



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



**GEOMETRİK TABANLI ÖZNİTELİK ÇIKARMA
VE ÖZNİTELİK FÜZYONUNA DAYALI PARMAK
DAMAR TANIMA**

Fatih TİTREK

DOKTORA TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Temmuz-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Fatih TİTREK tarafından hazırlanan “**Geometrik Tabanlı Öznitelik Çıkarma ve Öznitelik Füzyonuna Dayalı Parmak Damar Tanıma**” adlı tez çalışması 10/07/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Erkan ÜLKER

.....

Danışman

Doç. Dr. Ömer Kaan BAYKAN

.....

Üye

Prof. Dr. Harun UĞUZ

.....

Üye

Doç. Dr. Hasan Erdinç KOÇER

.....

Üye

Dr. Öğr. Üyesi Murat KÖKLÜ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Fatih TİTREK

Tarih: ... / ... /

ÖZET

DOKTORA TEZİ

GEOMETRİK TABANLI ÖZNİTELİK ÇIKARMA VE ÖZNİTELİK FÜZYONUNA DAYALI PARMAK DAMAR TANIMA

Fatih TİTREK

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Ömer Kaan BAYKAN

2023, 83 Sayfa

Jüri

Prof. Dr. Erkan ÜLKER

Prof. Dr. Harun UĞUZ

Doç. Dr. Hasan Erdinç KOÇER

Doç. Dr. Ömer Kaan BAYKAN

Dr. Öğr. Üyesi Murat KÖKLÜ

Biyometrik tanıma (BT) sistemleri, canlıların kimliklerinin otomatik olarak doğrulanmasını veya tanımlanmasını sağlayan sistemler bütünüdür. Bu işlem sırasında sadece o canlıya özgü benzersiz olarak bulunan parmak damar (PD) ağı, avuç içi damar ağı, parmak izi, retina, yüz, imza, ses vb. gibi karakteristik özellikler kullanılmaktadır. Bu özelliklerden birisi olan PD ağı, sahip olduğu ekstra avantajlar nedeniyle diğer BT sistemlerine göre kullanım alanlarını ve popülerliğini giderek artırmaktadır. Özellikle güvenliğin ve uygulanabilirliğin ön planda olduğu yerlerde kullanım alanı giderek yaygınlaşmaktadır. PD tanıma sistemlerindeki başarı oranlarını yükseltmek ve sistemin verimliliğini artırmak amacıyla önemli aşamalardan olan ön işleme ve öznitelik çıkarma aşamalarında her geçen gün yeni çalışmalar yapılmaktadır. Parmak damar ağı görüntülerinde bulunan gürültülerin azaltılması, yeni özniteliklerin çıkarılması ve bu özniteliklerin kullanıldığı yeni yöntemlerin geliştirilmesi konularında çalışmalar literatüre kazandırılmaktadır. PD resimlerinin elde edilme aşamasında kullanılan kızılötesi ışınların ya da kurulan sistemin, dokunun yapısal özelliklerinden kaynaklı meydana getirdiği ışık saçılmaları, optik ve hareketli bozulmalar sebebiyle ortaya çıkan gürültülerin temizlenmesi amacıyla çalışmalar yapılmaktadır. Bu tez çalışmasında, Homomorfik Filtre (HF) ve Perona-Malik Anizotropik Difüzyon (PMAD) yöntemleri ön işleme aşamasında kullanılarak görüntülerde bulunan gürültüler giderilmeye çalışılmıştır. Ayrıca başarı oranını yükseltmek amacıyla, literatürde kullanılan öznitelik çıkarma yöntemlerinden elde edilen özniteliklere ilaveten Yatay Toplam Oran (HTP) ve Dikey Toplam Oran (VTP) olmak üzere iki yeni öznitelik önerilmiştir. Bu öznitelikler Yatay ve Dikey Toplam Oran (HVTP) öznitelik çıkarma yöntemi kullanılarak literatüre kazandırılmıştır. Çıkarılan yeni öznitelikler hem uzamsal hem de frekans alanı öznitelikleri ile öznitelik füzyonu yardımıyla birleştirilmiş ve farklı sınıflandırma yöntemleri kullanılarak başarı oranında sağladığı iyileştirmeler gözlemlenmiştir. Yapılan çalışmalarla, parmak damarlarına ait özelliklerin etkin bir şekilde kullanılması ve PD tanıma performansının artırılması sağlanmış, kimlik tanıma süreçlerinde daha güvenilir ve yüksek doğruluk içeren uygulamaların geliştirilmesine katkıda bulunulmuştur.

Anahtar Kelimeler: Biyometrik tanıma, dikey toplam oran, görüntü işleme, öznitelik çıkarma, öznitelik tanımlama, parmak damar tanıma, sınıflandırma, yatay toplam oran.

ABSTRACT

PhD THESIS

GEOMETRIC BASED FEATURE EXTRACTION AND FINGER VEIN RECOGNITION BASED ON FEATURE FUSION

Fatih TİTREK

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Assoc. Prof. Dr. Ömer Kaan BAYKAN

2023, 83 Pages

Jury

Prof. Dr. Erkan ÜLKER

Prof. Dr. Harun UĞUZ

Assoc. Prof. Dr. Hasan Erdiñç KOÇER

Assoc. Prof. Dr. Ömer Kaan BAYKAN

Asst. Prof. Dr. Murat KÖKLÜ

Biometric recognition (BT) systems are a set of systems that automatically verify or identify individuals' identities. During this process, characteristic features unique to each individual, such as finger vein (PD) pattern, palm vein pattern, fingerprint, retina, face, signature, voice, etc. are used. PD pattern, which is one of these features, is gradually expanding its areas of usage and popularity compared to other BT systems due to its additional advantages. Especially in places where security and applicability are prioritized, the use of PD recognition systems is increasingly expanding. In order to enhance the success rates of PD recognition systems and increase the efficiency of the system, important stages such as preprocessing and feature extraction are being continuously explored through new research. Studies on the reduction of noise in PD images, the extraction of new features, and the development of new methods using these features are brought to the literature. Studies are made to remove the noise, caused by infrared rays, or light scattering occurring from the structural properties of the tissue or optical and motion distortions occurring in the process of acquiring PD images. In this thesis, the noise presented in the images was attempted to be removed by employing the Homomorphic Filter (HF) and Perona-Malik Anisotropic Diffusion (PMAD) methods during the preprocessing stage. Additionally, in order to enhance the success rates, two new features, namely Horizontal Total Proportion (HTP) and Vertical Total Proportion (VTP), have been proposed in addition to the features obtained from existing feature extraction methods used in the literature. These features have been introduced to the literature using the Horizontal and Vertical Total Proportion (HVTP) feature extraction method. The extracted new features were combined with both spatial and frequency domain features with the help of the feature fusion technique, and improvements in the success rates were observed by using different classification methods. Through these studies, the effective utilization of features associated with PD, as well as the enhancement of PD recognition performance, has been achieved, contributing to the development of more reliable and high-accuracy applications in identity recognition processes.

Keywords: Biometric recognition, classification, feature extraction, feature identification, finger vein recognition, horizontal total proportion, image processing, vertical total proportion.

ÖNSÖZ

Doktora öğrenimim boyunca yardımını, desteğini, tecrübesini, zamanını ve manevi desteğini hiçbir zaman esirgemeyen saygıdeğer danışman hocam Sayın Doç. Dr. Ömer Kaan BAYKAN'a;

Tezin gelişmesinde yönlendirici görüşleri, önerileri, fikirleri ve pozitif kişilikleriyle yardımcı olan çok kıymetli hocalarım Sayın Prof. Dr. Harun UĞUZ ve Sayın Doç. Dr. Hasan Erdiç KOÇER'e;

Her yardıma ihtiyaç duyduğumda fikirleriyle, pozitif yönlendirmeleriyle yardım etmekten kaçınmayan çok saygıdeğer hocalarımdan Sayın Prof. Dr. Erkan ÜLKER, Sayın Prof. Dr. Halife KODAZ, Prof. Dr. İsmail BABAOĞLU ve Sayın Dr. Öğr. Üyesi Hazim İŞCAN'a;

Bilgisayar Mühendisliği Bölümünü güzel bir aile ortamına çeviren hocalarımdan bilgisi, donanımı, ileri görüşlülüğüyle her zaman örnek olan, fark yaratan Sayın Prof. Dr. Ahmet ARSLAN'a, bölümde aynı ortamı paylaştığımız bütün hocalarıma ve araştırma görevlisi arkadaşlarıma;

Aramızdan erken ayrılmak zorunda kalan, yardımseverliğiyle, güler yüzüyle, esp-rileriyle gönüllerimizde taht kuran çok sevdiğim hocalarımdan Sayın Barış KOÇER'e;

Birlikte çalışma imkânı bulduğumuz arkadaşlarımdan Yılmaz ATAY, Ahmet ÖZ-KİŞ, Hüseyin HAKLI ve İsmail KOÇ'a;

Eski hocalarımdan, bende ayrı yere sahip olan Prof. Dr. Sibel TARI, Prof. Dr. Derviş KARABOĞA, Prof. Dr. Veysel ASLANTAŞ'a ve aramızdan erken ayrılmak zorunda kalan hocalarımdan Sayın Mehmet ALTUNER'e;

Üniversite yıllarıma kadar beni okutan, bana yol gösteren, fikir veren, dara düştüğümde yanımda olan, her şart ve koşulda yardımına koşan, birlikte bütün duyguları yaşadığımız en kıymetlilerim Annem ve Babama;

Bugün ailemize yeni katılacağı haberini aldığım ailemizin en yeni üyesine ve gelecekte katılacak olan diğer üyelere;

Elbette her zaman yanımda olan, varlığıyla bana sonsuz güç veren, özellikle çok yoğun geçen dönemlerimde bana desteğini esirgemeyen sevgili biricik eşime sonsuz teşekkürlerimi sunarım.

Fatih TİTREK
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. Tezin Amacı ve Önemi	4
1.2. Tezin Literatüre Katkısı	5
1.3. Tezin Organizasyonu	7
2. KAYNAK ARAŞTIRMASI	8
3. MATERYAL VE YÖNTEM.....	18
3.1. Parmak Damar Veri Setleri.....	18
3.1.1. Yang veri seti	18
3.1.2. MMCBNU_6000 veri seti	19
3.2. Ön İşleme Adımları	20
3.2.1. Homomorfik filtre.....	20
3.2.2. Perona-Malik anizotropik difüzyon	22
3.3. Segmentasyon ve Son İşleme Adımları	24
3.3.1. Niblack segmentasyon algoritması	24
3.3.2. Morfolojik işlemler	25
3.3.2.1. Aşındırma (Erosion)	25
3.3.2.2. Genişletme (Dilation)	26
3.3.2.3. Açma (Opening)	26
3.3.2.4. Kapama (Closing)	26
3.4. Öznitelik Çıkarma Yöntemleri.....	27
3.4.1. Gri seviye çalışma uzunluğu matrisi (GLRLM)	27
3.4.2. Gri seviye eş oluşum matrisi (GLCM)	30
3.4.3. Segmentasyon tabanlı fraktal doku analizi (SFTA).....	34
3.4.4. Genel fourier tanımlayıcılar (GFD)	35
3.4.5. Çalışma kapsamında kullanılan diğer öznitelikler.....	36
3.4.5.1. Standart sapma	36
3.4.5.2. Entropi	37
3.4.5.3. Ağırlık merkezi	37
3.5. Sınıflandırma Yöntemleri	38
3.5.1. Topluluk öğrenmesi	38
3.5.1.1. Torbalama	40
3.5.1.2. AdaBoost	40
3.5.1.3. RUSBoost	40
3.5.1.4. Alt uzay k-en yakın komşu	41

3.5.1.5. Alt uzay diskriminant.....	41
3.5.2. K-en yakın komşu (KNN).....	41
3.5.3. Destek vektör makineleri (SVM).....	42
3.5.4. Karar ağacı algoritması.....	43
3.5.5. Diskriminant analizi.....	44
3.6. Önerilen Öznitelik Çıkarma Metotları.....	44
3.6.1. Yatay Toplam Oran (HTP).....	45
3.6.2. Dikey Toplam Oran (VTP).....	47
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	49
4.1. Çalışmalarda Kullanılan Parametrelerin Belirlenmesi	50
4.2. Önerilen Algoritmaların Çıktıları	51
4.2.1. Ön işlem adımında kullanılan algoritmaların çıktıları.....	51
4.2.2. Segmentasyon ve son işlem adımlarında kullanılan algoritmaların çıktıları....	52
4.3. Öznitelik Seçimleri ve Etkileri	53
4.4. Sınıflandırma Sonuçları	54
4.4.1. Uzamsal domainde yapılan sınıflandırma sonuçları	54
4.4.2. Frekans domaininde yapılan sınıflandırma sonuçları	56
4.4.3. GLRLM, GLCM ve SFTA kullanılarak çıkarılan özniteliklerin HVTP öznitelikleriyle füzyon sonuçları	59
4.4.4. Özniteliklerin Relieff algoritması kullanılarak önem sıralamalarına göre ağırlıklandırma işlemi	67
4.4.5. Öznitelik ağırlıklandırma yardımıyla öznitelik azaltma yöntemi	70
4.4.6. Literatürde yapılan çalışmalar ve bulunan sonuçların karşılaştırılması.....	73
5. SONUÇLAR VE ÖNERİLER.....	75
5.1 Sonuçlar	75
5.2 Öneriler	77
KAYNAKLAR	78

SİMGELER VE KISALTMALAR

Simgeler

A_x	: Resmin ağırlık merkezinin X düzlemindeki koordinat değeri
A_y	: Resmin ağırlık merkezinin Y düzlemindeki koordinat değeri
H_x	: P_x 'in Entropisi
I_b	: İkili resim
I_g	: Gri seviye resim
N_{GL}	: Resimdeki gri seviye sayısı
N_{RL}	: Resimdeki maksimum çalışma uzunluğu
X_i	: i . Pikselin gri seviye değeri
X_n	: n . Kesişim noktasının X düzlemindeki koordinat değeri
Y_n	: n . Kesişim noktasının Y düzlemindeki koordinat değeri
f_{SE}	: Toplam Entropi
n_p	: Toplam piksel sayısı
n_r	: Toplam iterasyon sayısı
$t_{üst}$	: Üst eşik seviyesi
t_{alt}	: Alt eşik seviyesi
$\Delta(x, y)$	: İkili resmin sınırı
$\sum$	: Döngüsel toplam (Cyclic Summation)
C	: Difüzyon katsayısı (Diffusion Coefficient)
N	: Resimdeki toplam piksel sayısı
λ	: Kontrast parametresi (Lambda)
σ	: Standart sapma, Sigma (Standart Deviation)
E	: Entropi
$I(x, y)$	: Resmin (x, y) koordinatındaki yoğunluk değeri
INT	: İlgili koordinat düzlemindeki kesişim sayısı
$P(i, j \theta)$	: θ Açısal doğrultusunda, i gri seviyesinin j kez tekrarlanma sayısı
$P(i, j d, \theta)$	: θ Açısal doğrultusu ve d uzaklığında, gri seviye i 'den gri seviye j 'ye geçiş
T	: Yerel eşik değeri
$p(x)$	: x piksel değerinin resimde bulunma olasılığı
u	: Giriş verisi
θ	: Teta (Theta)
μ	: Ortalama (Mu)
ρ	: Rho

Kısaltmalar

AdaBoost	: Uyarlamalı Artırma (Adaptive Boosting)
AGCNN	: Adaptif Gabor Evrişimli Sinir Ağları (Adaptive Gabor Convolutional Neural Networks)
BT	: Biyometrik Tanıma (Biometric Recognition)
CCD	: Yük Bağlaşımlı Aygıt (Charge Coupled Device)
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
CT	: Karmaşık Ağaç (Complex Tree)
ÇD	: Çapraz Doğrulama (Cross Validation)

DA	: Diskriminant Analizi (Discriminant Analysis)
f-KNN	: İnce KNN (Fine KNN)
GCNN	: Gabor Evrişimli Sinir Ağı (Gabor Convolutional Neural Network)
GFD	: Genel Fourier Tanımlayıcılar (Generic Fourier Descriptors)
GLCM	: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrices)
GLRLM	: Gri Seviye Çalışma Uzunluğu Matrisi (Gray Level Run Length Matrices)
HF	: Homomorfik Filtre (Homomorphic Filter)
HTP	: Yatay Toplam Oran (Horizontal Total Proportion)
HVTP	: Yatay ve Dikey Toplam Oran (Horizontal and Vertical Total Proportion)
KNN	: K-En Yakın Komşu (K-Nearest Neighbor)
LBP	: Yerel İkili Desen (Local Binary Pattern)
LDA	: Doğrusal Diskriminant Analizi (Linear Discriminant Analysis)
LDC	: Yerel Yönlü Kodlama (Local Directional Code)
LDP	: Yerel Yönlü Desen (Local Directional Pattern)
LLBP	: Yerel Çizgi Tabanlı İkili Desen (Local Line Binary Pattern)
NIR	: Yakın Kızılötesi (Near Infrared)
PCLPP	: Temel Bileşen Analizi ve Yerel Koruyucu Projeksiyonlar (Principal Component Analysis and Locality Preserving Projections)
PD	: Parmak Damar (Finger Vein)
PMAD	: Perona-Malik Anizotropik Difüzyon (Perona-Malik Anisotropic Diffusion)
PWBDC	: Polarize Derinlik Ağırlıklı İkili Yön Kodlaması (Polarized depth-Weighted Binary Direction Coding)
QDA	: İkinci Dereceden Diskriminant Analizi (Quadratic Discriminant Analysis)
ROI	: İlgi Bölgesi (Region of Interest)
RPL	: Tekrarlı Çizgi Takibi (Repeated Line Tracking)
RUSBoost	: Rastgele Düşük Örnekleme Artırma (Random Under Sampling Boosting)
SD	: Alt Uzay Diskriminant (Subspace Discriminant)
SFTA	: Segmentasyon Tabanlı Fraktal Doku Analizi (Segmentation Based Fractal Texture Analysis)
SubKNN	: Alt Uzay K-En Yakın Komşu (Subspace KNN)
SVM	: Destek Vektör Makineleri (Support Vector Machine)
VS1	: Yang Veri Seti (Yang Data Set)
VS2	: MMCBNU_6000 Veri Seti (MMCBNU_6000 Data Set)
VTP	: Dikey Toplam Oran (Vertical Total Proportion)

1. GİRİŞ

İnsanların kim olduklarının tespiti, tanınması ve diğer insanlardan ayırt edilmesi, hayatın başlangıcından bu yana insanlar ve bazı canlılar tarafından doğal olarak yerine getirilebilen bir süreçtir. Eski çağlarda bu işlemler insanların yüzlerinden, seslerinden, kokularından veya karakteristik bazı özelliklerinden belirlenebiliyorken, artan gereksinimler ve gelişen teknoloji ile birlikte başlayan sanayi ve teknoloji devrimleri ile bu sürecin otonom hale gelme ihtiyacı doğmuş ve bu amaçla kimlik tanıma ve doğrulama sistemlerinin tarihsel gelişimi başlamıştır.

