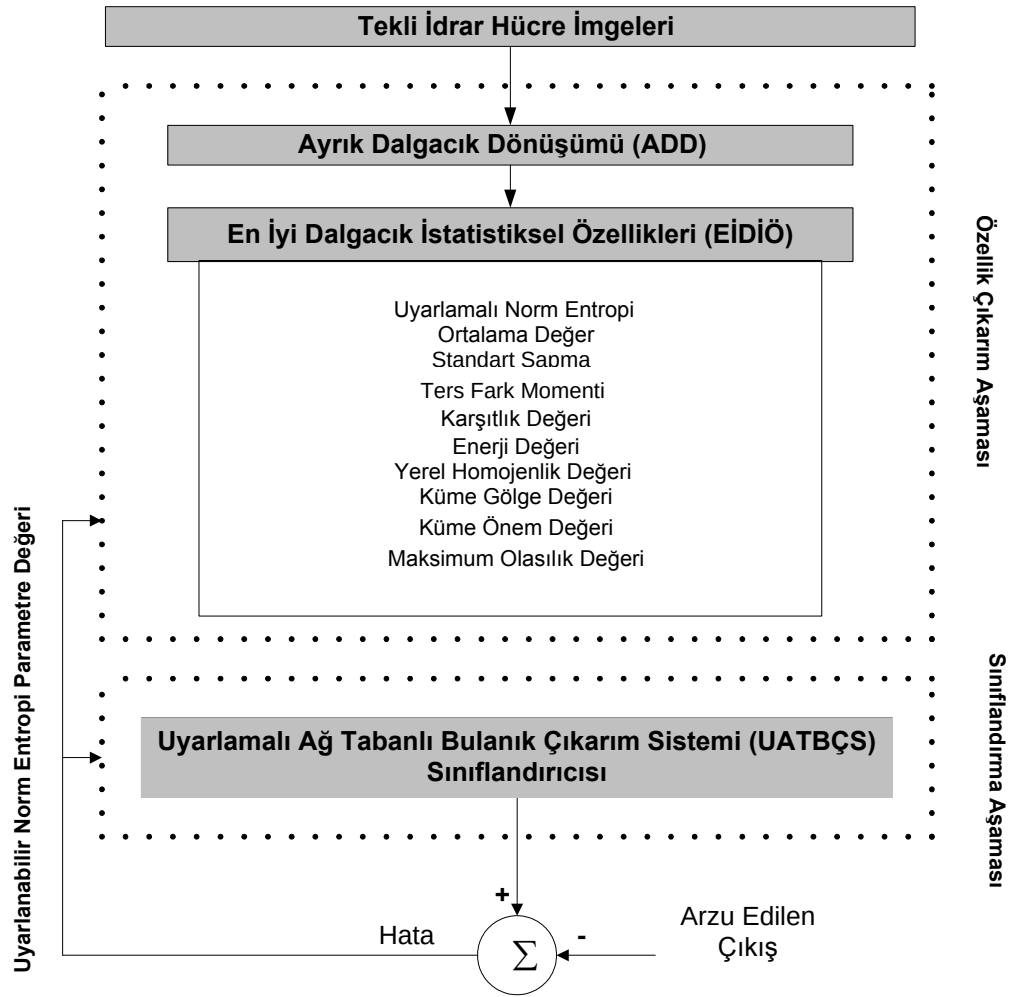
Test sürecinde, özellik çıkarım sürecinde belirtilen toplam 12 farklı özellik çıkarım yönteminin her biri için elde edilen doğru hücre tanıma ve sayma performansı karşılaştırımı yapılmıştır. Bu amaçla birbirinden farklı ayırık dalgacık dönüşüm filtre türleri kullanılan 12 adet özellik çıkarım yönteminin herbiri için elde edilmiş 2000 x 40'lık özellik vektörleri sırasıyla sınıflandırma sürecinde eğitilmiş YSA sınıflandırıcısının girişlerine verilerek test işlemi gerçekleştirilmiştir. Bu test işlemi sonucunda elde edilen UADD-İstatistiksel-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları Tablo 8.21'de verilmiştir.

Tablo 8. 21. UADD-İstatistiksel-YSA sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları.

Hücre Sırası	Hücre Türü	Doğru Tanıma ve Sayma Oranı (%)											
		Özellik Çıkarım Yöntemleri											
		ÖÇ-1	ÖÇ-2	ÖÇ-3	ÖÇ-4	ÖÇ-5	ÖÇ-6	ÖÇ-7	ÖÇ-8	ÖÇ-9	ÖÇ-10	ÖÇ-11	ÖÇ-12
1	eh	97.50	93.50	96.00	97.50	97.50	99.00	96.50	95.00	97.00	96.50	99.00	97.00
2	lh	98.50	96.00	96.50	95.00	98.00	96.50	97.50	99.00	99.50	99.00	97.00	99.50
3	th	96.00	99.50	96.50	96.00	99.50	93.50	98.50	98.50	97.00	97.00	100	99.50
4	dh	100	97.50	99.50	97.50	99.00	98.50	99.00	96.50	98.00	99.00	97.50	98.50
5	kh	97.50	100	99.50	99.00	96.50	97.50	96.50	98.50	90.00	97.50	99.50	96.50
6	ph	97.00	98.00	99.00	99.00	93.50	97.50	96.50	98.50	90.00	97.50	99.50	96.50
7	bmh	99.50	93.50	98.50	96.50	98.50	98.50	98.50	96.50	96.00	100	99.00	95.00
8	sh	98.00	95.50	97.00	96.50	98.00	95.50	98.00	99.00	99.00	100	97.00	96.50
9	ya	96.50	100	94.50	98.00	97.50	98.00	99.50	97.50	97.00	96.50	98.00	98.50
10	ia	94.50	100	98.50	99.50	99.00	95.50	96.50	98.00	93.50	97.50	96.50	98.00
Ortalama Tanıma Başarımı (%)		97.50	97.35	97.55	97.45	97.70	97.00	97.70	97.70	95,70	98.05	98.30	97.55

8.5.2. UADD-İstatistiksel - Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemleri (UADD-İstatistiksel-UATBÇS) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir. Aşağıda Şekil 8.27’de idrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel-UATBÇS karar destek sisteminin algoritmik akış diyagramı verilmiştir.



Şekil 8.27. İdrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel-UATBÇS karar destek sisteminin algoritmik akış diyagramı

Burada kullanılan UADD-İstatistiksel-UATBÇS algoritması Şekil 8.27’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. UADD-İstatistiksel-UATBÇS karar destek sisteminin ön işlem,

özellik çıkarımı, sınıflandırma ve test süreçlerinde yapılan işlemler bir önceki UADD-İstatistiksel-YSA karar destek sistemindeki süreçlerle aynıdır. Bundan dolayı bu bölümde sırasıyla Tablo 8.22’de kullanılan olan UATBÇS sınıflandırıcısının eğitim parametreleri ve Tablo 8.23’de ise test işlemi sonucunda elde edilen UADD-İstatistiksel-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları verilmiştir. Burada kullanılan giriş üyelik fonksiyon tipi, her bir giriş için giriş üyelik fonksiyonu sayısı ve öğrenme oranı gibi eğitim parametreleri, en iyi başarımlar için birkaç farklı deneme ile seçilmiştir.

Tablo 8. 22. UADD-İstatistiksel-UATBÇS sınıflandırma yöntemi için kullanılan UATBÇS modelinin yapısı ve eğitim parametreleri


UATBÇS Modelinin Yapısı	
Katman sayısı	5
Katmanlardaki nöron sayısı	Giriş : 40 Çıkış : 1
Başlangıç ağırlıkları ve eşik değerleri	Nguyen-Widrow metodu ile hesaplandı
Eğitim Parametreleri	
Öğrenme kuralı	Melez Öğrenme Algoritması (Doğrusal olmayan giriş parametreleri için Geri yayılım ve doğrusal çıkış parametreleri için En küçük kareler yöntemlerinin birleşimleri)
Toplam karesel hata (sse)	0.000000001

Tablo 8. 23.UADD-İstatistiksel-UATBÇS sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Hücre Sırası	Hücre Türü	Doğru Tanıma ve Sayma Oranı (%)											
		Özellik Çıkarım Yöntemleri											
		ÖÇ-1	ÖÇ-2	ÖÇ-3	ÖÇ-4	ÖÇ-5	ÖÇ-6	ÖÇ-7	ÖÇ-8	ÖÇ-9	ÖÇ-10	ÖÇ-11	ÖÇ-12
1	eh	100	94.00	96.00	97.50	97.50	99.00	96.50	95.00	97.00	96.50	99.00	97.00
2	lh	98.00	96.50	96.50	95.00	98.00	96.50	97.50	99.00	99.50	99.00	97.00	99.50
3	th	99.00	99.00	96.00	96.00	99.50	93.50	98.50	98.50	97.00	97.00	100	99.50
4	dh	100	97.00	99.50	97.00	99.00	98.50	99.00	96.50	98.00	99.00	97.50	98.50
5	kh	97.50	100	99.00	99.00	96.50	97.50	96.50	98.50	90.00	97.50	99.50	96.50
6	ph	97.50	98.00	99.00	99.00	93.50	97.50	96.50	98.50	90.50	97.50	99.50	96.50
7	bmh	99.50	93.00	98.50	96.50	98.50	98.50	98.50	96.50	96.00	100	99.00	95.00
8	sh	98.50	95.00	97.00	96.50	98.00	95.50	98.00	99.00	99.00	100	97.00	96.50
9	Ya	96.00	100	94.00	98.00	97.50	98.00	99.50	97.50	97.50	96.50	98.00	98.50
10	İa	98.00	100	98.00	99.50	99.00	95.50	96.50	98.00	93.50	97.50	96.50	98.00
Ortalama Tanıma Başarımı (%)		98.40	97.25	97.35	97.40	97.70	97.00	97.70	97.70	98.15	98.05	98.30	97.55

8.5.3. UADD-İstatistiksel - Çoklu Destek Vektör Makineleri Yöntemi

Bu bölümde, mikroskobik idrar tortusundaki hücrelerin otomatik sınıflandırılması ve sayılması için UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM) tabanlı akıllı bir sınıflama uygulaması anlatılarak sonuçları irdelenmiştir. Aşağıda Şekil 8.28’de idrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel-ÇDVM karar destek sisteminin algoritmik akış diyagramı verilmiştir.



Şekil 8. 28. İdrar hücrelerinin otomatik tanınması ve sayımı için UADD-İstatistiksel-ÇDVM karar destek sisteminin algoritmik akış diyagramı

Burada kullanılan UADD-İstatistiksel-ÇDVM algoritması Şekil 8.28’den de görüldüğü gibi temel olarak ön işlem, özellik çıkarım, sınıflama ve test süreçleri olmak üzere dört kısımdan meydana gelmiştir. UADD-İstatistiksel-ÇDVM karar destek sisteminin ön işlem, özellik çıkarımı, sınıflandırma ve test süreçlerinde yapılan işlemler bir önceki UADD-İstatistiksel-YSA karar destek sistemindeki süreçlerle aynıdır. Bundan dolayı bu bölümde sırasıyla Tablo 8.24’de kullanılan olan ÇDVM sınıflandırıcısının eğitim parametreleri ve Tablo 8.25’de ise

test işlemi sonucunda elde edilen UADD-İstatistiksel-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları verilmiştir.

Tablo 8. 24. UADD-İstatistiksel-ÇDVM sınıflandırma yöntemi için kullanılan ÇDVM modelinin yapısı ve eğitim parametreleri

Kullanılan Çekirdek Fonksiyon Tipi : Radyal Tabanlı Fonksiyon (RTF)
Hata Tolerans Sabiti (C): 100
Çekirdek Fonksiyonu Parametresi (σ): 4

Tablo 8. 25.UADD-İstatistiksel-ÇDVM sisteminin mikroskobik idrar hücre çeşitlerini doğru tanıma başarımları

Hücre Sırası	Hücre Türü	Doğru Tanıma ve Sayma Oranı (%)											
		Özellik Çıkarım Yöntemleri											
		ÖÇ-1	ÖÇ-2	ÖÇ-3	ÖÇ-4	ÖÇ-5	ÖÇ-6	ÖÇ-7	ÖÇ-8	ÖÇ-9	ÖÇ-10	ÖÇ-11	ÖÇ-12
1	Eh	96.50	99.00	98.00	99.00	97.50	99.00	98.50	95.00	97.00	96.50	99.00	98.50
2	Lh	98.00	100	96.50	95.00	100	96.50	98.50	99.00	100	99.00	97.00	99.50
3	Th	99.00	99.00	99.00	96.00	99.50	96.50	98.50	98.50	98.00	97.00	100	99.50
4	Dh	100	97.00	99.50	97.00	99.00	100	99.00	96.50	100	100	98.00	98.50
5	Kh	97.50	100	100	99.00	96.50	97.50	96.50	98.50	90.00	98.50	99.50	98.50
6	Ph	97.50	99.00	99.00	99.00	93.50	100	96.50	98.50	98.50	97.50	99.50	98.00
7	bmh	100	97.50	98.50	97.50	98.50	98.50	98.50	100	100	100	99.00	95.00
8	Sh	98.50	95.00	97.00	96.50	100	95.50	98.00	99.00	99.00	100	97.00	99.00
9	Ya	96.00	100	96.50	98.00	98.50	98.00	99.50	98.50	98.50	98.50	98.00	98.50
10	İa	98.00	100	98.00	99.50	99.00	95.50	98.50	98.00	93.50	97.50	96.50	98.00
Ortalama Tanıma Başarımları (%)		98.10	98.65	98.20	97.65	98.20	97.70	98.20	98.15	97.45	98.45	98.35	98.30

Aşağıda Tablo 8.26’da ise bu tez çalışmasında mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için uyarlanan toplam 45 adet karar destek sisteminden en yüksek ortalama tanıma ve sayma başarımına sahip ilk 10 karar destek sistemi verilmiştir.