Kimlik tanıma ve doğrulama sistemlerinin tarihsel gelişimi içinde kimlik doğrulama yöntemlerini bilgi tabanlı, nesne tabanlı ve biyometrik tabanlı olmak üzere üç kısımda inceleyebiliriz. Bilgi tabanlı kimlik doğrulama yöntemlerinde herhangi bir yere veya sisteme giriş yetkisi alabilmek için bireyden kullanıcı adı, parola, PIN veya anahtar kelime gibi gizli bilgiler istenilmektedir. Verilen bilgiler doğrulama yöntemi ile doğrulandıktan sonra girişine izin verilmekte veya giriş yetkisi verilmemektedir. Girişine izin verilen ortam, bir bilgisayar sistemi olabildiği gibi işyeri, askeri bölge veya bina da olabilir. Giriş yapılan yeri sadece dijital bir ortam ile sınırlamak veya doğrulama işleminin sadece elektronik bir sistem tarafından yapılacağını düşünmek yanlış olacaktır. Bu tip sistemlerin en büyük dezavantajı gizli bilginin bir başkasının eline geçmesiyle yetkisiz bir giriş yapılabilme ihtimalidir. Bir diğer olumsuz özelliği ise gizli bilginin unutulabilme ihtimalidir. Bu durumda yetkisi olmasına rağmen giriş yapamama gibi bir durum ortaya çıkabilmektedir. Nesne tabanlı kimlik doğrulama yöntemlerinde ise, içerisinde giriş yetkisi alabilmek için gerekli bilgilerin bulunduğu ve sistem tarafından bu bilgilerin doğrulandığı bir radyo frekanslı tanımlama kartı, manyetik kart, içinde elektronik devre barındıran bir kart, anahtar vb. gibi bireyin herhangi bir sisteme giriş yetkisi alabilmek için bir nesneye ihtiyaç duyulmaktadır. Nesne tabanlı yöntemler, bilgi temelli yöntemlerde yaşanan şifrenin veya parolanın unutulması probleminden farklı olarak kullanılan nesnenin herhangi bir yerde unutulması, bozulması, kaybedilmesi veya bir başkasının eline geçmesi gibi riskleri veya sorunları içerisinde barındırmaktadır. Bu iki sistemde de yaşanan temel sorunların büyük bölümünün yaşanmadığı, kişilerin bilgi ve nesne tabanlı yöntemlerin aksine şifre ya da anahtara ihtiyaç duymadığı, sadece kendi fiziksel veya davranışsal karakteristiklerinin kullanıldığı bir diğer yöntem ise biyometrik tabanlı yöntemlerdir. Bi-

yometrik tabanlı yöntemlerin amacı, hatırlanması gereken bir bilgiye veya yanında taşınması gereken herhangi bir nesneye ihtiyaç duyulmaksızın başkası tarafından kolaylıkla taklit edilemeyen ve bir başkasına devredilemeyen, genellikle ömür boyu değişmeyen, sadece o canlıya özgü bir veya birkaç özelliği kullanarak kimliklerini doğrulama veya tanımlama işleminin gerçekleştirilmesidir (Şamlı ve Yüksel, 2009). Biyometrik verilerin kullanılmasıyla birlikte, farklı bireylerin birbirlerinden ayırt edilebilirliği oldukça yüksek oranlara çıkmakta ve yetkisiz girişlerin önüne geçilerek güvenilir sistemler geliştirilmektedir. Bu amaçla BT sistemleri kullanılmaktadır.

BT sistemlerine geçmeden önce ilk olarak biyometri kelimesinin köküne inmek doğru olacaktır. Biyometri (biometrics), kelime olarak yaşam anlamına gelen “bio” ve ölçüm anlamına gelen “metrics” kelimelerinin birleşiminden meydana gelen, canlının fiziksel veya davranışsal karakteristik özelliklerinden yararlanılan bilim dalına verilen isimdir. BT sistemleri ise biyometrik tabanlı yöntemler aracılığıyla canlıya ait karakteristik özellikleri kullanarak tanıma işlemini gerçekleştirebilen sistemlere verilen genel addır. BT sistemlerini, fiziksel ve davranışsal özellikler kullanılarak gerçekleştirilen tanıma sistemleri olmak üzere ikiye ayrılabilir (Luo ve diğ., 2010). Canlının parmak izi, el geometrisi, yüz taraması, iris taraması, retina taraması, avuç içi izi, dil şekli, vücut şekli, dudak şekli, kulak şekli, koku, kalp sesi, DNA gen haritası, damar ağı gibi biyometrik veriler fiziksel özellikler kullanılarak gerçekleştirilen tanıma sistemleri kategorisinde değerlendirilir. Ses, el yazısı, ıslak imza, yürüyüş şekli, klavyede yazma / tuş basma dinamikleri analizi gibi biyometrik veriler ise davranışsal özellikler kullanılarak gerçekleştirilen tanıma sistemleri başlığı altında incelenmektedir. Bir özelliğin BT sistemlerince kabul edilebilmesi ve uygulanabilmesi için sahip olması gereken bazı temel nitelikler bulunmaktadır. Bunlardan evrensellik (universality), incelenen tür içindeki her canlının aynı karakteristiğe farklı şekillerde sahip olmasını ifade eder. Her canlıda kendine özgü olup aynı türdeki diğer canlıların her birinde farklı şekillerde oluşması durumu eşsiz olma / ayırt edilebilirlik (uniqueness) olarak ifade edilirken, niteliğin zamanla değişmediğini gösterme durumu süreklilik (permanence) olarak tanımlanmaktadır. Ölçümün rahat bir şekilde yapılarak özelliklerin kolay bir şekilde toplanabilmesi ise elde edilebilirlik (collectability) olarak ifade edilir (Sanjekar ve Patil, 2013). Biyometrik tabanlı yöntemlerin her birinin kendine özgü avantajları veya dezavantajları vardır. Kullanım amacına, hizmet verilen sektöre ve hizmetten yararlanacak kitleye göre tercih edilen yöntemlerin avantajları veya dezavantajları değişkenlik gösterebilmektedir. İhtiyaç duyulan güvenlik seviyesi

ile tercih edilecek yöntem arasında bir denge kurulmalıdır. Güvenliğin üst düzeyde olduğu askeri projeler yürüten sektörlerde iris veya retina taramaları ile birlikte diğer kimlik doğrulama yöntemleri çoklu model oluşturacak şekilde tercih edilebilirken, aynı yöntem sosyal tesislerin giriş çıkışlarının kontrol edilmesi amacıyla tercih edilmemektedir. Örneğin, insan için hayati öneme sahip olan gözün spor salonunda bir ışık kaynağına tutularak iris veya retina tanıma yöntemleri aracılığıyla giriş - çıkış kontrolünde kullanılması ne derece abartılı bir uygulama ise, yüksek güvenlik gerektiren tesislere girişin sadece bir şifre kullanılarak yapılması da o derece yetersiz ve yanlıştır. İnsanlar, düşük seviye güvenliğin yeterli olduğu ortamlarda yüksek güvenli bir biyometrik verilerini paylaşmak istemezler. Aynı zamanda kendi yaşam kalitelerini etkileyecek öneme sahip olan gözlerini bir ışık kaynağına tutmaya karşı direnç gösterirler. Bu nedenle tercih edilecek biyometrik tabanlı yöntemi seçerken ihtiyaç duyulan gereksinimlerle birlikte bu sistemi kullanacak bireyler de göz önüne alınmalıdır.

Bu yöntemlerden PD ağı tanıma tekniği üzerinde yakın zamanlarda araştırmacılar belli bir dalga boyu aralığındaki kızılötesi ışınların insan derisinden geçebildiğini ve damar içindeki hemoglobin tarafından emildiğini keşfetmişlerdir (Luo ve diğ., 2010). Dolayısıyla kızılötesi ışının yansımaları damarların olduğu bölgede etrafına göre daha az olmakta ve bu yüzden damarların olduğu bölgeler koyu renkte görülmektedir. Bu görüntü kızılötesine duyarlı yük bağlaşımlı aygıt (CCD) kameralar tarafından görüntülenebilmektedir. Bunun için yakın kızılötesi (NIR) kameralar kullanılabildiği gibi nadirde olsa uzak kızılötesi kameraların kullanıldığı çalışmalarda yapılmıştır (Wang ve diğ., 2008). PD ağı tanıma sistemleri, diğer biyometrik tanıma sistemlerine göre birçok yönden daha avantajlıdır. Öne çıkan avantajları arasında parmak izi, avuç içi izi gibi geleneksel yöntemlere göre PD ağı, yaşayan ve kan geçişi olduğu sürece tanınan bir organ olması nedeniyle kan akışının durmasına neden olacak hiçbir durumda tanıma işlemi gerçekleştirilemez. Damar vücut içinde bulunması ve deri ile kaplı olması nedeniyle çalınması çok daha zordur. Aynı zamanda dış deride meydana gelebilecek deformasyonlar parmak izinde olduğu gibi tanınmaya engel değildir. Bu tür tanıma sistemlerinde okuyucu cihaza parmağın temas etme zorunluluğu bulunması son günlerde sıklıkla gündeme gelen temas ile bulaşan hastalıklar sorununu gündeme getirmektedir. PD ağı tanıma sistemlerinde ise parmağa gönderilen kızıl ötesi ışın sayesinde cihazla temas etmeden damar görüntüsü alınabilmektedir. İris tanıma gibi sistemlerde gözün bir ışık kaynağına tutulması insanlar tarafından çok tercih

edilen bir durum olmamakta bu da uygulamada zorluklara neden olmaktadır. PD ağı tanıma sistemleri ise insanlar tarafından daha kolay kabul edilen bir yöntem olmaktadır. Ayrıca iris tanıma sistemlerine göre ucuz donanım maliyetine sahip olması bu yöntemin kolaylıkla tercih edilmesine ve kullanılmasına imkân sağlamaktadır.

1.1. Tezin Amacı ve Önemi

İnsan biyometrisine dayalı tanıma sistemleri günümüzde sıklıkla kullanılmaktadır. Biyometrik özellikler, her kişide farklı olması ve tahribatsız şekilde kısa zamanda elde edilebilmesi gibi nedenlerden ötürü tercih edilmektedir. PD tanıma sistemleri ise biyometrik tanıma sistemleri arasında son yıllarda popülerliğini giderek artırmaktadır. Bu sistemler, bireylerin parmak damarlarındaki benzersiz özellikler kullanılarak çıkarılan öz nitelikler sayesinde güvenli tanıma işlemini gerçekleştirmektedir. PD ağı tanıma sistemlerinin, geleneksel yöntemlerden olan yüz, iris, avuç içi, parmak izi tanıma sistemlerine göre bazı avantajları vardır. Bu sistemler, parmak damarlarının yaşayan bir organ olması ve kan geçişi olduğu sürece tanınabilmesi, her insana özgü olup güvenilir olması, tanıma esnasında temas gerektirmemesi, dış deride meydana gelebilecek bozulmaların damar ağın etkilememesi, çalınamaması, düşük maliyeti ve kolay uygulanabilirliği gibi nedenlerden ötürü tercih edilmektedir (Titrek ve Baykan, 2020). Mevcut parmak damar tanıma yöntemlerinin doğruluk ve güvenilirlik seviyelerini artırmak için yeni öz niteliklerin araştırılması veya mevcut elde edilen görüntülerdeki gürültülerin azaltılarak resim içindeki nesnelerin görünürlüğünün iyileştirilmesi üzerine yapılan çalışmalar önem arz etmektedir.

Bu tez çalışmasının amacı, PD resimlerine uygulanan görüntü işleme algoritmaları ile gürültüleri azaltılarak damarlı bölgenin görünürlüğü artırılmış olan resimlerin elde edilmesi, önerilen yeni öz nitelik çıkarma yönteminin uygulanması ile yeni öz niteliklerin elde edilmesi ve elde edilen öz niteliklerin PD tanıma sisteminin performansına olan olumlu yöndeki etkisinin incelenmesidir. Bu tez çalışması, literatürde bulunan mevcut PD görüntülerinden öz nitelik çıkarma yöntemlerine ek olarak yeni bir yaklaşım getirmeyi ve mevcut öz nitelik çıkarma yöntemleri ile birlikte kullanılması durumunda başarı oranını artırmayı hedeflemiştir. Aynı zamanda, elde edilen PD resimlerinde meydana gelen ışık saçılması kaynaklı bozulmaların sistem performansı üzerinde yaratacağı olumsuz etkinin, ön işleme aşamasında önerilen algoritmalar sayesinde en aza indirilmesi hedeflenmiştir.

Elde edilen sonuçlar ile PD tanıma sistemlerinin geliştirilerek başarı oranlarının artırılması ve biyometrik tanıma teknolojilerinin daha yaygın olarak kullanılmasına katkı sağlanması amaçlanmıştır. Görüntü zenginleştirme yöntemleri ve yeni özniteliklerin bulunması ile başarı oranlarının artırılması, biyometrik tanıma teknolojilerinin daha geniş uygulama alanlarına yayılması ve yüksek başarı oranları ve güvenilirlik sayesinde gündelik hayatta daha fazla yer almasına olanak sağlayabilecektir.

1.2. Tezin Literatüre Katkısı

PD tanıma sistemleri, biyometrik sistemler arasında tercih edilirliliği gün geçtikçe artmasına karşılık tanıma oranlarının yükseltilmesi üzerine çalışmalar hala devam etmektedir. Yeni öznitelikler genellikle, mevcut PD tanıma sistemlerinin başarı oranlarını veya performanslarını artırdıkları gibi parmak damarlarına ait benzersiz özelliklerin etkin bir şekilde kullanılmasını da sağlamaktadır. Aynı zamanda PD tanıma sistemlerinde kullanılan öznitelik çeşitliliğini artırarak, literatürde kullanılmakta olan özniteliklerdeki eksikliklerin ve sınırlamaların önüne geçmekte ve daha etkin bir tanıma sistemi oluşturulmasına katkıda bulunmaktadır. Böylelikle güvenlikteki ve kimlik doğrulama süreçlerindeki, daha güvenilir ve yüksek doğruluk içeren uygulamaların hayata geçirilme ihtiyacına önemli katkılar sunarak, PD tanıma sistemlerinin daha geniş kullanım alanlarına ulaşmasına yardımcı olmaktadır. Bu amaç doğrultusunda tez çalışmasında geliştirilen iki yeni öznitelikle birlikte literatüre katkıda bulunmaktadır. Literatüre kazandırılan bu öznitelikler sayesinde PD tanıma sistemlerinin performanslarının iyileştirilmesi üzerine yapılacak olan araştırma ve geliştirmelere önemli katkılar sağlaması beklenmektedir. Bu tez çalışması kapsamında geliştirilen öznitelikler *HTP* ve *VTP* olarak isimlendirilmektedir. *HTP* ve *VTP* özniteliklerinin, PD tanıma sistemlerindeki başarı oranlarına etkilerinin incelendiği iki adet SCI-e makale yayınlanmıştır.

Yapılan ilk çalışmada, bulunan iki yeni öznitelik olan *HTP* ve *VTP*, hem uzamsal domainde hem de frekans domaininde bazı öznitelikler ile birlikte kullanılarak başarı oranı üzerine etkileri incelenmiştir. Aynı zamanda, PD görüntülerinde başarı oranına olumsuz yönde etki yaptığı bilinen dokudaki ışık saçılma problemini ortadan kaldırmak ve resimdeki gürültülerden kurtularak damarlı bölgelerin görünürlüğünü artırmak amacıyla, PD görüntülerine ön işleme aşamasında Homomorfik Filtre (HF) ve Anizotropik

Difüzyon Filtresi uygulanmıştır. Böylelikle ışık saçılmalarından ve gürültülerden temizlenmiş olan PD veri setindeki resimlerden elde edilecek damarlı bölgelerin daha görünür olması amaçlanmıştır (Titrek ve Baykan, 2020).

Yapılan ikinci çalışmada ise, öznitelik füzyonuna dayalı öznitelik vektörü oluşturulması durumunda HVTP öznitelik çıkarma yönteminin başarı oranına etkisi detaylı olarak incelenmiştir. Bu amaçla Gri Seviye Çalışma Uzunluğu Matrisi (GLRLM), Gri Seviye Eş Oluşum Matrisi (GLCM), Segmentasyon Tabanlı Fraktal Doku Analizi (SFTA) ve HVTP öznitelik çıkarma yöntemleri kullanılmıştır. Çıkarılan öznitelik vektörleri mevcut veri tabanlarında farklı sınıflandırıcılar kullanılarak incelenmiş, *HTP* ve *VTP* özniteliklerinin başarı oranlarına etkileri araştırılmıştır (Titrek ve Baykan, 2023).

Yapılan çalışmaların literatüre yapmış olduğu katkılar sıralanacak olursa:

- PD tanıma sistemlerinde kullanılmak üzere *HTP* ve *VTP* isimli iki yeni öznitelik literatüre kazandırılmıştır.
- HF ve Perona Malik Anizotropik Difüzyon sayesinde, PD tanıma sistemlerinden elde edilen görüntülerde meydana gelen ışık saçılması ve gürültü azaltılarak resimdeki damarlı bölgenin görünürlüğü artırılmıştır.
- Yapılan çalışmalar göstermiştir ki *HTP* ve *VTP* öznitelikleri hem uzamsal domaininde, hem de frekans domaininde elde edilen öznitelikler üzerinde başarı oranını artırıcı yönde etki yapmıştır.
- HVTP öznitelik çıkarma yöntemi aracılığıyla çıkarılan *HTP* ve *VTP* öznitelikleriyle GLRLM, GLCM, SFTA öznitelik çıkarma yöntemleri sayesinde çıkarılan özellikler, öznitelik füzyonu yöntemi yardımıyla birleştirilmiş ve öznitelik vektörleri elde edilmiştir. Elde edilen öznitelik vektörleri kullanılarak farklı sınıflandırıcılar üzerinde yapılan çalışmalar ile *HTP* ve *VTP* özniteliklerinin başarı oranı üzerindeki etkisi incelenmiştir.
- İki farklı veri seti üzerinde yapılan denemelerle, literatürde geleneksel yöntemler kullanılarak yapılan çalışmalar arasında başarı oranında artış sağladığı görülmüştür.

1.3. Tezin Organizasyonu

Bu tez çalışması beş bölümden oluşmaktadır:

Birinci bölümde, kimlik tanıma ve doğrulama sistemlerinin tarihsel gelişimi hakkında genel bilgiler verilmiştir. Biyometrik tanıma sistemlerinin bir kolu olan PD tanıma sisteminin diğer kimlik tanıma sistemlerine göre avantajları ve dezavantajları anlatılmıştır. Tezin amacından ve öneminden bahsedildikten sonra literatüre sunduğu katkılar maddeler halinde açıklanmaktadır.

İkinci bölümde bulunan kaynak araştırması, doku görüntülerinin elde edilmesi sırasında yaşanan bozulmaların giderilmesi hakkındaki çalışmalar ve PD görüntülerinden öznitelik çıkarılmasına yönelik yapılan çalışmalar olmak üzere iki kısımdan oluşmaktadır.

Tez çalışmasında ihtiyaç duyulan materyaller ve kullanılan yöntemlerin açıklandığı materyal ve yöntemler üçüncü bölümde anlatılmaktadır. Kullanılan veri setleri, ön işleme adımında ihtiyaç duyulan filtreler, resmi bölütlere ayırmak için gerekli segmentasyon algoritmaları, segmente edilen resim üzerinde yapılacak son işlem adımları, çalışmada kullanılan öznitelik çıkarma yöntemleri, sınıflandırıcılar ve literatüre yeni kazandırılan HVTP öznitelik çıkarma yönteminin açıklaması ve detayları bu bölümün içerisinde yer almaktadır.