Tablo 8. 26. En yüksek ortalama tanıma ve sayma başarımına sahip ilk 10 karar destek sistemi ve doğru tanıma başarımları

Karar Destek Sistemlerinin Sırası	Karar Destek Sistemi	Ortalama Tanıma Başarımı (%)
1	ÖÇ-2 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.65
2	ÖÇ-10 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.45
3	ÖÇ-1 Kullanılarak Uyarlanan UADD-İstatistiksel-UATBÇS	98.40
4	ÖÇ-11 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.35
5	ÖÇ-11 Kullanılarak Uyarlanan UADD-İstatistiksel-YSA	98.30
6	ÖÇ-11 Kullanılarak Uyarlanan UADD-İstatistiksel-UATBÇS	98.30
7	ÖÇ-12 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.30
8	ÖÇ-3 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.20
9	ÖÇ-5 Kullanılarak Uyarlanan UADD-İstatistiksel-ÇDVM	98.20
10	ÖÇ-9 Kullanılarak Uyarlanan UADD-İstatistiksel-UATBÇS	98.15

8.6. Elde Edilen Mikroskobik İdrar Tortusu İmgelerine SBE Tabanlı Steganografi Yönteminin Uygulanması

Bu bölümde, Bölüm 8.1’de nasıl elde edildiği açıklanan mikroskobik idrar tortusu imgelerine, tezin 5. Bölümü’nde anlatılan temel steganografi tekniklerinden Son Bite Ekleme (SBE) yöntemi uygulanarak, Türkiye’nin neresine gidilirse gidilsin kime ait olduğu belli olan, hiçbir şekilde kayıp olmayacak, daha güvenli imgeler haline getirilmesi amaçlanmaktadır. Burada elde edilen idrar tortusu imgelerine Son Bite Ekleme (SBE) steganografik güvenlik yöntemi kullanılarak idrar tortusu imgelerinin her biri için ait olduğu hastanın “Adı ve Soyadı”, “ Türkiye Cumhuriyeti (T.C.) Vatandaşlık Numarası”, “Yaşı” ve “Cinsiyeti” gibi kişisel bilgilerinin sayısal imgenin içine gizlenmesi işlemi gerçekleştirilmiştir.

Tepe İşaret Gürültü Oranı (PSNR), herhangi bir işaret ya da imgenin bozulma gürültüsüne olan oranıdır. PSNR oranının yüksek çıkması işaret ya da imgenin bozulma gürültüsüne oranla daha güçlü olduğunu ifade etmektedir. Bu oran aynı zamanda bir mühendislik terimidir [102-104]. İşaretler ya da imgeler, çok geniş bir dinamik aralıkta olduğu için, genellikle PSNR, logaritmik ölçek desibel olarak ifade edilir. Aşağıda Denklem 8.1’de PSNR oranının hesaplanması verilmiştir.

$$OKH = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i, j) - N(i, j)]^2 \quad (8.1)$$

$$PSNR = 10 \cdot \log_{10} \frac{MAX_I^2}{OKH} \quad (8.2)$$

$$= 20 \cdot \log_{10} \frac{MAX_I}{\sqrt{OKH}} \quad (8.3)$$

$$= 20 \cdot \log_{10} MAX_I - 10 \cdot \log_{10} OKH \quad (8.4)$$

Burada, OKH, orijinal sayısal imge ile veri gizlenmiş sayısal imge arasındaki her bir piksel arasındaki ortalama karesel hata ve MAX_I sayısal imgenin mümkün olan en yüksek piksel değeridir.

Bu tez çalışmasında da, orijinal mikroskobik idrar tortusu imgesi ile SBE steganografi yöntemi uygulanarak içine veri gizlenmiş mikroskobik idrar tortusu imgesi arasındaki piksel farkı ve bozulma oranı PSNR oranı hesaplanarak bulunmuştur. Bu PSNR değerinin 40 veya daha yüksek değerler çıkması, orijinal sayısal imgenin piksel değerleri ile veri gizlenmiş

sayısal imgenin piksel değerleri arasındaki farkın çok az olduğunu göstermektedir. Aşağıda Şekil 8.29’da (a) Orijinal mikroskobik idrar tortusu imgesi, (b) SBE stegonografi yöntemi kullanılarak elde edilmiş sayısal imge, elde edilen OKH ve PSNR değerleri verilmiştir.



(a)



(b)

OKH Değeri: 2.723

PSNR Değeri: 43.756

Şekil 8. 29. (a) Orijinal mikroskobik idrar tortusu imgesi, (b) SBE stegonografi yöntemi kullanılarak elde edilmiş sayısal imge

Bu örnek uygulamada SBE stegonografi yöntemi kullanılarak sayısal imgenin içine gizlenen veri: “Derya AVCI”, “25456927268”, “32”, “Bayan” şeklindedir. Yukarıda Şekil 8.2’de gösterilen steganografi uygulamasında elde edilen 43.756’lık PSNR değeri bu yöntemin mikroskobik idrar tortu imgeleri için uygun olduğunu göstermektedir.

Elde edilen her bir mikroskobik tortu imgesine yukarıdaki gibi SBE stegonografi yöntemi kullanılarak hastaya ait “Adı ve Soyadı”, “ Türkiye Cumhuriyeti (T.C.) Vatandaşlık Numarası”, “Yaşı” ve “Cinsiyeti” bilgileri gizlenmiştir. Bu gizlenen veriler, bitler şeklinde imgenin 8 bitlik en dış kenar piksellerinin son bitine eklendiği için bu piksel değerlerinde çok fazla bir değişikliğe neden olmayacaktır. Bu durumda orjinal mikroskobik idrar tortusu imgesi piksellleri ile veri gizlenmiş mikroskobik idrar tortusu imgesi pikselleri arasındaki PSNR oranı genellikle 40 ve üzeri çıkmaktadır. Elde edilen veri gizlenmiş her bir mikroskobik idrar tortusu imgesi bundan sonraki aşamada uyarlanan karar destek sistemlerinde kullanılmıştır.

9. SONUÇ VE DEĞERLENDİRME

Bu tez çalışmasında, mikroskopik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için stagnografik yöntemlerle güvenli hale getirilmiş, birbirinden farklı yöntemleri kullanan karar destek sistemleri uyarlanmış ve bu uyarlanan karar destek sistemlerinin uygulamaları sonucunda elde edilen sonuçlar irdelenmiştir.

Bu tez çalışmasında, çoklu idrar hücrelerinin bulunduğu idrar tortusu imgelerinden eritrosit hücreleri (eh), lökosit hücreleri (lh), trombosit hücreleri (th), deri hücreleri (dh), kristal hücreleri (kh), parazit hücreleri (ph), bakteri hücreleri (bh), mantar hücreleri (mh), yabancı artıklar (ya), inorganik artıklar (ia) olmak üzere 10 farklı idrar hücresinin otomatik tanınması ve sayılması amacıyla uyarlanmış karar destek sistemleri aşağıda sıralanmıştır:

1. Değişmez Moment – Yapay Sinir Ağları (DM-YSA),
2. Değişmez Moment – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (DM-UATBÇS),
3. Değişmez Moment – Çoklu Destek Vektör Makineleri (DM-ÇDVM),
4. Hough Dönüşümü – Yapay Sinir Ağları (HD-YSA),
5. Hough Dönüşümü– Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (HD-UATBÇS),
6. Hough Dönüşümü – Çoklu Destek Vektör Makineleri (HD-ÇDVM),
7. Uyarlamalı Ayrık Dalgacık Dönüşüm – Yapay Sinir Ağları (UADD-YSA),
8. Uyarlamalı Ayrık Dalgacık Dönüşüm – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-UATBÇS),
9. Uyarlamalı Ayrık Dalgacık Dönüşüm – Çoklu Destek Vektör Makineleri (UADD-ÇDVM),
10. Özellik Çıkarım Yöntemi-1 (ÖÇ-1) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
11. Özellik Çıkarım Yöntemi-2 (ÖÇ-2) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
12. Özellik Çıkarım Yöntemi-3 (ÖÇ-3) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
13. Özellik Çıkarım Yöntemi-4 (ÖÇ-4) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),

14. Özellik Çıkarım Yöntemi-5 (ÖÇ-5) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
15. Özellik Çıkarım Yöntemi-6 (ÖÇ-6) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
16. Özellik Çıkarım Yöntemi-7 (ÖÇ-7) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
17. Özellik Çıkarım Yöntemi-8 (ÖÇ-8) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
18. Özellik Çıkarım Yöntemi-9 (ÖÇ-9) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
19. Özellik Çıkarım Yöntemi-10 (ÖÇ-10) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
20. Özellik Çıkarım Yöntemi-11 (ÖÇ-11) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
21. Özellik Çıkarım Yöntemi-12 (ÖÇ-12) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Yapay Sinir Ağları (UADD-İstatistiksel-YSA),
22. Özellik Çıkarım Yöntemi-1 (ÖÇ-1) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
23. Özellik Çıkarım Yöntemi-2 (ÖÇ-2) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
24. Özellik Çıkarım Yöntemi-3 (ÖÇ-3) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
25. Özellik Çıkarım Yöntemi-4 (ÖÇ-4) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
26. Özellik Çıkarım Yöntemi-5 (ÖÇ-5) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
27. Özellik Çıkarım Yöntemi-6 (ÖÇ-6) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
28. Özellik Çıkarım Yöntemi-7 (ÖÇ-7) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
29. Özellik Çıkarım Yöntemi-8 (ÖÇ-8) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),

30. Özellik Çıkarım Yöntemi-9 (ÖÇ-9) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
31. Özellik Çıkarım Yöntemi-10 (ÖÇ-10) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
32. Özellik Çıkarım Yöntemi-11 (ÖÇ-11) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
33. Özellik Çıkarım Yöntemi-12 (ÖÇ-12) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (UADD-İstatistiksel-UATBÇS),
34. Özellik Çıkarım Yöntemi-1 (ÖÇ-1) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
35. Özellik Çıkarım Yöntemi-2 (ÖÇ-2) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
36. Özellik Çıkarım Yöntemi-3 (ÖÇ-3) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
37. Özellik Çıkarım Yöntemi-4 (ÖÇ-4) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
38. Özellik Çıkarım Yöntemi-5 (ÖÇ-5) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
39. Özellik Çıkarım Yöntemi-6 (ÖÇ-6) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
40. Özellik Çıkarım Yöntemi-7 (ÖÇ-7) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
41. Özellik Çıkarım Yöntemi-8 (ÖÇ-8) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
42. Özellik Çıkarım Yöntemi-9 (ÖÇ-9) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
43. Özellik Çıkarım Yöntemi-10 (ÖÇ-10) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),
44. Özellik Çıkarım Yöntemi-11 (ÖÇ-11) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM),

45. Özellik Çıkarım Yöntemi-12 (ÖÇ-12) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM)'dir.

Böylelikle, toplam 45 adet farklı karar destek sistemi uyarlanmış ve son olarak ta bu uyarlanan karar destek sistemlerine steganografik güvenlik yöntemlerinin uygulanması işlemleri gerçekleştirilmiştir.

Literatürde daha önceden bu alanda yapılmış çalışmalara ve bu tez çalışmasında uyarlanan karar destek sistemlerinin uygulama sonuçlarına göre idrar hücre imgelerinin otomatik tanınması ve sayılması alanında, birçok önemli sorun tespit edilmiştir. Bu sorunlardan başlıcaları aşağıda sıralanmıştır:

- Mikroskobik idrar tortusu imgeleri elde edilirken ortamın ışık ayarlarının ve mikroskobun odaklama ayarının iyi bir şekilde yapılması zorunluluğu vardır. Eğer bu ayarlar gerektiği gibi yapılamazsa elde edilen imgeler tam olarak mikroskobik idrar tortusunu temsil edemeyebilir.
- Mikroskobik idrar tortusu imgeleri sayısal imge işleme yöntemleri ile işlenirken kullanılacak morfolojik teknikler örneğin median filtreleme, otomatik eşikleme, otomatik pencereleme v.b. uygun yöntemler olarak seçilmez iseler istenilen yüksek doğru tanıma ve sayma başarımları elde edilemeyecektir.
- Elde edilen mikroskobik idrar tortusu imgelerinde idrar hücreleri genellikle toplu halde karışık bir şekilde bulunmaktadır, ayrıca bu hücrelerin bazılarının birbirine yapışık ya da üst üste binmiş durumda olabilmesi, bu hücrelerin kolaylıkla birbirinden ayırt edilebilmelerini güçleştirmektedir. Bundan dolayı mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için uyarlanan karar destek sistemlerinde güçlü, etkin, kompleks ve gürültülere ve bozucu girişlere karşı dayanıklı özellik çıkarım yöntemlerinin kullanımı büyük önem taşımaktadır.
- Mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için uyarlanan karar destek sistemlerinin sınıflandırma aşamasında kullanılan karar verici sınıflandırıcıların doğru sınıflandırma etkinliği ve yetenekleri elde edilen sınıflandırma sonuçlarının hızlılığı ve güvenilirliğini çok büyük oranda etkilemektedir. Bundan dolayı, uyarlanacak karar destek sistemlerine uygun,

genelleme yeteneđi üst düzeyde olan, hızlı ve güvenilir sınıflandırıcıların seçilmesi gerekmektedir.

9.1. Sonuçların Deđerlendirilmesi

Mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması alanında karşılaşılan bu temel sorunların çözümünü gerçekleştirmek için bu tez çalışmasında uyarlanmış toplam 45 adet karar destek sisteminin elde edilen mikroskobik idrar tortusu imgelerine uygulanması işlemleri sonucunda Tablo 8.27'deki doğru tanıma ve sayma performans sıralaması elde edilmiştir. Bu sonuçlara göre yukarıda sayılan 45 farklı karar destek sistemi içerisinde en yüksek doğru tanıma ve sayma performansına, Özellik Çıkarım Yöntemi-2 (ÖÇ-2) Kullanılarak Gerçekleştirilen UADD-İstatistiksel – Çoklu Destek Vektör Makineleri (UADD-İstatistiksel-ÇDVM) karar destek sisteminin %98.65'lik doğru tanıma ve sayma oranıyla ulaşılmıştır. Bu karar destek sistemi yapısında ayrık dalgacık filtresi olarak, db2 kullanılmıştır. Bu UADD-İstatistiksel-ÇDVM karar destek sisteminin diđer kullanılan karar destek sistemlerine göre doğru tanıma ve sayma performansının yüksek çıkmasının temel nedenleri aşağıda sıralanmıştır:

- Bu tez çalışmasında geliştirilmiş ve literatürde ilk defa kullanılan histogram şekline dayalı bir otomatik eşikleme tekniđi ile mikroskobik sayısal idrar tortusu imgelerindeki hücrelerin bölütlenme işleminin yüksek hızda ve doğru oranda yapılması,
- Bu sistemde kullanılan ve üst üste binen hücre imgelerinin bile birbirinden kolayca ayırt edilip, tanınmasını sağlayan ayrık dalgacık dönüşüm uyarlamalı entropi ve enerji tekniđinin yanı sıra sistemde ilave olarak ortalama deđer, standart sapma, ters fark momenti, karşıtlık deđer, enerji deđer, yerel homojenlik deđer, küme gölge deđer, küme önem deđer, maksimum olasılık deđer gibi istatistiksel özelliklerinde kullanılması,
- Sınıflandırıcı olarak YSA ve UATBÇS sınıflandırıcılarından daha iyi sonuçlar veren ÇDVM sınıflandırıcısının kullanılmasıdır.