Dördüncü bölümde gerçekleştirilen araştırmaların deneysel sonuçları detaylıca kronolojik bir sırada anlatılmaktadır. Ön işlemede kullanılan yöntem çıktılarından segmentasyon ve son işlem adımlarında elde edilen görüntülere, öznitelik seçimi ve başarı oranlarına etkilerinden sınıflandırma sonuçlarına, yöntemlerde kullanılan parametrelerin belirlenmesi ve açıklanmasından yeni bulunan özneliğin başarı oranına etkilerine kadar tüm araştırma sonuçları bu bölümde açıklanmaktadır.

Beşinci ve son bölümde ise yapılan doktora çalışması kapsamında elde edilen sonuçlar değerlendirilmekte ve ilerleyen zamanda HVTP öznitelik çıkarma yönteminin farklı alanlarda uygulanabilirliğinin araştırılması ve bu konuda yapılması muhtemel çalışmalar hakkında önerilerde bulunmaktadır.

2. KAYNAK ARAŞTIRMASI

Yapılan literatür araştırmasına göre, ulusal ve uluslararası alanda yapılan çalışmalar incelendiğinde, PD tanıma sistemlerinin başarı oranını ve uygulanabilirliğini artırmaya yönelik birçok çalışmanın yapıldığı görülmektedir. PD tanıma sistemleri üzerine yapılan bu tez çalışması kapsamında, PD görüntülerindeki damarlı bölgede meydana gelen ışık saçılması, gürültü ve resimdeki bozulma sorununu ortadan kaldırmak amacıyla yapılan çalışmalara ve literatürde bulunan öznetelik çıkarma yöntemleri ile mevcut problemi çözmeye yönelik araştırmalara ait literatür özeti verilmiştir.

Fu ve diğ. (2010) yapmış oldukları çalışmada, NIR duyarlıklı kameralar tarafından elde edilen damarlı bölge ve çevre dokular arasındaki kontrastı artırmak için Bulanık Mantık ve Retinex teorisini birleştirmişlerdir. Görüntünün genel kontrastını artırmak için optimal bulanık dönüşüm kullanılmıştır. Görüntülerdeki ayrıntı bilgisini korumada optimal bulanık dönüşümün eksikliğini telafi etmek amacıyla bir parametrelili optimizasyon üyelik fonksiyonunun yeterli olmaması nedeniyle iki parametrelili bir optimizasyon üyelik fonksiyonu önerilmiş ve bu fonksiyonun parametrelerini belirlemek amacıyla uyarlamalı bir yaklaşım önerilmiştir. Deneysel sonuçlara göre bu çalışmada kullanılan yöntemin, damarlı bölge ile çevre dokular arasındaki kontrastı büyük ölçüde artırdığı gösterilmiştir (Fu ve diğ., 2010).

Gao ve diğ. (2010) çalışmalarında, PD görüntüsü üzerine odaklanmışlardır. Parmaktaki damarlı bölge ile arka plandaki dokuyu birbirinden ayırt etmek amacıyla görüntünün kontrastını artıran bir yöntem üzerinde çalışmışlardır. Çalışılan bu yöntem üç adımdan oluşmakta olup bunlar; gürültü giderme, kontrast zenginleştirme ve görüntüyü ikili resme çevirme olarak sıralanabilir. Gürültü giderme aşamasında damarlı bölge ile etrafındaki gri seviyeli bölge arasındaki ilişki dikkate alınarak gradyan ters ağırlıklı düzleştirme yöntemine (Gradient Inverse Weighted Smoothing) göre işlem yapılmıştır. Kontrast zenginleştirme adımında, geleneksel yüksek frekans filtreleme algoritması ile histogram eşitleme yöntemi birleştirilerek resimdeki kontrast artırılmıştır. Görüntünün ikili resme çevrilmesi aşamasında ise bölgeler arasındaki gri seviye farkları dikkate alınarak görüntüyü birkaç bölgeye ayırmaya dayalı bir yöntem önerilmiştir (Gao ve diğ., 2010).

Oh ve Hwang (2010), tıbbi görüntülerdeki kontrastı iyileştirmek için yeni bir morfoloji tabanlı HF tekniği önermiştir. Bu yöntem, bir görüntüyü morfolojik alt bantlara ayırarak HF uygulamak üzerine kurgulanmıştır. Her alt bant için en uygun kazancı ve yapılandırma elemanını bulmak amacıyla Diferansiyel Evrim Algoritması uygulanmış ve tıbbi görüntülerin kontrastının iyileştiği görülmüştür (Oh ve Hwang, 2010).

Yang ve diğ. (2012), PD görüntülerinin bozulmasına neden olan içsel faktörlerin analizlerini yapmış ve ışık saçılması problemini azaltmaya yönelik basit ve etkili bir görüntü geri yükleme yöntemi önermiştir. Araştırmacılar, PD görüntülerindeki bozulmaya neden olan faktörleri açıklayabilmek amacıyla canlı dokularda ışık saçılmasına dayalı biyolojik bir optik model kullanmışlardır. Yapılan çalışmada kullanılan biyolojik optik model, dokulardaki ışığın yayılma prensiplerine göre PD görüntülerindeki yayılma bileşeninin doğru bir şekilde tahmin edilebilmesini ve oluşan ışık saçılmasının kaldırılabilmesini amaçlamaktadır. Deneysel sonuçlara göre önerilen yöntem, görüntülerdeki damarlı bölgelerin kontrastını artırmış ve PD görüntülerindeki eşleşme oranını iyileştirmiştir (Yang ve diğ., 2012).

Yang ve Shi (2013) yaptıkları bu çalışmada, PD görüntülerini etkili bir şekilde iyileştirmek için ilk olarak resimdeki ışık saçılma probleminden kurtulma, yönlü filtreleme ve yanlış damar bilgisini çıkarmak amacıyla yeni bir yöntem önermişlerdir. Damarların yoğunluk ve çapındaki değişiklikleri dikkate alan bir Matlama Tabanlı Segmentasyon Algoritması (Matting-based Segmentation Algorithm) ile PD ağlarının yüksek doğruluk oranıyla otomatik olarak çıkarılması amaçlanmış ve yöntemin kabul edilebilirliği için çok sayıda deneysel çalışma yapılmıştır. Makalede yapılan çalışma PD görüntülerinin iyileştirilmesi ve segmentasyonu olmak üzere iki kısımdan oluşmaktadır. Birinci kısım olan iyileştirme aşaması görüntü restorasyonu ve özel olarak tasarlanmış bir Gabor Filtresine dayalı Yönlü Filtreleme algoritmasından oluşurken, segmentasyon bölümünde k-means ve Matlama Tabanlı Segmentasyon Algoritmaları kullanılarak segmentasyon çalışmaları yapılmıştır (Yang ve Shi, 2013).

Shin ve diğ. (2014), PD görüntülerinde meydana gelen, ışık saçılması, optik bozulma ve hareket bulanıklığı gibi nedenlerden ötürü tanıma başarısındaki düşüşün önüne geçmek amacıyla Bulanık Tabanlı bir füzyon tekniği önermişlerdir. Bu yöntemde, dört

yönlü Gabor Filtresi ve Retinex Filtresi kullanılarak FV çizgilerinin yerel ve genel özellikleri vurgulanmakta ve damar görünürlüğünü iyileştirmek için bulanık tabanlı bir füzyon tekniği önerilmektedir. Gabor ve Retinex filtrelemeden sonra elde edilen iki filtrelenenmiş görüntünün birleştirilmesi için en uygun ağırlıklara karar vermek için bulanık tabanlı bir yöntem kullanılmaktadır. Bulanık kural ve bulanık üyelik fonksiyonunun giriş parametreleri, yerel pencerelerdeki görüntülerin ortalamaları ve standart sapmaları kullanılarak hesaplanmaktadır (Shin ve diğ., 2014).

Matsuda ve diğ. (2016) tarafından, PD görüntüsü kullanılarak yapılan doğrulama çalışmalarındaki başarı oranını artırabilmek için, özellik noktalarının eşleştirilmesine dayalı bir PD doğrulama yöntemi önerilmektedir. Önerilen yöntemde, görüntü yoğunluk profillerinde bulunan eğrilikler, düzensiz gölgelendirmeye karşı sağlam bir özellik olarak öznelik noktalarının çıkarılmasında kullanılmaktadır. Öznelik noktalarının sayısını artırmak için bu noktalar, damar şeklinin doğrusal olmadığı bütün bölgelerden çıkarılmaktadır. Ayrıca yapılan çalışmada, bir parmak şekil modeli ve elastik olmayan kayıt yöntemi önerilmekte, böylelikle parmaktaki açısal değişiklik nedeniyle oluşan bozulmanın önüne geçilmektedir (Matsuda ve diğ., 2016).

Yang ve diğ. (2017) yaptıkları çalışmayla, elde edilen PD görüntülerinin düşük kalitede olması nedeniyle adaptif eğri dönüşümüne dayalı PD görüntü eşleştirme yöntemi üzerinde durmuşlardır. Bu çalışmada, damar ağlarının damar eğrisi segmentlerinden oluşması nedeniyle, eğriliği ve yönelimi değişen bir dizi Mekansal Eğri Filtresi tasarlanmaktadır. Damar eğrilerinin yerel olarak ve yakın bir şekilde uydurulabilmesi için, Mekansal Eğri Filtresi, değişken bir Gauss modeli kullanılarak ağırlıklandırılmaktadır. PD boyutları sabit olmadığı için de, ağırlıklandırılan Mekansal Eğri Filtrelerinin bu değişikliklere adapte olmasını sağlamak için etkili bir Eğri Uzunluk Alanı tahmin yöntemi önerilmektedir. Eğri Uzunluk Alanı kısıtlaması ile parmak damar ağı özelliği tanımlaması için damar vektör alanları oluşturulmaktadır (Yang ve diğ., 2017).

Meng ve diğ. (2017), parmak damarlarının tanınmasında deformasyon bilgisinin kullanılmasıyla, PD tanımaya yeni bir bakış açısı getirmektedir. PD resminde meydana gelen bozulmaları ayırt edici bilgi olarak kabul eden bu yöntemde, deformasyonların etkisini önlemeye çalışan mevcut yöntemlere göre farklılıklar bulunmaktadır. Düzenli deformasyonların sadece gerçek damar desenlerinde var olabileceği varsayımına dayanan

bu yöntemde, optimize eşleştirmeyi kullanarak deformasyonlara karşılık gelen piksel tabanlı iki boyutlu yer değiştirmeleri oluşturmak için tümleşik bir eşleştirme süreci kullanılmaktadır. Bu yöntemde, yer değiştirmelerden elde edilen birliktelik dokusu, nihai eşleştirme skoru olarak kullanılmaktadır (Meng ve diğ., 2017).

You ve diğ. (2019) yaptıkları çalışmada, PD görüntülerinde meydana gelen ışık saçılması gibi sorunları azaltmak amacıyla, yeni bir çift tabakalı restorasyon yöntemi (bi-layer restoration method) önerilmektedir. Önerilen yöntem ile PD görüntülerinde bozulmaya sebep olan içsel faktörler analiz edilmekte ve ışık saçılması azaltılarak PD resimlerinin görünürlüğü arttırılmaktadır. Önerilen çift tabakalı modelin parametrelerinin doğru bir şekilde tahmin edilmesi için blur-SURE yöntemi kullanılmakta ve ardından restorasyon performansının sağlamlığını artırmak için Multi-Wiener SURE-LET (Lineer genişletme eşikleri) yaklaşımı kullanılmaktadır (You ve diğ., 2019).

Yang ve diğ. (2020) tarafından, PD görüntülerinde çeşitli faktörler nedeniyle meydana gelen bozulmaların ve bu bozulmaların neden olduğu damar desenlerinde meydana gelen eksiklik ve kopmaların yeniden düzeltilmesi ve tamamlanması üzerine bir çalışma yapılmıştır. Bu amaçla Üretken Rakip Ağ (Generative Adversarial Network) tabanlı bir PD görüntü geri kazanım yaklaşımı önerilmektedir. PD görüntüsüne uygulanan segmentasyon ve inceltme aşamalarından sonra damar görüntüsü çıkarılmış resim, Üretken Rakip Ağ modeline giriş olarak gönderilmekte ve eksik damar desenleri yeniden onarılmaya çalışılmaktadır (Yang ve diğ., 2020).

Choi ve diğ. (2021) yapmış oldukları çalışmada, PD görüntüsünde herhangi bir nedenden dolayı meydana gelen bulanıklıkları üç gruba ayırmışlardır. Bunlar, dokuda meydana gelen ışık saçılması kaynaklı bulanıklık, lensin parmağa odaklanamamasından kaynaklanan optik bulanıklık ve parmağın sabit tutulamamasından kaynaklanan hareket bulanıklığı olarak ifade edilmektedir. Hareket bulanıklığına uğramış PD görüntülerini düzeltmek amacıyla yeniden düzenlenmiş bir DeblurGAN kullanarak yeni bir yöntem önerilmektedir (Choi ve diğ., 2021).

He ve diğ. (2023), PD görüntüsü elde edilirkenki çevre koşullarından kaynaklı, düşük sıcaklık, uygulanan aşırı basınç nedeniyle damarlarda meydana gelebilen kasılma, sıkışma gibi nedenlerden dolayı, PD resminde bozulmaların olabileceğini belirtmektedir.

Elde edilen resmin görüntü kalitesini artırmak amacıyla orijinal resmin tahmini amaçlanan Komşuluk Tabanlı İkili Modele dayalı 26 katmanlı bir üretici ağ önerilmektedir. Bu amaçla, gerçek uygulamalardan elde edilen farklı türlerde ve bozulma derecelerinde bulanık PD görüntüleri analiz edilerek, matematiksel modelleme yapan bir metot önerilmektedir (He ve diğ., 2023).

BT sistemleri alanında PD ağı kullanılarak yapılan çalışmalardaki başarı oranları ve diğer tanıma sistemlerine göre avantajları PD tanıma sistemleri üzerine olan ilgiyi artırmaktadır. PD görüntülerinden, yeni öznetelikler çıkarma, öznetelik füzyonuna dayalı PD tanıma performansının arttırılmasına yönelik araştırmalar gün geçtikçe artmaktadır. Literatürde bulunan öznetelik çıkarma yöntemleri, PD tanıma sistemlerindeki mevcut problemleri çözmeye yönelik araştırmalar ve öznetelik füzyonu kullanılarak tanıma başarısının arttırılması üzerine yapılan çalışmalar bu bölümde sunulmuştur.

Yang ve diğ. (2009), PD özelliklerini büyük oranda vurgulayabilen ve damar görüntüsü içermeyen bölgeleri büyük oranda ortadan kaldırabilen Gabor dalgacıkları ve dairesel Gabor filtresi birlikteliğine dayanan yeni bir PD çıkarma algoritması önermişlerdir. Yapılan bu çalışma ile PD ağları belirginleşmiş ve damar içermeyen bölgeler görüntüden çıkarılmıştır. İlk olarak görüntüdeki vasküler bölgeleri iyileştirmek amacıyla Gabor dalgacığı kullanılması ile başlayan süreç, daha sonra görüntü restorasyonu yapmak için kombinasyon kuralı kullanılması ile devam etmiştir. Son olarak dairesel Gabor filtresi kullanılarak görüntüdeki parmak damarları güvenilir ve etkili bir şekilde çıkarılmıştır (Yang ve diğ., 2009).

Yang ve Li (2010) yaptıkları çalışmada parmak damarlarının doğru bir şekilde yerlerinin tespit edilebilmesi ve tanınması için PD lokalizasyonu ve damar görüntüsünden öznetelik çıkarmanın zorluklarını ele alarak bu konuya çözüm getirebilmek amacıyla çalışmalar yapmışlardır. Yapılan araştırmada, parmak damarlarının yerlerinin doğru bir şekilde tespit edilebilmesi için insan parmağındaki eklemlerin birleşme bölgesinden yararlanılarak öncelikle ilgi bölgesi (ROI) belirlenmiş ve bilgi içermeyen damar bölgeleri resimden temizlenmiştir. Aynı zamanda damar görüntüleri, Yönlendirilebilir Filtreler (Steerable Filters) aracılığıyla enerji özellik serileri olarak karakterize edilmiş ve En Yakın Komşu Sınıflandırma yöntemi kullanılarak sınıflandırılmıştır (Yang ve Li, 2010).

Rosdi ve diğ. (2011) desen tanımlayıcı öznitelik çıkarma tekniklerinden birisi olan Yerel Çizgi Tabanlı İkili Desen (LLBP) kullanmışlardır. Komşuluk ilişkisi olarak kare şeklinde bir hücresel eleman kullanan Yerel İkili Desen (LBP) yönteminin aksine, LLBP yöntemindeki hücresel eleman iki boyutlu düz çizgilerden oluşmaktadır. Rosdi ve diğerlerinin yapmış oldukları çalışmaya göre, LLBP kullanarak önerilmiş olan yöntemin LBP ve Yerel Türev Deseni kullanan önceki yöntemlere göre daha başarılı sonuçlar ürettiği belirtilmiştir (Rosdi ve diğ., 2011).

Meng ve diğ. (2012) tarafından önerilen yöntemde, parmak damarlarının yerel yönlü kodlama (LDC) metodu kullanılarak tanıma yapılması ele alınmaktadır. Webber Yerel Tanımlayıcı metodundan esinlenerek yapılan çalışmada, PD tanıma için LDC adında yeni bir yönlendirme tabanlı yerel tanımlayıcı önerilmektedir. Bu yöntemde, yerel gradyan yön bilgisi sekiz açıda, sekizli sayı sistemi kullanılarak kodlanmaktadır. Önerilen yöntem, LLBP kullanan yöntemlere göre daha başarılı sonuçlar vermektedir (Meng ve diğ., 2012).

Kaur ve Mishra (2015) PD ağlarının güvenilirliğini ve etkinliğini artırmaya yönelik Tekrarlı Çizgi Takibi (RPL), Simetrik Gabor Filtresi yöntemleri temelinde Sinir Ağları ile segmentasyon işlemine dayalı bir yöntem önermişlerdir. Önerilen hibrit yaklaşımın amacı damar dokusunun tespit edilme doğruluğunu artırarak hesaplama süresini kısaltmaktır. Ön işleme aşamasında görüntü normalize edilerek ROI çıkarılmış ve morfolojik işlemler kullanılarak görüntü iyileştirme yapılmıştır. Daha sonraki aşamada damar deseninin çıkarılması için RPL ve Simetrik Gabor Filtresi kullanılmış, Sinir Ağları ile damar deseni eşleştirilerek segmentasyon gerçekleştirilmiştir. Yapılan çalışmalar sonucunda önerilen hibrit yöntemin, bu hibrit yöntemde kullanılan algoritmaların tek başlarına kullanılması durumlarına göre daha başarılı sonuçlar verdiği görülmüştür (Kaur ve Mishra, 2015).

Ma ve diğ. (2015) tarafından biyometrik veriler kullanılarak kimlik doğrulama sistemlerinin performansını artırmak üzerine ikili-model biyometri yöntemi önerilmektedir. Bu sistemde, her iki biyometri verisi için iki ayrı sınıflandırıcı tasarlanmakta, daha sonra elde edilen öznitelik vektörleri birbiri ardına birleştirilerek üçüncü bir sınıflandırıcıya gönderilmektedir. Son aşamada ise üç sınıflandırıcıdan elde edilen sınıflandırma so-

nuçları, çoklu oylama yöntemi yardımıyla karara bağlanmaktadır. Önerilen yöntemin sadece tekli model biyometri yöntemlerinde yaşanan zorlukları aşmakla kalmayıp, sistemin tanıma başarı oranında da artış sağladığı ifade edilmektedir (Ma ve diğ., 2015).