Uyarlanan özellik çıkarım algoritmaların da, doğrudan zaman veya frekans bölgesinin her bir noktasının büyüklüğünü özellik uzayı olarak tanımlamak yerine, daha ayrıntılı ve tutarlı özellikler elde etmek için, dalgacık ayrışımı ile sayısal imgeye birden çok perspektiften

bakılarak elde edilen her bir sayısal imge bileşeninin entropi değerleri hesaplanmıştır. Böylece sayısal imgenin özellik uzayı, imgenin farklı bakış açılarından çıkarılan her bir bileşeninin sahip olduğu entropi ve enerji değerlerinin oluşturduğu küme ile tanımlanmıştır. Bu durum, doğrudan zaman veya frekans bölgesinden elde edilen özellikler uzayına göre boyut olarak daha azdır. Örneğin; ayrık dalgacık dönüşüm tekniği kullanılarak, uyarlanan yöntemde bir sayısal imgeye ait 4 alt imgenin her birinden uzun ve iki boyutlu dalgacık katsayıları elde edilmektedir. Ancak bu uzun ve iki boyutlu veri kümesinin her birinin entropi ve enerji değerleri hesaplanarak, daha az boyutlu ve tanıma başarımı yüksek özellik uzayları elde edilmiştir. Bu ise, özellik çıkarma algoritmasının sağlam temellere dayalı olduğunu göstermektedir.

Ayrıca özellik uzayının boyut olarak küçük olması, sınıflayıcının karmaşıklığını (YSA’da daha az nöron ve ara katman, UATBÇS’de daha az kural ve ÇDVM’de ise daha az giriş parametresi kullanılmasını sağlar) önlediği için gerçek zaman uygulamalarına daha uygun hale getirmekte ve tasarımını kolaylaştırmaktadır.

Ayrıca YSA, UATBÇS ve ÇDVM sınıflayıcılarının yapısı küçük çapta olduğu için, nöronlar arası bağlantılar üzerinde bulunan ağırlıklar ile nitelendirilen bellek yapısı da küçük çapta olmakla birlikte bu yüksek başarıyı sağlaması, daha az hafıza boyutuna daha çok bilgiyi depolamanın önemi günümüzde aşıkardır. Buna mukabil, özellik çıkarım sürecindeki karmaşıklık, günümüz bilgisayar teknolojisinin ulaştığı nokta ve sayısal imge işleme işlemcileri ile sorun olmaktan çıkmıştır.

YSA, UATBÇS ve ÇDVM sınıflayıcılarının, eğitim başarımı uyarlanan özellik çıkarım algoritmaları için %100 gerçekleşmiştir. Buradan, özellik uzayında bir birini kapsayan alt kümelerin oluşmadığı anlaşılır. Bu ise, bir özellik çıkarım algoritmasından beklenen en iyi sonuç olup, uyarlanan özellik çıkarım yapılarının, sınıflar arasındaki ayrımı ne kadar keskin bir şekilde sağladığını göstermektedir.

Bu tez çalışmasında, Bölüm 8.1’de nasıl elde edildikleri açıklanan mikroskobik idrar tortusu imgelerine, tezin 5. Bölümü’nde anlatılan temel steganografi tekniklerinden Son Bite Ekleme (SBE) yöntemi uygulanarak, Türkiye’nin neresine gidilirse gidilsin kime ait olduğu belli olan, hiçbir şekilde kayıp olmayacak, daha güvenli imgeler haline getirilmesi sağlanmıştır. Burada elde edilen idrar tortusu imgelerine Son Bite Ekleme (SBE) steganografik güvenlik yöntemi kullanılarak idrar tortusu imgelerinin her biri için ait olduğu hastanın “Adı ve Soyadı”, “ Türkiye Cumhuriyeti (T.C.) Vatandaşlık Numarası”, “Yaşı” ve

“Cinsiyeti” gibi kişisel bilgilerinin sayısal imgenin içine gizlenmesi işlemi gerçekleştirilmiştir.

9.2. Öneriler

1. Mikroskobik idrar tortusu imgelerinde bulunan hücrelerin otomatik tanınması ve sayılması için yapılan uygulamada, YSA, UATBÇS ve ÇDVM sınıflandırıcılarının eğitimi için kullanılan veri örneklerinin sayısı artırılarak, uyarlanan karar destek sistemlerinin başarımı daha da yükseltilebileceği gibi bu mikroskobik idrar imgeleri kullanılarak hastalık teşhisine yönelik çalışmalar yapılabilir.
2. Bu tez çalışmasında kullanılan ve uyarlanan algoritmalarda veri alma, özellik çıkarma ve sınıflama işlemlerinin daha hızlı yapılabilmesi problemi ileride, DSP gerçeklemeleri kullanılarak giderilebilir.
3. Bu tezde uyarlanan karar destek sistemlerinde mikroskobik sayısal imgeler içerisine verileri gizlemek için SBE tekniğinin dışında diğer steganografi teknikleri de kullanılarak bu tekniklerin PSNR ve OKH performans karşılaştırmaları yapılabilir.

9.3. Yayınlar

Bu tez çalışmasında gerçekleştirilen uygulamalar iki adet dergi yayını [105], [106] ve bir adet konferans yayını [107] ile sonuçlandırılmıştır.

Kaynaklar

- [1] **Luo, H., Ma, S., Wu, D. and Xu, Z.,** 2007. Mumford-Shah Segmentation for Microscopic Image of the Urinary Sediment, The 1st International Conference on Bioinformatics and Biomedical Engineering, s.s.861 – 863, ICBBE.
- [2] **Lakatos, J., Bodor, T., Zidarics, Z., Nagy, J.,** 2000. Data processing of digital recordings of microscopic examination of urinary sediment, Clin Chimica Acta, cilt no. 297, s.s. 225–237.
- [3] **Lamchiagdhase, P., Preechaborisutkul, K., Lomsomboon, P., Srisuchart, P., Tantiniti, N. Khan-u-ra P. et al.,** 2005. Urine sediment examination: a comparison between the manual method and the iQ200 automated urine microscopy analyzer, Clin Chimica Acta, cilt no. 358, s.s. 167–174.
- [4] **Cao, G., Zhong, C., Li, L. and Dong, J.,** 2009. Detection of Red Blood Cell in Urine Micrograph, 3rd International Conference on Bioinformatics and Biomedical Engineering (ICBBE), s.s. 1 – 4.
- [5] **Wei, Y.,** 2008. The Research of Urinary Sediment Visual Component Analysis Based on Fuzzy Clustering [D]. Nanjing Information Engineering University, 2008:3-4, 15-32.
- [6] **Ding, R.,** 2006. Algorithm Research on Recognition and Classification of Microscopic Urinary Sediment Images [D]. Jilin University, 9-16, 20-31.
- [7] **Wang, K.,** 2000. Jianzheng ZHANG. Research of the Cell Automatic Recognition and Categorization in Urine Micrographs [J]. Chinese Journal of Scientific Instrument, 2000, cilt no. 21 (6), s.s. 648-650.
- [8] **Ma, J., Cong Y.,** 2004. Bacteriuria on the impact of urine analyzer to measure red blood cell. Chinese Journal of Laboratory Medicine, 22(4): 205-207.
- [9] **Avcı, D.,** 2012. Görüntü İşleme Teknikleri Kullanılarak İdrar Tortusunun İncelenmesi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Semineri, 2012.
- [10] **Li, C., Fang, B., Wang, Y., Lu, G., Qian, J., Chen, L.,** 2009. Automatic Detecting and Recognition of Casts in Urine Sediment Images, Proceedings of the 2009 International Conference on Wavelet Analysis and Pattern Recognition, Baoding, s.s. 26-31,12-15.
- [11] **Lamchiagdhasea, P., Preechaborisutkula, K., Lomsomboonb, P., Srisucharta, P., Tantinitia, P., Khanurab, N., Preechaborisutkula, B.,** 2007. Urine sediment examination: A comparison between the manual method and the iQ200 automated urine microscopy analyzer, Clinica Chimica Acta, Vol 384,pp. 28–34.