Khellat-Kihel ve diğ. (2016), farklı seviyelerde çoklu teknik metotlarının kullanılmasının başarı oranını ve güvenilirliği artıracığı fikrini benimseyerek, multimodal füzyon tekniğini önermektedir. Bu yöntem, parmak damarı, parmak eklemi izi ve parmak izinin çoklu-model füzyonunu kullanmaktadır. Sistem, özellik düzeyinde birleştirme ve karar düzeyinde birleştirme olmak üzere çoklu-model füzyonu kullanmaktadır. Ayrıca özellik seviyesindeki birleşmeyi iyileştirmek için çeşitli yöntemler uygulayarak, öznelik uzayını azaltmayı öneren bir yöntem tanıtılmaktadır (Khellat-Kihel ve diğ., 2016).

Sikarwar ve Manmohan (2016) yaptıkları çalışmada, güvenilir bir PD tanıma sistemi için Yerel Yönlü Desen (LDP) yönteminin farklı teknikleri analiz edilmektedir. LDP, piksel konumları dikkate alınarak sekiz yönde kenar tepkisini hesaplamak için kullanılmaktadır. Ayrıca, sınıflandırma doğruluğu ve Eşit Hata Oranı açısından en iyi sonucu elde etmek ve gürültüye duyarlı olan LBP'nin kısıtlamalarını ortadan kaldırmak için farklı türlerde yerel yönlendirme desenleri kullanılarak PD tanıma yöntemi açıklanmaktadır (Sikarwar ve Manmohan, 2016).

Babu ve diğ. (2017), PD ve düşük çözünürlüklü parmak izi görüntülerinin aynı anda elde edildiği ve bu iki biyometrik verinin yeni bir skor düzeyi birleştirme stratejisi kullanılarak birleştirildiği bir yöntem önermektedirler. Bu çalışmada, bütünsel ve doğrusal olmayan füzyon olmak üzere iki yeni skor ölçekli birleşim yöntemi geliştirilmekte ve daha popüler skor ölçekli füzyon yaklaşımlarıyla sonuçlar karşılaştırılmıştır (Babu ve diğ., 2017).

JosephP ve Ezhilmaran (2018) yaptıkları çalışmayla, PD tanıma sistemlerinin performansını artırmak için yeni bir akıllı hesaplama algoritması sunmuşlardır. Bu çalışmada, bulanık görüntü alma yoluyla PD çevresindeki, afin değişmez öznelik eşleştirme (affine invariant feature matching) etkinliği incelenmektedir. Afin değişmez özneliklerin hesaplama süresini en aza indirmek için, bulanık tabanlı görüntü geri alımıyla, veri tabanı boyutunun küçültülmesi sağlanmaktadır. Çalışmadaki deneysel sonuçlara göre,

mevcut öznitelik eşleştirme algoritmalarına kıyasla, erişimden sonra daha iyi performans ve çok daha düşük hata oranları göstermektedir (JosephP ve Ezhilmaran, 2018).

Ma ve Zhang (2019) tarafından, PD desenlerine dayalı olarak ilgili bölgelerin ve yönlendirilmiş elementlerin çıkartılmasını içeren yeni bir teknik önerilmektedir. Yapılan çalışmada, PD görüntülerinin elde edilmesi sırasında parmağın döndürülme ve öteleme etkilerini azaltmak için döndürme düzeltmesine dayalı bir ROI seçilmektedir. Yönlendirme özelliğini çıkarmak için, PD görüntülerindeki doku ve kararlı yönlendirme özellikleri kullanılmaktadır. Bunun için, bulanık segmentasyon bölgesindeki PD çizgileri boyunca noktaların gradyan büyüklüğü ve yönleri hesaplanmaktadır. Çıkarılan özniteliklerden elde edilen sonuçlar, geometrik deformasyon sorununu çözmede etkili olduğunu göstermektedir (Ma ve Zhang, 2019).

Yang ve diğ. (2019), Polarize Derinlik Ağırlıklı İkili Yön Kodlaması (PWBDC) isimli yeni bir öznitelik çıkarma yöntemi önermektedir. Ayrıca tek kamera yardımıyla hem PD, hem de parmak sırt doku görüntüsünün alındığı bir sistem önerilmektedir. Yapılan çalışmaya göre, PWBDC üç bileşen içermektedir: polarize yön çıkarımı, genişletilmiş normalleştirilmiş açısız ikili kodlama ve kendi kendini uyarlayan derinliğe bağlı ağırlıklandırma. Deneysel sonuçlar, önerilen sistemin ve özniteliğin hem depolama ve hesaplama açısından tasarruflu olduğunu, hem de tanımlama için etkili olduğunu göstermektedir (Yang ve diğ., 2019).

Yong (2020) yapmış olduğu çalışmada, PD öznitelik çıkarma, eşleştirme ve tanıma algoritması önermekte ve PD tanıma sistemi tasarlamaktadır. Bu sistem, parmak damar görüntüsü alma cihazı, görüntü işleme modülü ve eşleştirme olmak üzere üç modülden oluşmaktadır. Yong tarafından önerilen öznitelik çıkarma yönteminde, görüntünün Hessian matrisinin öz değerleri hesaplanarak özniteliği çıkarmak için bir eğrilik algoritması önerilmiştir (Yong, 2020).

Lu ve diğ. (2021) tarafından, FV görüntüsünün özelliklerine bağlı olarak yeni bir ROI çıkarma yöntemi önerilmektedir. Önerilen yöntemde üç yenilik bulunmaktadır. Bunlar, ek ağırlıklara sahip yatay bir Sobel operatörü, parmak çevresi görüntüleme özelliklerine dayalı bir kenar tespit yöntemi ve geniş alıcı alana dayalı bir gradyan tespit operatörü.

ROI çıkarma sonuçları, önerilen yöntemin farklı kalitedeki görüntüler için literatürde bulunan diğer yöntemlere göre daha tutarlı sonuçlar verdiğini göstermektedir (Lu ve diğ., 2021).

Jin ve diğ. (2021) tarafından yapılan çalışmada, damarsız bölgelerin tanımlama sürecindeki etkisini en aza indirmek amacıyla ikili resim temeline dayanan bir algoritma önerilmektedir. Hızlandırılmış segmentasyon testi algoritmasından sonra öznitelik noktaları tespit edilmekte ve bu öznitelik noktaları gradient histogramı kullanılarak vektörel bir şekilde tanımlanmaktadır. Aynı zamanda, dairesel eşleştirme komşuluk kavramı önerilmekte ve bu alanda eşleşen öznitelik nokta çiftleri seçilmektedir. Ardından, Öklid mesafe ve doğru eşleşen çiftlerin sayısı, algoritmanın tanıma oranını artırmak için kapsamlı bir şekilde değerlendirilmektedir (Jin ve diğ., 2021).

Zhang ve diğ. (2022), Evrişimli Sinir Ağlarındaki (CNN), yüksek hesaplama karmaşıklığı, büyük parametreler gibi zorlukları çözmek için alıcı alan (receptive fields) özelliklerine sahip bir Gabor Evrişimli Sinir Ağı (GCNN) önermektedir. Ayrıca, Gabor evrişimli katmanını tasarlamak için alıcı alan özelliklerine sahip Gabor Filtre kullanılmaktadır. Daha sonraki adımda, geleneksel evrişim katmanı, Gabor evrişim katmanıyla değiştirmekte, farklı kayıp fonksiyonlarının, evrişim çekirdek boyutunun ve özellik boyutunun ağ modeli üzerindeki etkisi analiz edilmekte ve en uygun model parametreleri ve kayıp fonksiyonu seçilmektedir. Son olarak, farklı PD veri setlerinde Adaptif Gabor Evrişimli Sinir Ağları (AGCNN) ve CNN'leri kullanarak başarı performansı belirlenmektedir (Zhang ve diğ., 2022b).

Feng ve diğ., (2022), Temel Bileşen Analizi ve Yerel Koruma Projeksiyonları tekniklerini birleştiren ve görüntünün hem genel hem de yerel özelliklerini koruyucu bir projeksiyon matrisi oluşturan, yeni bir özellik çıkarım yöntemi olan Temel Bileşen Analizi ve Yerel Koruyucu Projeksiyonlar (PCLPP) yöntemini önermektedir. Yapılan çalışmalar, PCLPP PD tanıma tekniğiyle çıkarılan öznitelik vektörü kullanılarak yapılan sınıflandırma doğruluğunun, hem Temel Bileşen Analizi hem de Yerellik Koruma Projeksiyonlarından daha başarılı sonuçlar ürettiğini göstermektedir. Ayrıca, PCLPP'nin Temel Bileşen Analizi ve Yerellik Koruma Projeksiyonlarına kıyasla gürültüden daha az etkilendiği belirtilmektedir (Feng ve diğ., 2022).

Bu tez çalışması kapsamında, PD görüntülerindeki gürültülerin giderilerek görüntü kalitesinin artırılması ve PD tanımada kullanılmak üzere yeni tanımlayıcı özniteliklerin çıkarılması konusunda çalışmalar gerçekleştirilmiştir.



3. MATERYAL VE YÖNTEM

3.1. Parmak Damar Veri Setleri

Yakın zamanlarda araştırmacılar 740-960 nm dalga boyu aralığındaki kızılötesi ışınların insan derisinden geçebildiğini ve damar içindeki hemoglobinin tarafından emildiğini keşfetmişlerdir. Bu nedenle, kızılötesi ışının yansıması, damarların bulunduğu bölgelerde çevresine göre daha az olmakta dolayısıyla damarlı bölgeler daha koyu görünmektedir. Böylece, kızılötesine duyarlı CCD kameralar kullanılarak damar görüntülerinin elde edilmesi mümkün hale gelmiş ve araştırmacılar çalışmalarını yapmak üzere veri setleri oluşturmaya başlamışlardır (Luo ve diğ., 2010). Veri setlerinin oluşturulma sürecinde, PD görüntüsü elde edilirken kullanılan düzeneğin genel yapısı Şekil 3.1’de verilmiştir.



Şekil 3.1. PD görüntüsü elde etme mekanizması


Geliştirilen öznetelik çıkarma yönteminin, PD tanıma sistemlerinin başarısına yapmış olduğu katkıyı test etmek ve sonuçlarını literatürde yapılan çalışmalar ile karşılaştırmak amacıyla, tez çalışmasında kullanılmak üzere iki farklı veri seti üzerinde çalışmalar yapılmıştır.

3.1.1. Yang veri seti

Tez çalışmasında kullanılan Jinfeng Yang tarafından Meijing Wu aracılığıyla sağlanan PD görüntüleri içeren Yang (VS1) olarak isimlendirdiğimiz veri seti 64 sınıftan oluşmaktadır. Her sınıf 15 adet örnek PD görüntüsünden oluşmaktadır ve resimler 170x80 piksel boyutlarına ölçeklenmiştir. Örnek PD görüntüleri için deneklerin işaret parmakları kullanılmıştır. Veri seti, *.jpg formatında kaydedilmiş toplamda 960 resimden oluşmaktadır. Yang ve diğ. tarafından oluşturulan veri setindeki PD görüntüleri, 760 nm dalga

boyuna sahip NIR ışık kaynakları ve kızılötesi ışınlara duyarlı 1 adet CCD kamera kullanılarak elde edilmiştir (Yang ve Li, 2010).

Şekil 3.2’de VS1’de bulunan farklı sınıflara ait örnek birer resim gösterilmiştir. Resimlerden anlaşılacağı üzere veri setindeki resimler farklı kontrast değerlerine sahip olmakla birlikte, aynı zamanda resimdeki damarlı bölgelerin ayırt edilmesini zorlaştıran ışık saçılmaları da içermektedir. Veri setinde bulunan görüntülerin, sabit şiddetteki NIR ışık kaynağından gönderilen ışının farklı yapı, yoğunluk veya karakteristik özellikteki dokudan geçerek kameraya ulaşması nedeniyle oluşan ışık saçılmaları içermesi, damarlı bölgelerin doğru olarak ayırt edilmesini zorlaştıran önemli etkenlerdendir. Bu sorunları ortadan kaldırmak amacıyla ön işleme aşamasında çalışmalar yapılmıştır.



Şekil 3.2. VS1’de farklı sınıflara ait örnek PD resimleri


3.1.2. MNCBNU_6000 veri seti

Chonbuk National Üniversitesi Elektronik ve Bilişim Mühendisliği Bölümü Multimedya Laboratuvarı’ndaki araştırmacılar tarafından taşınabilir ölçülerde 850 nm dalga boyuna sahip kızılötesi led ışık kaynakları ve kızılötesine duyarlı kameradan oluşan bir PD görüntüleme cihazı geliştirilmiş ve geliştirilen taşınabilir cihaz ile MNCBNU_6000 veri seti (VS2) oluşturulmuştur. VS2 oluşturulurken kullanılan 100 gönüllü bireyin her birinin sol ve sağ ellerinin işaret parmağı, orta parmak ve yüzük parmaklarının PD görüntüleri alınmıştır. Böylelikle her gönüllünün altı farklı parmağının her birinden 10’ar resim alınarak bir kişiden 6 sınıf olmak üzere toplamda 60 görüntü elde edilmiştir. Dolayısıyla 100 gönüllüden 600 sınıf oluşturulmuş ve her sınıfta 10 resim olmak üzere toplamda 6000 resimden oluşan VS2 elde edilmiştir. Elde edilen her bir örnek görüntü 480x640 piksel

boyutlarında olup resimler *.bmp formatında kaydedilmiştir. Daha sonra elde edilen görüntüler kullanılarak ROI çıkarılmış ve 60x128 piksel boyutlarına normalize edilmiştir (Lu ve diğ., 2013).

VS2 farklı amaçlar için kullanılabilen bir veri setidir. Bu veri seti 100 sınıf olarak düşünülecek olursa, 6 farklı parmaktan elde edilen 60 PD görüntüsü tek bir sınıf olarak kabul edilerek çalışmalar yapılabilir. Ancak bu tez çalışmasında sınıf sayısını çoğaltmak amacıyla her bir parmaktan elde edilen görüntüler bir sınıf kabul edilmiş ve 6000 resimden oluşan 600 sınıflık bir veri seti olarak uygulamalar gerçekleştirilmiştir.

Şekil 3.3’de aynı bireyin 6 farklı parmağına ait PD görüntüsü verilmektedir. Tablonun üst tarafındaki görüntüler, aynı bireyin sol elinin sırasıyla işaret, orta ve yüzük parmaklarına ait resimleri gösterirken, alt taraftaki görüntüler ise sağ elinin işaret, orta ve yüzük parmaklarına ait resimleri göstermektedir. Bu çalışmada, her parmaktan alınan 10’ar görüntü tek sınıf, bir bireyin altı parmağından alınan görüntüler ise 6 farklı sınıf olarak kabul edilmekte ve Şekil 3.3’de farklı sınıflardan örnek gösterilmektedir.



Şekil 3.3. VS2’de aynı bireyin farklı parmaklarına ait örnek PD resimleri

3.2. Ön İşleme Adımları

3.2.1. Homomorfik filtre

Homomorfik Filtre, görüntü işleme problemlerinde özellikle ön işleme adımı olarak kullanılan filtreleme algoritmalarından biridir. Bu algoritma, özellikle düşük aydınlatmanın ve yansımanın olduğu ortamlarda çekilen görüntülerdeki yerel dengesizliklerden kurtularak, görüntülerdeki kontrastı artırmak için dijital görüntü işlemede, iyileştirme ve yeniden yapılandırma işlemleri için kullanılmaktadır (Ponomarev ve Pogrebnik, 1995). Resimde meydana gelen yerel dengesizlikler, genellikle resmi çekilen nesnenin bir kısmının

güçlü bir şekilde aydınlatılırken diğer kısmının yetersiz aydınlatılması, yani aydınlatmanın homojen bir şekilde yapılamaması durumlarında ortaya çıkmaktadır. Bu durum, aydınlatmadan da kaynaklanabileceği gibi ışık kaynağı altında resmedilen nesnenin özelliğine de bağlı olabilmektedir. Özellikle canlı dokular, yapıları gereği büyük oranda homojen olmayan optik bir ortama sahip olmalarından dolayı, içinden geçen ışınların kaydedildiği doku resimlerinde çok fazla ışık saçılmalarına neden olabilmektedir (Oh ve Hwang, 2010).

Homomorfik konsepti, MIT üniversitesinde yapılan zaman serisi çalışmalarından yola çıkılarak Bogert ve diğ. (1963) tarafından geliştirilen bir yaklaşımdır (Oppenheim ve Schafer, 2004). Denklem 3.1’de gösterildiği şekliyle Homomorfik Filtrede kabul edilen yaklaşıma göre, Dijital bir resimdeki ışık dağılımı, ışık kaynağından gönderilen ışık ile nesneden yansıyan ışığın çarpımı şeklinde tanımlanan bir teoriye dayanmaktadır. Denklem 3.1’deki formülde bulunan $Işık(x, y)$ aydınlatma işlevini gören ışık kaynağının yoğunluğunu, $r(x, y)$ ise nesneden geçerek kameraya ulaşan ışık miktarının 0 ile 1 arasındaki yansımalarını ifade etmektedir.


$$Resim(x, y) = Işık(x, y) * r(x, y) \quad (3.1)$$

Homomorfik Filtreleme, görüntülerdeki alçak frekans bileşenlerini azaltırken, yüksek frekans bileşenlerini artırma temeline dayanmaktadır. Böylelikle resimdeki keskin kenar bilgileri daha görünür hale gelmekte, düz yüzeyler ise baskılanmaktadır. Denklem 3.2’de gösterildiği gibi yeni bir görüntü formülü tanımlanarak, yapılmak istenilen işlem matematiksel olarak formüle edilmektedir. Denklem 3.2’de $\ln(I)$ ile tanımlanan yeni görüntü tanımına göre $\ln(l)$ düşük geçirgenliği, $\ln(\rho)$ yüksek geçirgenliği ifade etmekte ve görüntüye logaritmik dönüşüm uygulanarak, $Resim I = \ln(Resim(x, y))$ doğrusal bir filtre ile seçici olarak filtrelenebilen gürültü içeren bir resim şeklinde formüle edilmektedir (Shahamat ve Pouyan, 2014).

$$\ln(I) = \ln(l) + \ln(\rho) \quad (3.2)$$

Aydınlatmanın düşük geçiş karakteristiğine sahip olduğu varsayıldığından, farklı ışık kaynaklarından yapılan aydınlatmalardan en iyi sonucun alınabilmesi için, filtrenin yeterince yüksek geçirgenlik özelliğine sahip olarak tasarlanması gerekmektedir (Al-amri

ve diğ., 2010). Şekil 3.4’de akış şeması verilen Homomorfik Filtre incelenecek olursa, ilk olarak resmin logaritmik dönüşümü yapılmakta, daha sonra zaman domaininden frekans domainine geçiş yapabilmek için, resmin Fourier Dönüşümü alınmaktadır. Frekans domainine geçiş yapıldıktan sonra yüksek frekans değerlerini, yani resimdeki keskin ton değişimlerini ve kenar bilgilerini korumak adına resme Yüksek Geçirgen Filtre uygulanmaktadır. Böylelikle resimdeki düşük frekans bilgileri azaltılmış olmaktadır. Ters Fourier Dönüşümü uygulayarak frekans domaininden yeniden zaman domainine geçiş yapılmakta ve resmin ters logaritmik dönüşümü yapılarak işlenmiş resim elde edilmektedir.