- [12] **Chien, T., Kao, J., Liu, H., Lin, P., Hong, J., Hsieh, H., Chien, M.,** 2007. Urine sediment examination: A comparison of automated urinalysis systems and manual microscopy, *Clinica Chimica Acta*, Vol 384,pp. 28–34.
- [13] **Li, Y., Li, Z., Mei, Y., Zhang, J.,** 2005. Detecting Algorithm Based Gabor in Microscopic Image, *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou*, pp.18-21.
- [14] **Li, C., Fang, B., Wang Y., Lu, G., Qian, J., Chen, L.,** 2009. Automatic Detecting And Recognition of Casts in Urine Sediment Images, *Proceedings of the 2009 International Conference on Wavelet Analysis and Pattern Recognition, Baoding*, 12-15.
- [15] **Lamchiagdhasa, P., Preechaborisutkula, K., Lomsomboonb P., Srisucharta P., Tantinitia, P., Khanurab, N., Preechaborisutkula, B.,** 2007, Urine sediment examination: A comparison between the manual method and the iQ200 automated urine microscopy analyzer, *Clinica Chimica Acta*, Vol 384,pp. 28–34.
- [16] **Chien, T., Kao, J., Liu, H., Lin, P., Hong, J., Hsieh, H., Chien, M.,** 2007, Urine sediment examination: A comparison of automated urinalysis systems and manual microscopy, *Clinica Chimica Acta*, Vol 384,pp. 28–34.
- [17] **İdrarın Mikroskopik Analizi**, 2011. Tıbbi Laboratuar Ders Notları, 725TTT118, T.C. Milli Eğitim Bakanlığı, Ankara.
- [18] <http://www.nkfu.com/oruntu-nedir-oruntu-ornekleri/>, Erişim Tarihi 18.06.2014.
- [19] **Deshuang, H., Erke, M., Yueqiu, H.,** 1995. Application of function link net to recognition of radar targets, *Acoustics, Speech, and Signal Processing, ICASSP-95., International Conference on*, 5, 9-12, 3487 – 3490.
- [20] **Türkoğlu, İ.,** 2002. Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma, *Fırat Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi*, s.s. 112.
- [21] **Rothe, H.,** 1998. Approaches to pattern recognition, advanced pattern recognition techniques, *NATO-RTO Lecture Series 214, Lisbon Portugal*, 1.1 – 1.29.
- [22] **Duda, R.O. and Hart, P.E.,** 1989. *Pattern Classification and Scene Analysis*. Stanford Research Institute, 483s.

- [23] **Phan, F., Tzanakou, E.M. and Sideman, S.,** 2000. Speaker identification using neural networks and wavelets, IEEE Engineering in Medicine and Biology, 92-101.
- [24] **Akin, M., Arserim, M.A., Kıymık, M.K. and Türkoğlu, İ.,** 2001. A new approach for diagnosing epilepsy by using wavelet transform and neural networks, 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC2001), 25-28 October 2001, İstanbul, 4.2.6.(1).
- [25] **Türkoğlu, İ. ve Hanbay, D.,** 2001. Yapay sinir ağı ve HFD kullanarak DTMF sinyal örüntülerini tanıma sistemi, Elektrik-Elektronik-Bilgisayar Mühendisliği 9.Ulusal Kongresi, Kocaeli, 431-434.
- [26] **Sowelam, S.M. ve Tewfik, A.H.,** 2000. Waveform selection in radar target classification, IEEE Transactions on Information Theory, 46, 1014 –1029.
- [27] **Chau, T.,** 1994. Pattern recognition of processed EMG signals for two-site Myoelectric control, Uygulamalı Master Lisans Tezi, Toronto Üniversitesi, 96s.
- [28] **Kil, D.H. ve Shin, F.B.,** 1996. Pattern Recognition and Prediction with Applications to Signal Characterization. AIP Press, USA, 417s.
- [29] **Rutledge, G.A.,** 2000. Dictionary Projection Pursuit: A wavelet packet technique for acoustic spectral feature extraction, Doktora Tezi, Victoria Üniversitesi, 193s.
- [30] **Englehart, K.,** 1998. Signal Representation for Classification of the Transient Myoelectric Signal, Doktora Tezi, New Brunswick Üniversitesi, Kanada, 319s.
- [31] <http://emrahozkaynak.blogcu.com/oruntu-tanima-ders-notlari-1/10026042>, Örüntü Tanıma Ders Notları-1, 10.04.2014
- [32] **Shannon, C.E.,** 1948. A mathematical theory of communication, Bell System Technology Journal, 27, 379-423.
- [33] **Rajan, J.J.,** 1994. Time series classification, Doktora Tezi, Cambridge Üniversitesi, 191s.
- [34] http://tr.wikipedia.org/wiki/Karar_destek_sistemi, Karar Destek Sistemleri-1, 09.04.2014.
- [35] http://tr.wikipedia.org/wiki/Uzman_sistemler, Uzman Sistemler, 09.04.2014.