Şekil 3.4. Homomorfik filtre akış şeması

3.2.2. Perona-Malik anizotropik difüzyon

Dijital resimdeki yumuşatma, bir difüzyon işleminin sonucudur. Fick yasasından türetilen difüzyon süreçleri, verileri bozmadan konsantrasyon farkını dengeleyen fiziksel bir süreçtir (Flynn ve diğ., 1974). Perona-Malik Anizotropik Difüzyon en temel haliyle, veri içeriğine bağlı olarak değişen bir yumuşatma filtresi olarak tanımlanmaktadır (Weickert, 1998). PMAD görüntüdeki farklı yapısal özelliklere farklı derecelerde filtreleme uygulayarak gürültüyü azaltırken kenar bölgelerini korumakta ve aynı zamanda veri içeriğinin önemli kısımlarını koruyarak yüksek frekans bileşenlerini azaltmaktadır. Difüzyon eşitliği, Denklem (3.3)’de gösterilmektedir.

$$\frac{\partial u}{\partial t} = \frac{\partial}{\partial x} \left(C \cdot \frac{\partial}{\partial x} u \right) \quad (3.3)$$

Denklem (3.3)’de ifade edilen C sabiti difüzyon katsayısını gösterirken, giriş verisi ise u ifadesi ile temsil edilmektedir. Difüzyon katsayısı görüntünün farklı yapısal özelliklerine bağlı olarak 0 ile 1 arasında değişmektedir. Difüzyon katsayısı olarak ifade

edilen C değerinin 1'e eşit olması durumunda PMAD algoritması, Lineer Difüzyon Filtresi gibi davranmakta ve bu durumda difüzyon eşitliği, Denklem (3.4)' de gösterildiği gibi olmaktadır (Perona ve Malik, 1990).

$$\frac{\partial u}{\partial t} = \frac{\partial^2}{\partial x^2} u \quad (3.4)$$

C ile ifade edilen difüzyon katsayısı, görüntünün farklı yapısal özelliklerine bağlı olarak değişmekte ve bu değişim difüzyona etki etmektedir. Difüzyon esnasında işlem penceresi, resimdeki verilerin önemli kısımlarına yaklaşması durumunda C difüzyon katsayısı 0 değerine yakınsamakta, dolayısıyla Denklem (3.3)'e göre resmin kenar bölgeleri gibi önemli yerlerindeki kayıplar en aza indirgenmektedir. Difüzyon katsayısı C 'nin değeri, Denklem (3.5)'deki eşitlik ile bulunmaktadır. Denklem (3.6) ve (3.7) incelendiğinde, difüzyon katsayısının, görüntünün gradyanı ve eşik değeri ile ilişkili olduğu görülmektedir. Gradyan, resimdeki bir pikselin yoğunluğunda meydana gelen değişimin büyüklüğünü ve yönünü ifade etmektedir ve pikselin etrafındaki diğer komşu piksellerin yoğunluk değerleriyle karşılaştırılarak hesaplanmakta ve Denklem (3.6) ve (3.7)'de formüle edilmektedir.

$$C = g\left(\frac{\partial}{\partial x} u\right) \quad (3.5)$$

Zaman adımı olarak ifade edebileceğimiz t , algoritmanın her bir iterasyonda görüntünün güncelleme miktarını belirler. Daha küçük bir t demek daha yavaş ve hassas bir güncelleme anlamına gelmektedir.

$$\frac{\partial u}{\partial t} = \frac{\partial}{\partial x} \left(g\left(\frac{\partial}{\partial x} u\right)^2 \right) \quad (3.6)$$

Denklem (3.7) ile gösterilen PMAD algoritmasındaki Lamda (λ) eşik değeri, difüzyon katsayısının hesaplanması için kullanılmakta ve ileri difüzyon bölgelerini geri difüzyon bölgelerinden ayıran bir kontrast parametresi olarak ifade edilmektedir.

$$g\left(\frac{\partial}{\partial x}u\right) = \frac{1}{\left(1 + \left(\frac{\left(\frac{\partial}{\partial x}u\right)^2}{\lambda^2}\right)\right)} \quad (3.7)$$

3.3. Segmentasyon ve Son İşleme Adımları

3.3.1. Niblack segmentasyon algoritması

Niblack Segmentasyon, dijital görüntü işlemede yerel uyarlanabilir eşikleme yöntemi olarak kullanılan bir tekniktir (Niblack, 1986). Bu algoritma, bir çeşit çok eşikli segmentasyon yöntemi kullanmakta ve eşik değerleri Denklem (3.8)'de de gösterildiği gibi yerel ortalama ve yerel standart sapma değerlerine bağlı olarak her piksel için ayrı ayrı hesaplanmaktadır. Denklem (3.8)'de bulunan $\mu(i, j)$, ilgilenilen işlem penceresindeki piksellerin yerel ortalamasını gösterirken, $\sigma(i, j)$, kullanıcı tarafından boyutu belirlenen (i, j) işlem penceresi içinde kalan piksellerin yerel standart sapmasını ve k değeri ise kullanıcı tarafından $[-1, 1]$ arasında seçilen ve algoritmanın çalışma hassasiyetini belirten sabit bir değeri göstermektedir. Denklem (3.8)'de $T(i, j)$ ile gösterilerek hesaplanan yerel eşik değerine göre, ilgili piksel olan (i, j) , 0 veya 1 değerini alarak resimdeki bölgeler otomatik olarak ayrıştırılır.

$$T(i, j) = \mu(i, j) + k \cdot \sigma(i, j) \quad (3.8)$$

Niblack Segmentasyon algoritmasının ana fikri, pikselin yerel bölgesindeki kontrastın ve aydınlatmanın ölçüsü olan yerel istatistikî öznitelikleri kullanarak resimlerin sınıflandırılmasının sağlanmasıdır. Bu algoritmanın işlem adımları:

1. Resim içerisindeki her bir piksel için problemin niteliğine göre işlem penceresi seçilir. Burada dikkat edilmesi gereken nokta, seçilen işlem pencere boyutunun resimdeki detayları kaybetmeyecek kadar küçük olması gerekirken, resimdeki gürültüleri bastıracak kadar büyük olması gerektiğidir.
2. İşlem penceresi içerisinde kalan piksellerin ortalaması ve standart sapması hesaplanır.

3. Her işlem penceresi için yerel eşik değeri, kullanıcı tarafından girilecek k sabitine göre Denklem (3.8)'deki formül kullanılarak hesaplanır.
4. Bulunan eşik değeri, işlem penceresi içerisindeki merkez pikselin değeri ile karşılaştırılarak büyük ya da küçük olma durumuna göre merkez pikselin yeni değeri 1 ya da 0 olarak atanır.
5. Bu adımlar, tüm pikseller bitene kadar işlem penceresi resimdeki pikseller üzerinde gezdirilerek tekrarlanır.

3.3.2. Morfolojik işlemler

Görüntü işlemede kullanılan morfolojik işlemler, görüntülerdeki şekilsel veya yapısal özelliklerin analiz edilmesi ve değiştirilmesi için kullanılan temel yöntemlerdir. Morfolojik işlemler, piksel düzeyinde yapılan basit matematiksel operasyonlarla gerçekleştirilmekte ve genellikle şekil tabanlı analiz, kenar belirleme, iskelet çıkarma, gürültü giderme, görüntü segmentasyonu, nesne tespiti gibi birçok işlemde yaygın olarak kullanılmaktadır. Yapısal bir eleman kullanılarak gerçekleştirilen matematiksel işlemler sırasında kullanılacak yapısal elemanın şekli ihtiyaca göre kare, dikdörtgen, daire, düz çizgi vs. olarak belirlenebilmektedir. Yapısal eleman tüm görüntü üzerinde gezdirilerek morfolojik işlemler tamamlanmaktadır (Woods ve Gonzalez, 2008).

Morfolojik işlemler temel olarak Aşındırma ve Genişletme olarak ifade edilen iki yöntem üzerine kurulmaktadır. Diğer yöntemler Aşındırma ve Genişletme işlemlerinin belli kurallar çerçevesinde birlikte uygulanmasıyla elde edilmekle birlikte açma, kapama vs. olarak isimlendirilmektedir.

3.3.2.1. Aşındırma (Erosion)

Aşındırma işlemi, bir görüntüdeki nesnelerin boyutlarının küçültülmesi, resimdeki gürültülerin giderilmesi, nesnelerin birbirlerinden ayrıştırılması, nesne kenarlarının inceltilmesi vs. gibi amaçlar için kullanılmaktadır. Yapısal elemanın tüm resim üzerinde dolaştırılması sonucu resmin yapısal elemanla tam olarak uyuşmaması durumlarında merkez pikselin değerinin 0 olarak belirlenmesi, tam uyuşması durumunda merkez piksel değerinin 1 olarak ifade edilmesi şeklinde uygulanmaktadır (Woods ve Gonzalez, 2008).

3.3.2.2. Genişletme (Dilation)

Görüntü işleme algoritmalarında kullanılan morfolojik işlemlerden olan Genişletme ise, görüntü içindeki nesneleri büyütme, birbirlerinden kopmuş olan nesneleri birleştirme, nesne içerisinde oluşan boşlukları doldurma, nesne kenarlarını kalınlaştırma vs. gibi amaçlar için kullanılmaktadır. Özet olarak, resim üzerinde dolaştırılan yapısal elemanın merkez piksel değerinin resimde işlem gören piksel ile aynı olması durumunda yapısal elemandaki değerlerin resme işlenmesi şeklinde ifade edilmektedir (Woods ve Gonzalez, 2008).

3.3.2.3. Açma (Opening)

Açma işlemi, Aşındırma yöntemi ile nesneleri küçülterek başlamakta, ardından Genişletme işlemi ile nesnelerin yeniden eski boyutlarına getirilmesini sağlayarak resimdeki birbirlerine zayıf bağlarla bağlanmış nesneleri birbirlerinden ayırma, keskin ya da sivri köşe çizgilerini törpüleme veya çıkıntılı kenar çizgilerini yumuşatma gibi amaçlar için kullanılmaktadır. Açma işlemi daha çok dışbükey köşelerde törpüleme yaparak yumuşatma işlemi gerçekleştirmektedir (Woods ve Gonzalez, 2008).

3.3.2.4. Kapama (Closing)

Morfolojik işlemlerden Kapama işlemi ise, Genişletme yöntemi ile ilk olarak görüntüdeki nesneleri büyütme başlamakta ve devamında Aşındırma yöntemi uygulanarak büyütülen nesnelerin yeniden orijinal boyutlarına getirilmesini sağlamaktadır. Kapama işlemi, nesne içindeki gürültü niteliğindeki küçük boşlukların doldurulması, birbirlerine kuvvetli ve yakın bağlarla bağlanmış nesnelerin birleştirilmesi, içbükey köşelerde doldurma işlemi yaparak köşe geçişlerinin yumuşatılması ve kenar çizgilerindeki boşlukların azaltılması gibi amaçlar için kullanılmaktadır (Woods ve Gonzalez, 2008).

3.4. Öznitelik Çıkarma Yöntemleri

3.4.1. Gri seviye çalışma uzunluğu matrisi (GLRLM)

GLRLM, görüntünün doku gibi yapısal özelliklerinin analiz edilmesini sağlayan bir yöntemdir. Bu yöntem, görüntüdeki gri seviye değerlerinin ardışık sıralanışlarını ve uzunluklarını analiz ederek farklı öznitelikler elde etmeyi sağlar. Bir başka ifadeyle GLRLM, gri seviye değerlerinin sayısını ve ROI bölgesinde bulunan belirli yönlerdeki ardışık piksel gruplarının yoğunluk değerlerini ve uzunluklarını bularak oluşturulan iki boyutlu bir matristir. Matrisin her bir elemanı, görüntü üzerinde belirli bir yoğunluk değeri ve belirli bir uzunluğa sahip ardışık grupların sayısını ifade eder.

Bir gri seviye çalışması, ROI içerisinde sisteme tanımlanmış yönlerdeki ardışık ve eş doğrusal olarak dağıtılan aynı gri değere sahip bir piksel kümesi olarak ifade edilebilir. Gri seviye çalışmasının uzunluğu, belirli bir ROI içinde sayılarak hesaplanan piksel sayısını ifade eder (Tang, 1998; Zhang ve diğ., 2020). Resim için ifade edilen $P(i, j | \theta)$, piksel gri seviyesi i için θ açısal doğrultusunda arka arkaya j kez tekrarlanan oluşumların sayısını verir. GLRLM oluşturulurken, her görüntü için $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° açılarında dört yönde hesaplama yapılır.

GLRLM algoritmasının işlem adımları:

1. Gri seviye resim üzerinde belirli bir gri seviye ölçeklendirmesi seçilerek ölçekleme gerçekleştirilir.
2. Ölçeklenen görüntü üzerinde $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° açısal yönlerde tarama yapılır.
3. Tarama yönünde ardışık piksel grupları bulunur. Bu gruplar, aynı gri seviye ölçeğindeki piksellerin yan yana gelmesiyle oluşan gruplardır. Her bir ardışık piksel grubunun uzunluğu ve yoğunluk değeri bulunarak GLRLM matrisi oluşturulur.
4. Her açı için ayrı ayrı incelenen sonuçlara göre oluşturulan GLRLM matrisiyle bu işlemler tekrarlanır.
5. Oluşturulan GLRLM matrisi üzerinden istatistiksel öznitelikler hesaplanarak öznitelik vektörü çıkarılır.

GLRLM matrisi kullanılarak çıkarılan ve literatüre giren bazı öznitelik çıkarma yöntemleri ve metrikleri bulunmaktadır. Elde edilen öznitelikler, görüntünün farklı yapısal özelliklerini temsil etmekte ve tercih edilmektedir. Bu tez çalışmasında kapsamında kullanılan GLRLM özniteliklerini şu şekilde sıralayabiliriz.

Mary tarafından GLRLM kullanılarak beş adet çalışma uzunluğu özniteliği çıkarılmıştır (Mary, 1975). Öznitelik çıkarma denklemlerinde kullanılan N_{GL} resimdeki gri seviye sayısını, N_{RL} maksimum çalışma uzunluğunu, n_r toplam çalıştırma sayısını ve n_p ise resimdeki toplam piksel sayısını ifade etmektedir. Bu GLRLM öznitelikleri şu şekilde sıralanabilir: Kısa Koşu Vurgusu (Short Run Emphasis), Uzun Koşu Vurgusu (Long Run Emphasis), Gri Seviye Düzensizliği (Gray Level Nonuniformity), Koşu Uzunluğu Düzensizliği (Run Length Nonuniformity), Koşu Yüzdesi (Run Percentage).

$$Kısa Koşu Vurgusu = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} \frac{P(i, j \mid \theta)}{j^2} \quad (3.9)$$

$$Uzun Koşu Vurgusu = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} P(i, j \mid \theta) \cdot j^2 \quad (3.10)$$

$$Gri Seviye Düzensizliği = \sum_{i=0}^{N_{GL}-1} \left(\sum_{j=1}^{N_{RL}} P(i, j \mid \theta) \right)^2 \quad (3.11)$$

$$Koşu Uzunluğu Düzensizliği = \sum_{j=1}^{N_{RL}} \left(\sum_{i=0}^{N_{GL}-1} P(i, j \mid \theta) \right)^2 \quad (3.12)$$

$$Koşu Yüzdesi = \frac{n_r}{n_p} \quad (3.13)$$

Chu ve diğ. 1990 yılında yaptıkları çalışmayla, gri seviye değerinin etkisini daha fazla ön plana çıkarma fikrine dayalı iki adet çalışma uzunluğu istatistiği çıkarmışlardır (Chu ve diğ., 1990). Bu öznitelikler şu şekilde sıralanabilir: Düşük Gri Seviye Koşu Vurgusu (Low Gray Level Run Emphasis), Yüksek Gri Seviye Koşu Vurgusu (High Gray Level Run Emphasis).

$$\text{Düşük Gri Seviye Koşu Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} \frac{P(i, j \mid \theta)}{i^2} \quad (3.14)$$

$$\text{Yüksek Gri Seviye Koşu Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} P(i, j \mid \theta) \cdot i^2 \quad (3.15)$$

Edwin ve Belur, bir görüntünün dokusunun daha detaylı çıkarılmasına yardımcı olan dört yeni GLRLM öz niteliği çıkararak literatüre kazandırmışlardır (Belur ve Edwin, 1991). Mevcut özelliklere ilave olarak çıkarılan yeni GLRLM öz nitelikleri şu şekilde sıralanmaktadır. Kısa Koşu Düşük Gri Seviye Vurgusu (Short Run Low Gray Level Emphasis), Kısa Koşu Yüksek Gri Seviye Vurgusu (Short Run High Gray Level Emphasis), Uzun Koşu Düşük Gri Seviye Vurgusu (Long Run Low Gray Level Emphasis), Uzun Koşu Yüksek Gri Seviye Vurgusu (Long Run High Gray Level Emphasis).

$$\text{Kısa Koşu Düşük Gri Seviye Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} \frac{P(i, j \mid \theta)}{i^2 \cdot j^2} \quad (3.16)$$

$$\text{Kısa Koşu Yüksek Gri Seviye Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} \frac{P(i, j \mid \theta) \cdot i^2}{j^2} \quad (3.17)$$

$$\text{Uzun Koşu Düşük Gri Seviye Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} \frac{P(i, j \mid \theta) \cdot j^2}{i^2} \quad (3.18)$$

$$\text{Uzun Koşu Yüksek Gri Seviye Vurgusu} = \sum_{i=0}^{N_{GL}-1} \sum_{j=1}^{N_{RL}} P(i, j \mid \theta) \cdot i^2 \cdot j^2 \quad (3.19)$$

Böylelikle bu çalışmada, GLRLM kullanılarak elde edilen 11 adet öz nitelik açıklanmıştır. Öz nitelik değerleri ve toplam öz nitelik sayıları, her açısall yönde farklı olacağından dolayı, kullanılan θ açısall yön sayısı ile öz niteliklerin sayısını çarparak toplam öz nitelik sayısını çoğaltmak mümkündür.

3.4.2. Gri seviye eş oluşum matrisi (GLCM)

İlk olarak Haralick ve Shanmugam tarafından geliştirilen GLCM, bir görüntüdeki piksellerin gri seviye değerlerinin birbirleriyle ilişkilerini, istatistiksel özellikler kullanarak tanımlayan, ikinci dereceden bileşik durum olasılık yoğunluk fonksiyonları tahminine dayanan bir öznitelik çıkarma yöntemidir (Haralick ve diğ., 1973). Bu yöntem, piksellerin yoğunluk değerleri arasındaki ilişkiden çıkarılan istatistiksel özellikleri kullanmaktadır. Genel olarak bir görüntünün yapısı ile nesneler arasındaki ilişkinin, görüntüdeki gri tonların birbiriyle olan uzamsal ilişkisinde saklı olduğu varsayımına dayanmaktadır. Dolayısıyla bir görüntünün yapısı ve dokusu hakkında bilgi sahibi olmak amacıyla çıkarılan öznitelikler, piksellerin uzamsal ilişkilerini hesaplayarak ikinci dereceden istatistiksel çıkarımlar yapmaktadır. GLCM, iki komşu piksel değerini temsil eden i ve j gri seviye değerlerinin, θ açısında ve d uzaklığında bulunmasının $P(i, j | d, \theta)$ şeklinde sembolize edildiği, istatistiki olarak doku-içerik bilgisini içeren bir matristir. Gri seviyeli resimlerden elde edilen GLCM matrisi, komşu piksel hücreleri arasındaki mesafeyi ve açısal ilişkiyi göstermektedir. Boyutları belirlenen işlem penceresi, resim üzerinde hareket ettirilir ve komşu piksellerdeki yoğunluk değerlerinin açısal olarak yer değiştirmesi durumlarını da kontrol altına alabilmek amacıyla Haralick ve diğerleri tarafından belirlenen şekliyle $\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135° açılarından oluşan dört yönde inceleme yapılabildiği gibi inceleme yapılan açı sayısı isteğe bağlı olarak değiştirilebilmektedir.

GLCM yönteminde kullanılan algoritmanın işlem adımları:

1. GLCM, resimdeki piksellerin gri seviye değerleri kullanılarak oluşturulur. Resim üzerinde taranacak pencere boyutu, kare olmak şartıyla belirlendikten sonra merkez piksel referans alınarak işlemler yapılır.
2. Referans piksel için belli bir uzaklık ve açıda ($\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135°) komşu piksel çiftlerinin oluşumu incelenir.
3. Piksel çiftlerinin oluşma sayıları veya istatistiki bilgileri GLCM matrisine işlenir. Matrisin boyutu görüntünün gri seviye değerleri sayısına bağlıdır.
4. Oluşturulan GLCM matrisi, simetrik açıdaki piksel çiftleri aynı olarak değerlendirildiği için simetrik bir yapıya sahiptir.
5. Her açı için ayrı ayrı incelenerek oluşturulan GLCM matrisine göre bu işlemler tekrarlanır.

6. Oluşturulan GLCM matrisi üzerinde çeşitli istatistiksel öznitelikler hesaplanarak öznitelik vektörü çıkarılır.

GLCM matrisinden öznitelik çıkarmak için farklı yöntemler ve metrikler bulunmaktadır. Bunlardan elde edilen öznitelikler görüntünün farklı yapısal özelliklerini temsil etmekte ve uygulama amacına bağlı olarak tercih edilmektedir. Literatürde bulunan mevcut çalışmalarda türetilen ikinci dereceden istatistiksel olasılığa dayalı GLCM öznitelikleri şu şekilde sıralanabilir (Haralick ve diğ., 1973; Soh ve Tsatsoulis, 1999; Clausi, 2002; Aziz ve diğ., 2021). Açısal İkinci Moment (Angular Second Moment), Entropi (Entropy), Farklılık (Dissimilarity), Ters Fark (Inverse Difference), Ters Fark Moment (Inverse Difference Moment), Korelasyon (Correlation), Otokorelasyon (Autocorrelation), Kontrast (Contrast), Küme Gölgesi (Cluster Shade), Küme Belirginliği (Cluster Prominence), Maksimum Olasılık (Maximum Probability), Kareler Toplamı (Sum of Square), Toplam Ortalama (Sum Average), Toplam Entropi (Sum Entropy), Toplam Varyans (Sum Variance), Fark Varyans (Difference Variance), Fark Entropi (Difference Entropy), Korelasyon Bilgi Ölçütleri (Information Measures of Correlation), Maksimal Korelasyon Katsayısı (Maximal Correlation Coefficient).

GLCM kullanılarak elde edilen normalize edilmiş gri seviye uzamsal bağlantı matrisinin (i, j) indisinde bulunan veri $P(i, j)$ ile gösterilirken, incelenen görüntüdeki farklı gri seviye değerlerinin sayısı ise N_{GL} ile ifade edilmektedir.

GLCM özniteliklerini çıkarırken kullanılan formüllerdeki $P_{x+y}(k)$, $P_{x-y}(k)$, $P_x(i)$, $P_y(j)$ ifadelerinin hesaplanması ile ilgili bilgi Denklem (3.20)'de verilmektedir.

$$\begin{aligned}
 P_{x+y}(k) &= \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P(i, j), \quad |i+j = k \{ k = 2, 3, \dots, 2N_{GL} \} \\
 P_{x-y}(k) &= \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P(i, j), \quad ||i-j| = k \{ k = 0, 1, \dots, N_{GL}-1 \} \\
 P_x(i) &= \sum_{j=1}^{N_{GL}} P(i, j) \\
 P_y(j) &= \sum_{i=1}^{N_{GL}} P(i, j)
 \end{aligned} \tag{3.20}$$

Denklem (3.20)'de gösterilen varsayımlardan yola çıkılarak GLCM öz nitelikleri şu şekilde açıklanmaktadır;

$$\text{Açısal İkinci Moment} = \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} \{P(i, j)\}^2 \quad (3.21)$$

$$\text{Entropi} = - \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P(i, j) (\log (P(i, j))) \quad (3.22)$$

$$\text{Farklılık} = \sum_i \sum_j |i - j| \cdot P(i, j) \quad (3.23)$$

$$\text{Ters Fark} = \sum_i \sum_j \frac{1}{1 + (i - j)} P(i, j) \quad (3.24)$$

$$\text{Ters Fark Moment} = \sum_i \sum_j \frac{1}{1 + (i - j)^2} P(i, j) \quad (3.25)$$

$$\text{Korelasyon} = \frac{\sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} \{(i - \mu_x)(j - \mu_y)P(i, j)\}}{\sigma_x \sigma_y} \quad (3.26)$$

Denklem (3.26)'da μ_x ve μ_y değişkenleri P_x ve P_y ifadelerinin ortalamalarını gösterirken σ_x ve σ_y değişkenleri ise P_x ve P_y 'nin standart sapmasını ifade etmektedir.

$$\text{Otokorelasyon} = \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} (i j) P(i, j) \quad (3.27)$$

$$\text{Kontrast} = \sum_{n=0}^{N_{GL}-1} n^2 \left\{ \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P(i, j) \right\} \quad |i - j| = n \quad (3.28)$$

$$\text{Küme Gölgesi} = \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} \{(i + j - \mu_x - \mu_y)^3 P(i, j)\} \quad (3.29)$$

$$\text{Küme Belirginliği} = \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} \{(i + j - \mu_x - \mu_y)^4 P(i, j)\} \quad (3.30)$$

$$\text{Maksimum Olasılık} = \max P(i, j) \quad \text{Bütün } (i, j)\text{'ler için} \quad (3.31)$$

$$\text{Karelerin Toplamı} = \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} (i - \mu)^2 P(i, j) \quad (3.32)$$

$$\text{Toplam Ortalama} = \sum_{i=2}^{2N_{GL}} i P_{x+y}(i) \quad (3.33)$$

$$\text{Toplam Entropi} = - \sum_{i=2}^{2N_{GL}} P_{x+y}(i) (\log (P_{x+y}(i))) \quad (3.34)$$

$$\text{Toplam Varyans} = \sum_{i=2}^{2N_{GL}} (i - f_{SE})^2 P_{x+y}(i) \quad (3.35)$$

$$\text{Fark Varyans} = P_{x-y}(i) \text{ ifadesinin varyansı} \quad (3.36)$$

$$\text{Fark Entropi} = - \sum_{i=0}^{N_{GL}-1} P_{x-y}(i) (\log (P_{x-y}(i))) \quad (3.37)$$

$$\text{Korelasyon Bilgi Ölçütü}_1 = \frac{H_{xy} - H_{xy1}}{\max \{H_x, H_y\}} \quad (3.38)$$

Denklem (3.38)'de kullanılan ve formüle edilmemiş tanımlamalar, Denklem (3.39)'da toplu olarak formüle edilmiştir.

$$\begin{aligned} H_{xy} &= - \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} (P(i, j) (\log P(i, j))), \\ H_{xy1} &= - \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P(i, j) (\log \{P_x(i) P_y(j)\}), \\ H_{xy2} &= - \sum_{i=1}^{N_{GL}} \sum_{j=1}^{N_{GL}} P_x(i) P_y(j) \log \{P_x(i) P_y(j)\} \end{aligned} \quad (3.39)$$

H_x ve H_y sembolleri, P_x ve P_y değişkenlerinin Entropi değerlerini temsil eder.

$$\text{Korelasyon Bilgi Ölçütü}_2 = \sqrt{(1 - \exp[-2.0 (H_{xy2} - H_{xy}])]} \quad (3.40)$$

$$Q(i, j) = \sum_k \frac{P(i, k)P(j, k)}{P_x(i)P_y(k)} \quad (3.41)$$

$$\text{Maksimal Korelasyon Katsayısı} = \sqrt{(Q'nun en büyük 2. eigen değeri)}$$

3.4.3. Segmentasyon tabanlı fraktal doku analizi (SFTA)

SFTA, görüntülerin fraktal yapısını analiz ederek öznelilikler çıkaran bir görüntü işleme yöntemidir. Fraktallar, kendine benzerliğin farklı ölçeklerde tekrarlandığı geometrik şekillerdir. Bu yöntem, görüntülerdeki doku özelliklerini çıkarmak için kullanılmakta ve genellikle görüntü sınıflandırma, görüntü tanıma ve segmentasyon gibi uygulamalarda tercih edilmektedir. SFTA yöntemi için ilk olarak resim gri seviyeli bir resme dönüştürülmekte ve kullanıcı tarafından eşik seviyeleri sayısı belirlenmektedir. SFTA yönteminin uygulanmasında iki ana adım bulunmaktadır.

İlk adımda, gri seviyeye dönüştürülmüş resim, kullanıcı tarafından belirlenen eşik seviyeleri sayısı ile OTSU çok seviyeli eşik belirleme algoritmasına gönderilmekte ve çoklu eşik seviyeleri belirlenmektedir. Bulunan n adet eşik seviyesi $T = t_1, t_2, t_3, \dots, t_n$ vektöründe saklanmaktadır. Bulunan bu eşik değerleri T_A vektörüne çiftler halinde eklenerek, $T_A \leftarrow \llbracket (t_i, t_{i+1}) : t_i, t_{i+1} \in T, i \in \{1, 2, \dots, n-1\} \rrbracket$ vektörü elde edilmektedir. T_A vektörüne tüm eşik çiftlerinin eklenmesinden sonra, sıradaki T_B vektörünü oluşturmak amacıyla tüm eşik seviyelerinin yanlarına resimdeki en büyük gri seviye değeri koyularak $T_B \leftarrow \llbracket (t_i, t_n) : t_i \in T, i \in \{1, 2, \dots, n-1\} \rrbracket$ vektörü oluşturulmaktadır. Bu eşik çiftleri, İki Eşikli İkili Ayırıştırma (Two Threshold Binary Decomposition) yöntemi kullanılarak Denklem (3.42)'de gösterildiği gibi gri seviyeli resme ayrı ayrı uygulanmakta ve görüntü ikili resme dönüştürülmektedir (Nisa ve diğ., 2020).

$$I_b(x, y) = \begin{cases} 1, & \text{Eğer } t_{alt} < I_g(x, y) \leq t_{üst} \\ 0, & \text{Diğer durumda} \end{cases} \quad (3.42)$$

Böylelikle girdi görüntüsü birçok farklı ikili alt resimlere dönüştürülmektedir. I_b : İkili resmi, I_g : Gri seviye resmi, $(t_{alt}, t_{üst})$: değerleri ise eşik çiftlerini temsil etmektedir.

İkinci adımda ise, Denklem (3.43)'de gösterilen ikili görüntüler kullanılarak özneliliklerin çıkarılma aşamasına geçilmektedir.

$$\Delta(x, y) = \begin{cases} 1, & \text{Eğer } \exists (x', y') \in N_8[(x, y)]: \\ & I_b(x', y') = 0 \quad \wedge \quad I_b(x, y) = 1, \\ 0, & \text{Diğer durumda} \end{cases} \quad (3.43)$$

$N_8[(x, y)]$ ifadesi (x, y) merkez koordinatının etrafındaki sekiz adet pikseli, $\Delta(x, y)$ ise ikili resmin sınırını ifade etmektedir. Çıktı resimlerinin her birindeki kenar pikseller ile birlikte ikili resim kullanılarak piksel sayıları (Alan bilgisi) hesaplanmaktadır. Aynı zamanda kenar piksel koordinatları kullanılarak, gri seviyeli görüntülerdeki ortalama gri seviye değerleri bulunmaktadır. Her ikili alt görüntü için kutu sayma yöntemi kullanılarak fraktal boyut bilgisi elde edilmekte ve öznitelik kümesi oluşturulmaktadır (Costa ve diğ., 2012; Faloutsos ve diğ., 2021). Bu çalışmada eşik seviyesi sayısı olarak 7 seçilmiş ve toplamda 39 öznitelik elde edilmiştir.

SFTA yönteminde kullanılan algoritmanın işlem adımları:

1. Gri seviyeye dönüştürülmüş resim ve belirlenen eşik seviye sayısı (n), OTSU çok seviyeli eşik belirleme algoritmasına gönderilerek $t_1, t_2, t_3, \dots, t_n$ eşik seviye değerleri belirlenir.
2. Belirlenen eşik seviyeleri kullanılarak T_A ve T_B vektörleri tespit edilir.
3. Gri seviye resim ve eşik çiftleri, İki Eşikli İkili Ayırıştırma yöntemine gönderilerek ikili resme dönüştürülür.
4. Gri seviye resimler, ikili görüntüler kullanılarak elde edilen alt ikili resimler ve kenar pikseller kullanılarak öznitelik vektörü çıkarılır.

3.4.4. Genel fourier tanımlayıcılar (GFD)

Frekans domaininde elde edilen özniteliklerden olan Genel Fourier Tanımlayıcılar (GFD), görüntü işlemede nesne tanıma, şekil analizi, görüntü eşleştirme gibi konularda kullanılan ve nesnenin şeklini, kontur bilgisini Fourier dönüşümü yardımıyla tanımlayan bir öznitelik çıkarma yöntemidir. Kontur, bir nesnenin sınırlarının veya silüetinin tanımlandığı piksellerin birbirlerine bağlanmasıyla oluşan bir dizi kapalı noktalar bütünüdür. Fourier Dönüşümü kullanılarak resim frekans bileşenlerine dönüştürülmekte, dönüştürülen veriler genellikle frekans ve faz bileşenlerini içeren karmaşık sayılar şeklinde temsil

edilmektedir. GFD kullanılarak elde edilen öznitelikler hem radyal hem de açısal yönlerde çoklu çözünürlüklü öznitelik analizine imkân tanımaktadır (Zhang ve Lu, 2002).

GFD'ler, gri seviyeli resimlere uygulanabildiği gibi, ikili resimlere de uygulanabilmektedir. Fourier tanımlayıcılar, görüntünün frekans bileşenlerini analiz ederek resmin şekil, doku gibi özelliklerini temsil etmek için kullanılmaktadır. Fourier dönüşümü yardımıyla görüntüden frekans bileşenleri elde edilmekte ve bu bileşenlerin frekans veya faz değerlerine göre öznitelik vektörü oluşturulmaktadır (Zhang ve Lu, 2002). Bu tez çalışmasında, morfolojik işlemler sonucunda elde edilen PD görüntülerinin tanımlanmasında 4 radyal frekans ve 13 açısal frekans kullanılarak en başarılı sonuca ulaşılmış ve toplamda her bir PD görüntüsü için 52 adet öznitelik vektörü elde edilmiştir.

3.4.5. Çalışma kapsamında kullanılan diğer öznitelikler

Standart sapma ve Entropi, görüntü işlemede yaygın olarak kullanılan istatistiksel tabanlı öznitelikler grubunda yer alırken, Ağırlık merkezi, geometri tabanlı öznitelikler grubunda kabul edilmektedir. İstatistiksel tabanlı öznitelikler, veri setinin değişkenliği, dağılımı, düzensizliği gibi konularda bilgi verirken, geometri tabanlı öznitelikler ise veri setindeki nesnelerin şekli, konumu, yönü gibi geometrik konularda bilgi vermektedir. Bu öznitelikler, görüntü işlemede istatistiksel analizler, nesne tespiti, nesnelerin yeri ve yönelim açısı analizi, sınıflandırma, görüntü segmentasyonu gibi uygulamalarda kullanılmaktadır.

3.4.5.1. Standart sapma

Görüntü işlemede kullanılan Standart sapma (σ), piksellerin yoğunluk değerlerinin dağılımının ölçüsünü temsil etmektedir. Bir başka ifadeyle Standart sapma, piksellerin ortalama değerden ne kadar farklılık gösterdiğini ölçmekte ve bu şekilde resimdeki kontrast veya varyans değerleri hakkında bilgi sağlamaktadır. Örneğin gri seviye resimlerde piksellerin çoğunun birbirlerine yakın değerlere sahip olması Standart sapması düşük olan homojene yakın bir resmi ifade etmektedir. Ancak resimdeki piksel değerlerinin fazla değişkenlik göstermesi, Standart sapmanın yüksek olması dolayısıyla resimdeki detayların veya kenarların daha belirgin olduğu anlamına gelmektedir. Standart sapma Denklem (3.44) ile hesaplanmaktadır (Wang ve Chang, 2011).

$$\text{Standart Sapma } (\sigma) = \sqrt{\frac{\sum (X_i - \mu)^2}{N}} \quad (3.44)$$

N, resimdeki toplam piksel sayısını göstermektedir.

X_i , her bir pikselin değerini ifade etmektedir.

μ , resimdeki tüm piksellerin ortalama değerini temsil etmektedir.

3.4.5.2. Entropi

Görüntü işlemede kullanılan bir diğer öznelik olan entropi, bir resmin piksellerinin dağılımının karmaşıklığını ölçerek resimdeki düzensizlik veya belirsizlik seviyesi hakkında bilgi vermektedir. Yüksek entropi değeri, piksellerin farklı değerlere sahip olduğu, yani dağılımlarının daha dengesiz, karmaşık olduğu bir resmi gösterirken, düşük entropi değeri daha düzgün ve tekrarlanan bir deseni ifade etmektedir (Wang ve Chang, 2011).

Entropi için Denklem (3.45) kullanılmaktadır. Bu denklemde $p(x)$ olarak ifade edilen değer, x 'in resimde bulunma olasılığını göstermektedir.

$$\text{Entropi } (E) = -\sum (p(x) * \log_2 p(x)) \quad (3.45)$$

3.4.5.3. Ağırlık merkezi

Görüntü işlemede öznelik çıkarma yöntemlerinden biri olan Ağırlık merkezi (Centroids), bir nesnenin ağırlık dağılımını dikkate alarak ağırlık merkezinin bulunmasını temsil etmektedir. Ağırlık merkezi, bir nesnenin konumunu belirlemek için kullanılmakta ve resimdeki piksellerin (x, y) konum bilgisi ve yoğunlukları kullanılarak resmin ağırlık merkezi hesaplanmaktadır. Bu amaçla en yaygın olarak kullanılan yöntem, nesnenin momentlerinin kullanılarak ağırlık merkezinin hesaplanmasıdır. Ağırlık merkezi, nesnenin momentini alıp toplam kütesine bölerek bulunmaktadır. Resmin momenti, resim içindeki piksellerin koordinat bilgileriyle piksel yoğunluğunun çarpılarak toplanması sonucunda

bulunmaktadır. Toplam kütle ise görüntüdeki piksellerin yoğunluk değerlerinin toplanmasıyla bulunmakta ve bir resmin ağırlık merkezini bulmak için Denklem (3.46) ve (3.47) kullanılmaktadır (Mutlag ve diğ., 2020).

$$C_x = \frac{\sum (x * I(x, y))}{\sum (I(x, y))} \quad (3.46)$$

$$C_y = \frac{\sum (y * I(x, y))}{\sum (I(x, y))} \quad (3.47)$$

Hesaplanan C_x ve C_y değişkenleri Ağırlık merkezinin (C_x, C_y) koordinatlarını, $I(x, y)$ pikselin ilgili koordinattaki yoğunluğunu verirken x ve y değerleri ise işlem yapılan pikselin koordinat bilgisini göstermektedir.