- [36] **Boehringer S, Vollmar T, Tasse C, Wurtz R.P.**, 2006. Syndrome identification based on 2d analysis software. *Eur J Hum Genet* 2006;14(10):1082–9.
- [37] **Farkas LG.** 2009. Anthropometry of the head and face in medicine. New York: Elsevier.
- [38] **Aldridge K, Boyadjiev S.A., Capone G.T., DeLeon V.B., Richtsmeier J.T.**, 2005. Precision and error of 3d phenotypic measures acquired from 3dMD photogrammetric images. *Am J Med Genet A* 2005; 138(3): 247–53.
- [39] **Kau1 C.H., Richmond S, Incrapera A, English J, Xia J.J.**, 2007. Three-dimensional surface acquisition systems for the study of facial morphology and their application to maxillofacial surgery. *Int J Med Robot* 2007;3(2):97–110.
- [40] **Loos H.S., Wieczorek D, Wurtz R.P., Malsburg C.**, 2003. Computer-based recognition of dysmorphic faces. *Eur J Hum Genet* 2003;11(8):555–60.
- [41] **Hammond P, Hutton T.J., Allanson J.E., Buxton B.**, 2005. Discriminating power of localized three-dimensional facial morphology. *Am J Med Genet* 2005;77(6):999–1010.
- [42] **Hammond P.**, 2007. The use of 3d face shape modelling in dysmorphology. *Arch Dis Child* 2007;92(12):1120–6.
- [43] **Gul A.B.**, 2003. Holistic face recognition by dimension reduction. Middle East Technical University, Master's thesis.
- [44] **Tripathi B.K. and Kalra P.K.**, High dimensional neural networks and applications. In: Prathiar DK, Jain LJ, editors. *Intelligent autonomous systems: foundations and applications*. Berlin, Heidelberg: Springer; 2010. p. 215–33.
- [45] **Wozniak M, Grana M, Corchado E.**, 2014. A survey of multiple classifier systems as hybrid systems. *Inform Fusion* 2014;16:3–17.
- [46] **Corchado E, Wozniak M, Abraham A.**, 2014. Snásel V. Recent trends in intelligent data analysis. *Neurocomputing* 2014;126:1–2.
- [47] **Kapoor S, Khanna S, Bhatia R.** 2010. Facial gesture recognition using correlation and Mahalanobis distance. *Int J Comput Sci Inform Secur* 2010;7(2):267–72.
- [48] http://tr.wikipedia.org/wiki/Sayısal_görüntü_işleme, Sayısal görüntü işleme, 09.04.2014.
- [49] **Avcı D.** 2009. İnsanlarda Görülen Parazit Yumurtalarının Otomatik Sınıflandırılması İçin Bir Uzman Sistem Tasarımı, Fırat Üniversitesi Fen bilimleri Enstitüsü, Yüksek Lisans Tezi.
- [50] **Ash L. R. ve Orihel T. C.**, 1990. *Atlas of Human Parasitology*, 3rd ed. Chicago, IL: ASCP.
- [51] <http://tr.wikipedia.org/wiki/Parazit>. Parazit, 10.10.2007.

- [52] <http://www.yildiz.edu.tr/~bayram/sgi/saygi.htm>, Sayısal Görüntü İşleme, 09.04.2014.
- [53] **Dogantekin E., Yilmaz M., Dogantekin A., Avcı E., ve Sengur A.**, 2008. A robust technique based on invariant moments – ANFIS for recognition of human parasite eggs in microscopic images, *Expert Systems with Applications*, 35(3), s.s. 728-738.
- [54] **Sezgin M, Sankur B.**, 2004. Survey over image thresholding techniques and quantitative performance evaluation. *J Electron Image*;13:146–65
- [55] **Calvo A.R., Ruiz F.T., Rurainsky J, Eisert P.**, 2008. 2d-3d mixed face recognition schemes.In: Delac K, Grgic M, Bartlett MS, editors. Recent advances in face recognition.Croatia: In-Teh; p. 125–48.
- [56] **Katzenbeisser, S., Petitcolas, F. A. P.**, 2000. Information Hiding Techniques for Steganography and Digital Watermarking, Artech House, 2000 - 220 sayfa.
- [57]**Gopalan, K.**, 2003. Audio steganography using bit modification, *InternationalConference on Multimedia and Expo*, Baltimore, Maryland, 629-632.
- [58] **Johnson, N.F., Jajodia, S.**, 1998. Exploring Steganography: Seeing the Unseen, *IEEE Computer*, 31(2):26-34.
- [59] **Kessler, G.C.**, 2004. An Overview of Steganography for the Computer Forensics Examiner, *Forensic Science Communications*, 6(3):1-29.
- [60] **Anderson, R.J., Petitcola, F.A.**, 1998. On the limits of steganography, *IEEE J. Sel. Areas Commun.* 16, 474–481.
- [61] **Cheddad, A., Condell, J., Curran, K., Kevitt, P.M.**, 2010. Digital image steganography: survey and analysis of current methods, *Signal Process.* 90, 727–752.
- [62] **Chandramouli, R., Kharrazi, M., Memon, N.**, 2003. Image steganography and steganalysis: Concepts and practice, in: *Proc. of International Workshop on Digital-forensics and Watermarking*, vol. 2939, pp. 35–49.
- [63] **Wang, H., Wang, S.**, 2004. Cyber warfare: Steganography vs. steganalysis, *Commun. ACM* 47,76–82.
- [64] **Sabeti, V., Samavi, S., Mahdavi, M., Shirani, S.**, 2010. Steganalysis and payload estimation of embedding in pixel differences using neural networks, *Pattern Recognit.* 43, 405–415.

- [65] **Petitcolas, A.P., Anderson, R.J., Kuhn, M.G., 1999.** Information hiding: A survey, in: Proc. of IEEE Special Issue on Protection of Multimedia Content, vol. 87, pp. 1062–1078.
- [66] **Wu, N.I., Hwang, M.S., 2007.** Data hiding: Current status and key issues, Int. J. Netw. Secur. 4, 1–9.
- [67] **Li, B., He, J., Huang, J. Shi, Y.Q., 2011.** A survey on image steganography and steganalysis, Int. J. Inf. Hiding Multimedia Signal Process. 2, 142–172.
- [68] **Pevny, T., Fridrich, J., 2008.** Benchmarking for steganography, in: Proc. of the 10th International Workshop on Information Hiding, vol. 5284, pp. 251–267.
- [69] **Zhang, F., Pan, Z., Cao, K., Zheng, F., Wu, F., 2008.** The upper and lower bounds of the information hiding capacity of digital images, Inform. Sci. 178, 2950–2959.
- [70] **Korzhik, V., Imai, H., Shikata, J., 2008.** On the use of Bhattacharyya distance as a measure of the detectability of steganographic systems, in: Transactions on Data Hiding and Multimedia Security, in: Lecture Notes in Computer Science, vol. 4920, Springer-Verlag, Heidelberg, pp. 23–32.
- [70] **Hu, M. K., 1962.** Visual Pattern Recognition by Moment Invariants, IRE Trans. Info. Theory, vol. IT-8, pp. 179–187.
- [71] **Alt, F.L., 1968.** Digital pattern recognition by moments. Journal of ACM, 9(2), 240–258.
- [72] **Yu F.T.S. ve Li, Y., 1990.** Application of Moment Invariant to Neural computing for Pattern Recognition, Hybrid Image and signal Processing II. Proc. SPIE, s.s. 1297-1307.
- [73] **Micheli-Tzanakou E., Ademoğlu A. ve Enderwick C., 2000,** Other Type of Feature Extraction Methods, Supervised and Unsupervised Pattern Recognition, Chapter 4, CRC Press.
- [74] **Vapnik, V., 1995.** The Nature of Statistical Learning Theory, New York: Springer Verlag, New York, 187s., 1995.
- [75] **Pöyhönen, S., 2004.** Support Vector Machine Based Classification In Condition Monitoring of Induction Motors, Doktora Tezi, Helsinki University of Technology, 63s.
- [76] **Smola, A.J. ve Schölkopf, B., 1998.** A tutorial on support vector regression, Technical Report NC2-TR-1998-030, s.s. 200-222.
- [77] **Jiang, Z.G., Fu, H.G. ve Li, L.J., 2005.** Support vector machine for mechanical faults classification, Journal of Zhejiang University Science, 6A(5), s.s. 433-439.
- [78] **Avcı, E., Akıllı Radar ile Hedef Tanıma Sistemi, 2005,** Fırat Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 176 sayfa.

- [79] **Murasaki, Y., Taniguchi, K., Murakami, Y.,** 1993. Pattern Recognition of Urinary Sediment Images Applying a Fuzzy-neural Network, Trans. of IECE vol.76-D, 12:2630- 2632.
- [80] **Zeng, N., Taniguchi, K., Watanabe, S., Nakano, Y., Nakamoto, H.,** 2000. A precise classifier for the substances in urinary sediment images based on neural networks and fuzzy reasoning, Systems, Man, and Cybernetics, 2000 IEEE International Conference, 3:1928 – 1933.
- [81] **Dong, L., Yuan, S., Liu, G. and Zhou, L.,** 2007. Classification of Urinary Sediments Image Based on Bayesian Classifier, Mechatronics and Automation, 556 – 560.
- [82] **Qian, J., Fang, B., Li, C. and Chen, L.,** 2009. Coarse-to-Fine Particle Segmentation in Microscopic Urinary Images, 3rd International Conference on Bioinformatics and Biomedical Engineering, Beijing.
- [83] **Fang, B., Hsu, W., Lee, M.,** 2003. On the accurate counting of tumor cells, NanoBioscience, IEEE Transactions 2:94 – 103.
- [84] **Pun, C. and Lee, M.,** 2004. Extraction of Shift Invariant Wavelet Features for Classification of Images with Different Sizes, IEEE Transactions on Pattern Analysis and Machine Intelligence, 26(9).
- [85] **Li, C., Fang, B., Wang, Y., Lu, G.Z., Qian, J., Chen, L.,** 2009. Automatic Detecting and Recognition of Casts in Urine Sediment Images, Proceedings of the 2009 International Conference on Wavelet Analysis and Pattern Recognition, Baoding.
- [86] **Tuceryan, M., and Jain, A.K.,** 1993. Texture Analysis, Handbook of Pattern Recognition and Computer Vision, World Scientific, 235-276.
- [87] **Connors, R.W. and Harlow, C.A.,** 1980. A Theoretical Comparison of Texture Algorithms, IEEE Trans. Pattern Analysis and Machine Intelligence, 2: 204-222.
- [88] **Bovik, A.C., Clark, M. and Geisler, W.S.,** 1990. Multichannel Texture Analysis Using Localized Spatial Filters, IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 12.
- [89] **Teuner, A., Pichler, O. and Hosticka, B.J.,** 1995. Unsupervised Texture Segmentation of Images Using Tuned Matched Gabor Filters, IEEE Trans. Image Processing, 6(4): 863- 870.
- [90] **Chang, T. and Kuo, C.C.J.,** 1993. Texture Analysis and Classification with Tree-Structured Wavelet Transform, IEEE Trans. Image Processing, 2: 429-441.
- [91] **Laine, A. and Fan, J.,** 1993. Texture Classification by Wavelet Packet Signatures, IEEE Trans. Pattern Analysis and Machine Intelligence, 15(11):1186-1191.

- [92] **Unser, M.**, 1995. Texture Classification and Segmentation Using Wavelet Frames, IEEE Trans. Image Processing, 4:1549-1560.
- [93] **Pun, C. and Lee, M.** 2003. Log-Polar Wavelet Energy Signatures for Rotation and Scale Invariant Texture Classification, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 25, No.5.
- [94] **Chang, T. and Kuo, J.**, 1993. Texture Analysis and Classification with Tree Structured Wavelet Transform, IEEE Trans. Image Processing, 2(4): 429-441.
- [95] **Arivazhagan, S. and Ganesan, L.**, 2003. Texture classification using wavelet transform, Pattern Recognition Letters, 24:1513-1521.
- [96] **Weszka, J.S., Dyer, C.R., Rosenfeld, A.**, 1976. A comparative study of texture measures for terrain classification. IEEE Trans. System Man Cybernat. SMC-6, 4: 269–286.
- [97] **Davis, L.S., Johns, S.A., Aggarwal, J.K.**, 1979. Texture analysis using generalized co-occurrence matrices. IEEE Trans. Pattern Anal. Machine Intell. PAMI-1, 251–259.
- [98] **Chang, T., Kuo, C.C.J.**, 1993. Texture analysis and classification with tree-structured wavelet transform. IEEE Trans. Image Process. 2 (4):429–440.
- [99] **Unser, M.**, 1995. Texture classification and segmentation using wavelet frames. IEEE Trans. Image Process. 4 (11):1549–1560.
- [100] **Haley, G.M., Manjunath, B.S.**, 1995. Rotation invariant texture classification using modified Gabor filters. Proc. IEEE, 262–265.
- [101] **Manjunath, B.S., Ma, W.Y.**, 1996. Texture features for browsing and retrieval of image data. IEEE Trans. Pattern Anal. Machine Intell. 18(8): 837–842.
- [102] **Wu, W.R., Wei, S.C.**, 1996. Rotation and gray scale transform invariant texture classification using spiral resampling, sub band decomposition and Hidden Markov model. IEEE Trans. Image Process. 5 (10), 1423–1433.
- [103] **Avci, E., Turkoglu, I., Poyraz, M.**, 2005. Intelligent Target Recognition Based on Wavelet Packet Neural Network, Experts Systems with Applications, 29(1):175-182.
- [104] **Turkoglu, I., Arslan, A., Ilkay, E.**, 2003. An Intelligent system for diagnosis of the heart valve diseases with wavelet packet neural networks, Computer in Biology and Medicine, 33:319-331.
- [105] **Avci, D., Poyraz, M., Leblebicioğlu, M.K., Doğantekin E.**, 2014. A New Method Based on Adaptive Discrete Wavelet Entropy Energy and Neural Network

Classifier (ADWEENN) for Recognition of Urine Cells from Microscopic Images Independent of Rotation and Scaling, J Med Syst, 38:7.

- [106] **Doğantekin E., Avcı, D., Poyraz, M., Doğantekin A., Erkuş Ö.,** 2014. The Automatic Detection of RNA Viruses Using Multi-Entropy and Artificial Neural Network Method (ME-ANN)”, E-Journal of New World Sciences Academy (NWSA) - Medical Sciences, DOI Number: 2014.9.3.1B0038, 1-13.
- [107] **Güleryüz, H.İ., Tuncer, T., Avcı, D.,** 2013. Kaos ve SCAN Algoritması Tabanlı Görüntü Şifreleme Uygulaması, 1st International Symposium on Digital Forensics and Security (ISDFS’13), 167-171, Elazığ, Turkey

ÖZGEÇMİŞ

Derya AVCI

derya2344@hotmail.com.tr

Fırat Üniversitesi Mühendislik Fakültesi

Elektrik-Elektronik Mühendisliği

ELAZIĞ

1982 yılında Malatya’da doğdu. İlk, orta ve lise öğrenimini Malatya’da tamamladıktan sonra 2001 yılında Fırat Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Eğitimi Bilgisayar Öğretmenliği Bölümü’nü kazandı. 2005 yılında bu bölümden mezun oldu. 2009 yılında Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektronik Bilgisayar Eğitimi Ana bilim Dalı Bilgisayar Sistemleri Anabilim Dalı’nda yüksek lisans eğitimini tamamladı. 2010 yılı şubat ayında Elektrik-Elektronik Mühendisliği Devreler Sistemler anabilim dalında doktora eğitimine başladı. Şu an Elazığ Mehmet Koloğlu Anadolu Lisesi’nde Bilgisayar Öğretmeni olarak görevini sürdürmektedir. Yabancı dili İngilizce’dir. Evli ve iki çocuk annesidir.