3.5. Sınıflandırma Yöntemleri

Sınıflandırma işlemi, görüntü işlemede nesne tanıma, desen tanıma, nesnelerin arka plan görüntülerinden ayrıştırılması, görüntülerin önceden belirlenmiş sınıflara ayrılması gibi amaçlar için kullanılmaktadır. Sınıflandırma yöntemleri, görüntülerden çıkarılan özniteliklerden faydalanarak bir veri noktasını belli bir sınıfa atamak amacıyla istatistiksel ve matematiksel yöntemler kullanılmaktadır. Bu başlık altında, tez çalışmasında kullanılan Topluluk Öğrenmesi, K-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Karar Ağacı gibi sınıflandırma algoritmaları hakkında bilgiler verilecektir.

3.5.1. Topluluk öğrenmesi

Bu fikrin ilk olarak ortaya çıkması, istatistikçi ve düşünür olan Galton tarafından düzenlenen bir ağırlık tahmin etme yarışmasına kadar uzanmaktadır. Yapılan yarışmada kimse ağırlığı doğru olarak tahmin edememiş olsa da katılımcıların yapmış oldukları tahminlerin ortalaması doğru cevaba en yakın cevap olmuştur. Böylece Galton, birden çok tahmini birleştirmenin doğruya en yakın sonucu verebileceği fikrini ortaya koyarak aslında Topluluk Öğrenmesi (Ensemble Learning) sınıflandırma yönteminin temelini atmıştır (Rokach, 2010).

Topluluk öğrenme sınıflandırma algoritması, birden çok sınıflandırma modelinin bir araya getirilmesi fikrine dayanarak daha güçlü ve başarılı bir sınıflandırma modeli oluşturmayı amaçlayan bir yöntemdir. Farklı sınıflandırıcıların birbirlerinden farklı sınıflandırma başarılarına sahip olabileceği, bu nedenle veri setindeki yanlış sınıflandırılan kısımların, farklı sınıflandırıcılar kullanılarak doğru bir şekilde sınıflandırılabilmesi fikrine dayanmaktadır.

Topluluk öğrenme sınıflandırıcılarının temel çalışma adımları (Rokach, 2010):

1. Topluluk öğrenme sınıflandırıcıları ilk olarak etiketli verilerden oluşan bir eğitim veri setine ihtiyaç duymaktadır.
2. Birden fazla temel sınıflandırıcının birleşmesiyle oluşmaktadır. Her sınıflandırıcı farklı öğrenme algoritmaları veya farklı parametrelerle eğitilmiş olabilir. Örnek olarak SVM, Karar Ağacı, KNN vb. sınıflandırma algoritmaları kullanılabilir. Temel sınıflandırıcıların tek başlarına yeterli başarı gösteremedikleri kabul edilir ve zayıf sınıflandırıcılar olarak adlandırılır.
3. Temel sınıflandırıcılar, farklı parametrelerle veya farklı özniteliklerle ayrı ayrı eğitilerek seçilen sınıflandırıcılar arasında çeşitlilik sağlanır. Temel amaç, sınıflandırıcıların farklı hatalar yaparak tüm veri seti üzerindeki başarısını artırmaktır. Bu amaçla veri setleri alt veri setlerine parçalanarak, her alt veri setinin temel sınıflandırıcılardaki başarıları analiz edilebileceği gibi, farklı parametre kullanımlarındaki davranışları da incelenebilir.
4. Temel Sınıflandırıcılardan elde edilen tahminler bir model çerçevesinde bir araya getirilerek son tahmin üretilir. Birleştirme yöntemleri olarak, çoğunluk oylaması, ağırlıklandırma veya kural tabanlı karar algoritmaları kullanarak ağırlıklandırma ve oylamanın her ikisinin de kullanılabildiği yöntemler sıralanabilir.

Topluluk öğrenme sınıflandırıcının çeşitlilik oluşturma bileşeni olarak kullanılan metotlarından bazılarını; Torbalama (Bagging), Uyarlamalı Artırma (AdaBoost), Rastgele Düşük Örnekleme Artırma (RUSBoost), Alt Uzay K-En Yakın Komşu (SubKNN), Alt Uzay Diskriminant (SD) olarak sayılabilmektedir (Khan ve diğ., 2023).

3.5.1.1. Torbalama

Torbalama yönteminde, veri seti Rastgele Örneklem (Bootstrap Sampling) yöntemiyle birden fazla alt veri kümelerine bölünmektedir. Her alt veri kümesi üzerinde bağımsız olarak çalışan ayrı öğrenme modelleri oluşturularak eğitilmektedir. Eğitim tamamlandıktan sonra her bir alt model, kendi tahminine dayalı sonuçlar üreterek toplu bir tahmin işlemi gerçekleştirilmektedir. Sınıflandırmadaki sonuç üretme aşamasında çoğunluk oylaması ya da ağırlıklandırma gibi birleştirme yöntemleri kullanılabilir (Khan ve diğ., 2023).

3.5.1.2. AdaBoost

AdaBoost, bir dizi zayıf modelden sağlam bir model üretmeye çalışan yinelemeli bir makine öğrenme algoritmasıdır. Bu algorithmada bütün ağırlıklar başlangıçta eşitlenmektedir. Örnekler, sınıflandırma yapılacak olan veri kümesindeki bireysel veri noktalarını temsil etmektedir. Örneklerin ağırlıkları her iterasyonda sınıflandırma performansına göre güncellenerek yanlış sınıflandırılan tüm örneklerin ağırlıkları artırılırken, doğru sınıflandırılan örneklerin ağırlıkları azaltılmaktadır. Sonuç olarak başarısız olarak sınıflandırılan örnekler üzerine odaklanılarak, bu örnekler yeni iterasyonlarda doğru olarak sınıflandırılmaya çalışılarak toplam eğitim hatası azaltılır. Tüm iterasyonlar tamamlandıktan sonra etiketlenmemiş olan örneklere bir sınıf atamak için ise tüm modellerin ağırlıklandırılmış oyu kullanılır (Freund ve Schapire, 1997; Khan ve diğ., 2023).

3.5.1.3. RUSBoost

RUSBoost, bir çeşit AdaBoost metodu temeline dayanmakta ve daha hızlı model eğitim süreleri ve performansına sahip daha basit bir algoritma olarak karşımıza çıkmaktadır (Seiffert ve diğ., 2010). RUSBoost, her bir iterasyonda eğitim setinin rastgele bir alt kümesini seçmekte ve bu alt kümede sınıf dengesini koruyacak şekilde örneklem yapmaktadır. Ardışık iterasyonlarda yeni sınıflandırıcılar oluşturularak ağırlıkları ayarlanmaktadır. Ayarlanan bu ağırlıklara göre oy verilerek Topluluk tahmini yapılmaktadır (Seiffert ve diğ., 2010; Khan ve diğ., 2023).

3.5.1.4. Alt uzay k-en yakın komşu

SubKNN yönteminde, öznitelik alt kümeleri seçilmekte ve her bir alt küme üzerinde ayrı ayrı KNN sınıflandırıcısı uygulanmaktadır. Alt küme sınıflandırıcılarının tahminleri birleştirilerek Topluluk tahmini elde edilmektedir (Khan ve diğ., 2023).

3.5.1.5. Alt uzay diskriminant

SD metodunda, veri setinin farklı öznitelik alt kümeleri üzerinde ayrı ayrı sınıflandırma modelleri oluşturarak daha güçlü bir topluluk modeli elde etmeyi amaçlamaktadır. Yüksek boyutlu veri setlerinde öznitelik kümesinin tamamını tek bir sınıflandırıcıda kullanmak yerine, öznitelik kümesini alt kümelere bölerek farklı sınıflandırma modelleri kullanarak yüksek boyutlu veri setlerinde karşılaşılabilen aşırı uyma (overfitting) sorununu azaltmak için kullanılmaktadır. Böylelikle her bir alt model farklı öznitelikleri dikkate alarak veri setini farklı özniteliklerle değerlendirmektedir. Eğitim işleminden sonra her alt model tahminleri uygun bir birleştirme yöntemi kullanılıp birleştirilerek Topluluk tahmini yapılmaktadır (Khan ve diğ., 2023).

3.5.2. K-en yakın komşu (KNN)

KNN sınıflandırıcısı, en popüler makine öğrenmesi algoritmalarının başında gelmektedir. KNN algoritması için temel çalışma mantığı şu şekilde ifade edilebilir. Bu örnekte iki boyutlu bir öznitelik uzayının olduğu varsayımından yola çıkılmaktadır. Ait olduğu sınıf bilgisi öğrenilmek istenilen herhangi bir noktanın, öznitelik uzayı içinde diğer noktalara olan uzaklıkları ölçüm teknikleri kullanılarak hesaplanmakta ve en yakın k adet noktanın çoğunlukla hangi sınıfa ait olduğu bilgisine bakılarak sonuç üretilmektedir. Bu algorithmada k sabiti kullanıcı tarafından belirlenmekte ve genellikle eşitlik olmaması için tek sayı tercih edilmektedir. Bulunan k adet noktanın çoğunluğu hangi sınıfa ait ise öğrenilmek istenen nokta o sınıfa dahil edilmektedir. Böylelikle bilinmeyen noktanın hangi sınıfa ait olduğu bilgisi, uzaklık ölçüm metrikleri kullanılarak hesaplanmaktadır. Kullanılacak uzaklık hesaplama metriğine ve k sabitinin değerine göre algoritma farklı sonuçlar üretebilmektedir. Uzaklık ölçüsü, bilinen sınıfların ağırlık merkezleri temel alınarak hesaplanabileceği gibi, sınıflara ait örneklerin konumlarına olan uzaklıklarına göre de hesaplanabilmektedir. KNN algoritmasındaki k sabitinin değeri yapılan deneme sonuçlarına

göre belirlenmekte ve bu değerin 1 olarak belirlenmesi durumunda algoritma ince KNN (f-KNN) olarak tanımlanmaktadır (Sekhavati ve diğ., 2022). KNN algoritmasında kullanılacak uzaklık metriklerinden bazıları Öklid uzaklığı (Euclidean), Şehir Blok uzaklığı (Manhattan, City Block), Mahalanobis uzaklığı, Kübik uzaklığı (Minkowski), Kosinüs uzaklığı (Cosine), Jaccard uzaklığı, Hamming uzaklığı vs. olarak sayılabilir (Aljarah ve diğ., 2021).

3.5.3. Destek vektör makineleri (SVM)

Sınıflandırma sorununa etkili ve basit bir çözüm önerisinde bulunan SVM, makine öğrenimi alanında oldukça yaygın bir kullanıma sahiptir. Chervonenkis ve Vapnik tarafından 1960'lı yılların sonlarında önerilen istatistiksel öğrenme teorisi veya Vapnik - Chervonenkis (VC) teorisi, SVM'nin temelini oluşturur. 1990'lı yıllara kadar istatistiksel öğrenme teorisi, belli bir veri kümesinden fonksiyon tahmini çıkartılması probleminin teorik bir analizi olarak kullanılmıştır. 1990'lı yılların ortalarında geliştirilen teoriye dayalı yeni tip bir öğrenme algoritması olarak SVM önerilmiştir. Bu algoritma, öznetelik uzayındaki veri noktalarını iki sınıfa ayırmak amacıyla sınıflar arasına çizilecek en iyi karar çizgisi veya hiperdüzlem bulmayı hedeflemektedir. Sınıflar arasına çizilen çizgi ya da hiperdüzlem sayesinde yeni gelen verinin en doğru şekilde sınıflandırılması sağlanmaktadır (Cortes ve Vapnik, 1995; Vapnik, 1999). İki'den fazla sayıda sınıf bulunması durumunda sınıf sayısına bağlı olarak SVM, ikili sınıflandırmalar yapacak şekilde düzenlenmektedir. Bunun için 1'e karşı 1 ve 1'e karşı hepsi yöntemleri kullanılmıştır. 1'e karşı 1 yönteminde yeni gelen veri, ikiye ayrılarak tüm sınıf çiftlerinde eğitilmesi sonucunda daha çok atandığı sınıf, yeni verinin sınıfı olarak belirlenmektedir. Bu işlem için, n sınıflı bir veri seti için $n*(n-1)/2$ adet eğitim yapılması gerekmektedir. İki'den fazla sınıf bulunduğu durumlarda izlenecek bir diğer yol olan 1'e karşı hepsi yönteminde ise her ilgilenilen veri sınıfı dışında kalan tüm veriler bir sınıfa aitmiş gibi düşünülerek eğitim işlemi gerçekleştirilir. Bu yöntemde n sınıflı bir veri seti için n adet eğitim yapılması gerekmektedir. Bir verinin hangi sınıfa ait olduğuna, eğitim sonucu hesaplanan destek vektörleri kullanılarak yapılacak karşılaştırmalar sonucunda karar verilir. En iyi çözüm için, hiperdüzlem ile destek vektörleri arasındaki mesafenin de maksimum olması gerekmektedir (Chih-Wei ve Chih-Jen, 2002; Bansal ve diğ., 2022).

SVM sınıflandırma algoritması uygulamasında takip edilecek adımlar:

1. Veri seti etiketlenerek eğitim kümesi ve test kümesi olmak üzere ayrılır.
2. Verilerin farklı ölçeklerde olmasını engellemek adına veriler normalleştirme işlemine tabi tutulur.
3. Sınıflar arasında maksimum aralığa sahip olacak bir hiperdüzlem bulmak üzere eğitim veri seti kullanılarak SVM modeli oluşturulur ve sınıfları birbirinden ayıran hiperdüzlem çıkarılır.
4. SVM için kullanılacak en iyi sınıflandırma performansını verecek parametreler belirlenir.
5. Eğitimden sonra model test edilerek modelin performansı değerlendirilir.
6. Parametreler ve çekirdek fonksiyonları yeniden değerlendirilerek, gerekirse boyut azaltma teknikleri ile modelin performansı arttırılmaya çalışılır.

3.5.4. Karar ağacı algoritması

Sınıflandırma problemlerini çözmek için kullanılan bir diğer makine öğrenmesi algoritması Karar Ağacı (Decision Tree) algoritmasıdır. Veri setinin özelliklerini ve sınıflarını daha iyi yakalamak amacıyla veri kümesi üzerinde Karar Ağacı oluşturularak, verilerin özelliklerine dayalı kararlar almayı sağlamaktadır. Karar Ağacı algoritmasında ağaç yapısı, kök düğüm, iç düğüm (dal) ve yaprakтан oluşmaktadır. Kök düğüm, veri kümesindeki en önemli özelliği seçmekte ve buna göre veri kümesini bölerek ağacın dallarını oluşturmakta, iç düğümler, veri kümesini daha küçük alt kümelere bölmektedir. Yaprak ise en alt seviyede olup, karar sınıflandırmasının yapıldığı yerde bulunmaktadır (Azmi ve Baliga, 2020).

Karmaşık Ağaç (CT), Orta Ağaç, Basit Ağaç, Karar Ağacı algoritmasının genel karmaşıklık düzeylerini ifade eden parametrelerdir. Basit bir karar ağacı, düşük karmaşıklığa sahip, az sayıda karar düğümü ve iç düğüm içeren bir yapıya sahiptir. Sınıflandırma kararları daha az sayıda dallanma ve karar düğümleri içermektedir. CT ise yüksek düzeyde karmaşıklığa sahip olup büyük ve çok sayıda sınıfın bulunduğu veri setlerinde

daha detaylı sınıflandırma yapmak için kullanılmaktadır. CT algoritması çok sayıda öz-niteliğin ve sınıfın bulunduğu problemlerde tercih edilmekte ancak daha fazla hafıza ve hesaplama gücü gerektirmektedir (Çetinkaya ve Horasan, 2021).

3.5.5. Diskriminant analizi

Diskriminant Analizi (DA) yöntemi, ilk kez R. A. Fisher tarafından 1936 yılında önerilen, çok değişkenli istatistiksel tabanlı bir sınıflandırma yöntemidir. Bu yöntemde, farklı sınıflardaki örneklerden elde edilen öz-nitelik değerleri arasındaki farkı maksimize etmek ve aynı sınıf içindeki örneklerin öz-nitelik değerleri arasındaki farkı ise minimize etmek amacıyla istatistiksel ve matematiksel yöntemlerden faydalanılır. Öz-nitelikleri çıkartılan örneklerin hangi sınıfa ait olduğu belirlendikten sonra yanlış bir sınıfa atanması durumunda bir hatalı sınıflandırma olasılığı belirlenmektedir. Sınıflandırma sırasındaki amaç, sınıf belirleme işleminin en az hatayla yapılmasıdır. Birden fazla bağımsız değişken olabilirken, bağımlı değişkenin kategorik olması gerekir (Fisher, 1938; Tharwat, 2016).

DA kullanılarak yapılan sınıflandırma işlemleri Doğrusal Diskriminant Analizi (LDA) ve İkinci Dereceden (Kuadratik - Karesel) Diskriminant Analizi (QDA) olmak üzere iki gruba ayrılır. Sınıflar arası Varyans kovaryans matrisleri, LDA’da eşit iken QDA’da eşit değildir (Tabachnick ve diğ., 2013).


3.6. Önerilen Öz-nitelik Çıkarma Metotları

Bu tez çalışması kapsamında PD ağına dayalı sistemlerin, tanımlama ve sınıflandırma performansını iyileştirmek amacıyla, iki yeni öz-nitelik çıkarma yöntemi geliştirilmiştir. Geliştirilen öz-nitelik çıkarma yöntemi, PD görüntüleri çıkarılmış resmin ağırlık merkezinden yatay ve dikey düzlemde geçtiği varsayılan hayali çizginin, PD ile kesiştiği noktaların oransal bilgisi temeline dayanmaktadır. Bu sayede damarlar arasındaki uzaklık bilgisi, matematiksel yöntemler kullanılarak ayırt edici bir metriğe dönüşmektedir. Şekil 3.5’de *HTP* ve *VTP* öz-niteliklerinin çıkarılması ile ilgili akış şeması gösterilmektedir.



Şekil 3.5. HTP ve VTP öznitelik çıkarma algoritması akış şeması

Öznitelik çıkarma aşamasında, damar iskeleti elde edilmiş olan ikili resim üzerinde HVTP öznitelik çıkarma yöntemi uygulanarak, PD görüntüsünden öznitelik çıkarma işlemi gerçekleştirilmektedir. Bir başka ifadeyle son işlem adımından sonra görüntümüzün damar iskeleti çıkarılarak ikili resim formatına dönüşmüş olması gerekmektedir. Damar iskeleti çıkarılan ikili resmin ağırlık merkezi bulunarak, bu noktadan geçtiği düşünülen yatay ve dikey eksenler üzerinden *HTP* ve *VTP* öznitelik değerleri ölçümlenmektedir. Örnek bir PD görüntüsünün Şekil 3.5’de gösterilen akış şemasındaki işlem basamaklarından son işlem adımı uygulanması sonrasında elde edilen ikili PD iskeleti ve resmin ağırlık merkezinden geçen düzlemlerin damarla olan yatay ve dikey kesişim noktaları Şekil 3.6’da gösterilmektedir.




Şekil 3.6. HTP ve VTP öznitelikleri tanımı.

(a) Örnek giriş PD görüntüsü, (b) Son işlem sonucunda iskeleti çıkarılmış ikili PD görüntüsü, (c) Yatay ve dikey kesişme noktaları

3.6.1. Yatay Toplam Oran (HTP)

Şekil 3.5’deki akış şemasında gösterildiği üzere, ön işlem, segmentasyon ve son işlem adımlarının uygulanması sonrası iskeleti çıkarılarak ikili resme dönüştürülmüş olan PD görüntüsü Şekil 3.6 - (b)’de gösterilmektedir. Geliştirilen özniteliklerden ilki olan

Yatay Toplam Oran, Şekil 3.7’de gösterilen ikili PD görüntüsü kullanılarak çıkarılmaktadır. İskeleti çıkarılan ikili resmin ağırlık merkezinin (A_x, A_y) olarak bulunduğu varsayılmaktadır. Ağırlık merkezi olarak hesaplanan (A_x, A_y) noktasından geçen hayali yatay bir eksen oluşturularak, bu eksen ile kesişen PD noktalarının koordinatları Şekil 3.7’de gösterildiği gibi tespit edilmektedir. Görüldüğü üzere PD ağları, yatay eksen ile üç farklı noktada kesişmiş ve kesişim noktaları işaretlenmiştir. X_1, X_2 ve X_3 olarak isimlendirilen bu kesişim noktalarının koordinat düzlemindeki adresleri (X_1, A_y) , (X_2, A_y) ve (X_3, A_y) şeklinde gösterilmektedir.



Şekil 3.7. HTP öznelik tanımı.


Burada, her bir X_n noktasının $(0, A_y)$ noktasına olan Öklid uzaklığı hesaplanmaktadır. İki boyutlu koordinat düzleminde (X_1, A_y) noktasının $(0, A_y)$ noktasına olan Öklid uzaklığı X_1 olurken, (X_2, A_y) noktasının $(0, A_y)$ noktasına olan Öklid uzaklığı X_2 , (X_3, A_y) noktasının $(0, A_y)$ noktasına olan Öklid uzaklığı X_3 , (X_n, A_y) noktasının $(0, A_y)$ noktasına olan Öklid uzaklığı X_n ’dir. Bulunan veriler Denklem (3.48)’de yerine koyularak *HTP* özneliği hesaplanmaktadır (Titrek ve Baykan, 2020).

$$HTP = \left(\frac{X_1}{X_2} + \frac{X_2}{X_3} + \dots + \frac{X_{n-1}}{X_n} \right) * INT \quad (3.48)$$

Denklem (3.48)’de *INT* olarak tanımlanan değişken yatay yöndeki toplam kesişim sayısını ifade etmektedir (Titrek ve Baykan, 2020). Denklem (3.48)’de *INT* değerinin bir olması durumunda *X* değeri, *HTP* olarak belirlenmektedir. VS1 veri setinden rastgele seçilen sınıflara ait örneklerden elde edilen *HTP* ağırlıkları Çizelge 3.1’de verilmektedir.

3.6.2. Dikey Toplam Oran (VTP)

Şekil 3.5’deki akış şemasında gösterildiği üzere PD görüntüsüne, ön işlem, segmentasyon ve son işlem adımları uygulanmakta ve iskeleti çıkarılarak ikili resme dönüştürülmektedir. İskeleti çıkarılarak damarsal bölgeleri tespit edilen Şekil 3.6 - (b)’deki ikili PD resminin ağırlık merkezi hesaplanmakta ve (A_x, A_y) noktası olduğu varsayılmaktadır. Bu varsayımdan yola çıkarak hesaplanan (A_x, A_y) noktasından geçen hayali dikey bir eksen oluşturulmakta ve bu dikey eksen ile kesişen PD noktaları Şekil 3.8’de gösterilmektedir. Dikey eksenindeki 5 farklı noktada kesiştiği görülen Y_1, Y_2, Y_3, Y_4 ve Y_5 olarak isimlendirilen kesişim noktalarının koordinat düzlemindeki adresleri $(A_x, Y_1), (A_x, Y_2), (A_x, Y_3), (A_x, Y_4)$ ve (A_x, Y_5) şeklinde gösterilmektedir.



Şekil 3.8. VTP öznitelik tanımı.

Burada, her bir Y_n noktasının $(A_x, 0)$ noktasına olan Öklid uzaklığı hesaplanmaktadır. İki boyutlu koordinat düzleminde (A_x, Y_1) noktasının $(A_x, 0)$ noktasına olan Öklid uzaklığı Y_1 olurken, (A_x, Y_2) noktasının $(A_x, 0)$ noktasına olan Öklid uzaklığı Y_2 , (A_x, Y_3) noktasının $(A_x, 0)$ noktasına olan Öklid uzaklığı Y_3 ve (A_x, Y_n) noktasının $(A_x, 0)$ noktasına olan Öklid uzaklığı Y_n olmaktadır. Bulunan veriler Denklem (3.49)’da yerine koyularak VTP özniteliği hesaplanmaktadır (Titrek ve Baykan, 2020).

$$VTP = \left(\frac{Y_1}{Y_2} + \frac{Y_2}{Y_3} + \dots + \frac{Y_{n-1}}{Y_n} \right) * INT \quad (3.49)$$

Denklem (3.49)’da INT olarak tanımlanan değişken dikey yöndeki toplam kesişim sayısını ifade etmektedir (Titrek ve Baykan, 2020). Denklem (3.49)’da INT değerinin

bir olması durumunda Y değeri, VTP olarak belirlenmektedir. VS1 veri setinden rastgele seçilen sınıflara ait örneklerden elde edilen VTP ağırlıkları Çizelge 3.1’de verilmektedir.

Çizelge 3.1’de, sınıf içi elde edilen HTP ve VTP ağırlıklarının standart sapması ve ortalaması hesaplanıp çizelgenin en alt kısmında sunulmuştur. Böylelikle sınıf içi ve sınıflar arası değerlerin birbirlerine olan uzaklıkları ve yakınlıkları incelenmektedir. Görüldüğü üzere sınıf içindeki standart sapmalar düşük çıkarken, ortalama değerler sınıflara göre farklılık göstermektedir. Bir sınıftaki örneklerin standart sapmasının düşük olması, sınıf içindeki ağırlıkların birbirlerine yakın olduğu anlamına gelmektedir. Sınıflara ait ortalama değerlerin birbirlerinden farklı çıkması ise, çıkarılan özniteliğin sınıflar arasındaki ayırt ediciliğinin yüksek olması anlamına gelmektedir. Sınıf içi ağırlıkların birbirlerine yakın, sınıflar arası ağırlıkların ise birbirlerinden uzak olması ayırt edicilik açısından istenilen bir durumdur. Çizelge 3.1’e göre HTP ve VTP özniteliklerinin bu durumu sağladığı görülmektedir.

Çizelge 3.1. Farklı sınıflarda HTP ve VTP değerlerinin incelenmesi


	Sınıf 25		Sınıf 46		Sınıf 55	
Örnek numarası	HTP	VTP	HTP	VTP	HTP	VTP
1	0.5084746	1.4918626	4.7070218	1.7740049	1.6326531	1.8095238
2	0.5172414	1.5454340	4.6714286	1.7740049	1.6400000	1.7882353
3	0.5517241	1.4918626	4.6616279	1.7589820	1.6078431	1.8333333
4	0.5084746	1.4918626	4.6980686	1.7589820	1.6400000	1.7882353
5	0.5517241	1.5033311	4.7428571	1.7740049	1.6400000	1.8571429
6	0.5084746	1.4918626	4.7313953	1.7589820	1.6400000	1.7647059
7	0.5423729	1.4986351	4.7985893	1.7589820	1.6078431	1.8588235
8	0.5172414	1.4986351	5.1613953	1.7589820	1.6400000	1.7882353
9	0.5084746	1.4918626	5.2166048	1.7440300	1.6400000	1.8352941
10	0.5172414	1.4986351	4.8340961	1.7291515	1.6078431	1.8333333
11	0.5172414	1.4986351	5.2217687	1.7078854	1.6078431	1.8117647
12	0.5172414	1.4986351	4.7454319	1.7323580	1.6400000	1.7882353
13	0.5517241	1.4986351	4.5962310	1.7232678	1.6000000	1.8571429
14	0.5517241	1.4986351	4.6622257	1.7078854	1.6734694	1.8117647
15	0.4827586	1.4986351	4.6659984	1.7232678	1.6400000	1.8117647
Ortalama	0.5234756	1.4998106	4.8076494	1.7456514	1.6304997	1.8158357
Standart sapma	0.0212155	0.0131497	0.2115359	0.0233092	0.0199223	0.0292800

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez kapsamında; PD tanıma işleminin, literatürde bulunan geleneksel yöntemler kullanılarak yapılan çalışmalara göre daha başarılı sonuçlar üretebilmesi amacıyla bir dizi çalışma yapılmıştır. Yapılan çalışmalarda *3.10 GHz Intel® Core™ i5-2400 CPU*, *4.00 GB RAM* ve *64 bitlik Windows 10* işletim sistemine sahip masaüstü bilgisayarda yüklü *Matlab R2021a* platformu kullanılarak gerçekleştirilmiştir.


Tez çalışması kapsamında genel hatları ile iki çalışma yapılmış ve bu çalışmalara ait akış şemaları Şekil 4.1, 4.2 ve 4.3’de gösterilmiştir. İlk yapılan çalışmanın akış şeması Şekil 4.1 ve 4.2’de, ikinci yapılan çalışmanın akış şeması Şekil 4.3.’de gösterilmiştir.

Şekil 4.1’de görüldüğü üzere uzamsal domainde çıkarılan özniteliklerden Standart sapma ve Entropi ön işlem adımından sonra çıkarılırken, Ağırlık merkezi, *HTP* ve *VTP* öznitelikleri son işlem adımından sonra çıkarılmaktadır.




Şekil 4.1. PD tanıma sistemi ile ilgili yapılan çalışmada kullanılan akış şeması (uzamsal domain öznitelik çıkarma)

Şekil 4.2’de görüldüğü üzere *HTP* ve *VTP* ile frekans domaininde çıkarılan GFD öznitelikleri son işlem adımından sonra çıkarılmaktadır.



Şekil 4.2. PD tanıma sistemi ile ilgili yapılan çalışmada kullanılan akış şeması (frekans domaini öznitelik çıkarma)

Şekil 4.3’de görüldüğü üzere HVTP öznitelik çıkarma işlemi son işlem adımından sonra elde edilen ikili resim üzerinden çıkarılırken GLRLM, GLCM, SFTA öznitelikleri ise ön işlem adımından sonraki gri seviye resim üzerinden çıkarılmaktadır.



Şekil 4.3. PD tanıma sistemi ile ilgili yapılan çalışmada kullanılan akış şeması

4.1. Çalışmalarda Kullanılan Parametrelerin Belirlenmesi

Tez çalışması kapsamında önerilen mevcut algoritmalar için kullanılan parametreler, en iyi çıktıyı üretecek şekilde yapılan denemeler sonucunda seçilmiş ve tez çalışmasına eklenmiştir. Önerilen öznitelik çıkarma yöntemleri, literatürde biyometrik tanıma sistemlerinde sıklıkla tercih edilerek başarılı sonuçlar üreten öznitelik çıkarma algoritmalarıyla öznitelik füzyonu yöntemi yardımıyla birleştirilmiş ve iki farklı PD veri seti üzerinde çalışmalar yapılmıştır. Kullanılan özniteliklerin başarı oranı üzerindeki etkileri incelenmiş ve yeterli başarı sağlayamayan özellikler, öznitelik vektöründen çıkarılmıştır.


Bu çalışma kapsamında ilk olarak damar dokusunu çıkarmaya yönelik araştırmalar yapılmıştır. Ancak NIR ışığına maruz kalan dokuda meydana gelen ışık saçılması,

damar görüntüsünün başarılı bir şekilde resimden çıkarılmasına en büyük engellerden birisi olmuştur. Bu nedenle ön işleme adımında ışık saçılma sorunundan kurtulmaya odaklanılmıştır. Yapılan deneysel çalışmalar ve araştırmalar sonucunda HF ile başarılı sonuçlar alındığı görülmüştür. HF içerisinde Butterworth Yüksek Geçirgen Filtre kullanılmıştır. HF de kullanılan parametrelerden kesme frekansı 10, Q keskinlik faktörü 2, düşük frekans kesme bandı (α_l) 0.0999, yüksek frekans kesme bandı (α_h) 1.01 olarak belirlenmesi durumunda en iyi sonuca ulaşılmıştır. HF algoritmasından sonra resimdeki gürültülerden kurtulmak amacıyla uygulanan PMAD işleminde difüzyon işleminin tekrarlanma sayısı (T) 10, difüzyon sürecindeki adım büyüklüğü (Δt) 0.25, gauss işlemi için Standart sapma değerini belirleyen sigma değeri 2, difüzyon işlemi esnasındaki kenar koruma parametresi olan lambda 2 olarak kabul edilmiştir. Damarlı bölgeyi damarsız bölgeden ayırmak için Niblack Segmentasyon algoritması kullanılmıştır. Bu algoritmanın doğal bir sonucu olarak işlem sonunda resim ikili resme dönüşmüştür. Niblack Segmentasyon algoritmasında, eşik seviyesinin belirlenmesi amacıyla kullanılan k parametresi, [-1, 1] arasındaki değerleri alacak şekilde yapılan çalışmalar sonucunda -0.17 olarak belirlenmiştir. Bu algortmada işlem penceresinin büyüklüğünü seçerken, seçeceğimiz pencere boyutunun detayları kaybetmeyecek kadar küçük, resimdeki gürültüleri bastırarak kadar büyük olması gerekmektedir. Bu amaçla, işlem penceresi büyüklüğünün belirlenebilmesi için [3, 153] arasındaki değerler yinelemeli olarak çalıştırılmış ve işlem pencere boyutu 13 olarak belirlenmiştir. Sınıflandırma algoritmalarından KNN algoritmasında en iyi sonuca, k değerinin 1 olarak seçildiği f-KNN de ulaşılmıştır. Diğer sınıflandırma algoritmalarında elde edilen sonuçlarda kullanılan parametreler detaylı olarak anlatılmıştır.

4.2. Önerilen Algoritmaların Çıktıları

4.2.1. Ön işlem adımında kullanılan algoritmaların çıktıları


Şekil 4.1, 4.2 ve 4.3’de verilen akış şemasında resme ilk olarak ön işleme algoritmaları uygulanmaktadır. PD görüntülerindeki ışık saçılma probleminden kurtulmak amacıyla Şekil 4.4 - (a)’da gösterilen resme ilk olarak HF uygulanmaktadır. Şekil 4.4 - (b)’de HF uygulandıktan sonraki ışık saçılmaları azaltılmış resim gösterilmektedir. Işık saçılmaları azaltılan resimdeki damar görüntüsüne zarar vermeden gürültülerin azaltılarak daha başarılı bir segmentasyon işlemi yapılabilmesi amacıyla PMAD işlemi uygulanarak, Şekil 4.4 - (c)’de gösterilen gürültüsü azaltılmış resim elde edilmiştir.



Şekil 4.4. Ön işlem algoritmalarının PD çıktıları
(a) PD girdi resmi, (b) HF uygulanmış resim, (c) PMAD uygulanmış resim

4.2.2. Segmentasyon ve son işlem adımlarında kullanılan algoritmaların çıktıları

Şekil 4.4 - (c)'de elde edilen resimdeki damarlı bölgeyi dokudan ayırt edebilmek amacıyla Niblack Segmentasyon algoritması uygulanmıştır. Böylelikle Şekil 4.5 - (b)'deki damarlı bölgeler çıkarılmış ve görüntü gri seviyeden ikili seviye resme dönüştürülmüştür. Son işlem aşamasında, Şekil 4.5 - (b) ile gösterilen damar görüntülerindeki gürültülerden kurtulmak ve damardaki kopmaları azaltmak amacıyla morfolojik işlemler uygulanmıştır. Bu amaçla disk şeklinde bir yapılandırma elemanı kullanılarak resimde morfolojik kapama işlemi yapılmıştır. Morfolojik kapama, aynı yapısal eleman kullanarak sırasıyla, morfolojik genişletme ve aşındırma işlemlerinin yapılmasına verilen isimdir. Birbirlerine bağlı olan damarlardaki ufak kopukluklar tamamlanıp, nesne içindeki küçük boşluklar doldurulduktan sonra resme aşındırma işlemi uygulanmıştır. Daha sonra resme inceltme algoritması uygulanarak damar görüntüsü çıkarılmış ve Şekil 4.5 - (c)'de gösterilen damar resmi elde edilmiştir.



Şekil 4.5. Segmentasyon ve son işlem algoritmalarının PD çıktıları
(a) PMAD çıktısı, (b) Niblack çıktısı, (c) Morfolojik işlemler ve iskeletin çıkarılması

4.3. Öznitelik Seçimleri ve Etkileri

Öznitelik seçimi aşamasında, ilk olarak uzamsal domainindeki bazı istatistiksel ve geometri tabanlı öznitelikler üzerinde çalışmalara başlanılmıştır. Bunlar; Entropi, Standart sapma, Ağırlık merkezi, Ortalama gri seviye değeri, Uç sayısı, Çatallaşma sayısı, Çevre ve Alan bilgisi olarak sayılabilir. Bu özniteliklerin kendi aralarındaki kombinasyonel eşleştirmelerle yapılan çalışmalarda elde edilen sonuçlara bakılarak, Entropi, Standart sapma ve Ağırlık merkezi dışındaki özniteliklerin başarı oranına yeterince olumlu katkı yapmadığı görülmüş, bu nedenle çalışmanın devamında bunlar dışındaki öznitelikler çıkarılmıştır. Entropi, Standart sapma, Ağırlık merkezi ile birlikte, geliştirilen *HTP* ve *VTP* öznitelikleri kullanılmaya devam edilmiştir.

Tez çalışmasının başlarında *HTP* ve *VTP* öznitelik başarı oranlarının, uzamsal domain özniteliklerinden olan Ağırlık merkezi, Entropi ve Standart sapma başarı oranları arasındaki yerini ve başarı oranlarına etkisini görmek amacıyla Şekil 4.1 ile belirtilen akış şemasına göre, VS1 veri seti üzerinde, KNN sınıflandırma algoritması kullanılarak yapılan çalışma sonuçları Çizelge 4.1’de paylaşılmıştır. Kullanılan KNN sınıflandırma algoritmasında, uzaklık metriği olarak Öklid, Mahalanobis ve Şehir Blok uzaklıkları incelenmiş, en başarılı sonuca Şehir Blok uzaklığı kullanılması durumunda ulaşılmıştır. VS1 veri setinde bulunan 64 sınıf ve her sınıfta bulunan 15 örnek resimden, 10 tanesi eğitim veri seti için kullanılırken kalan 5 tanesi ise test veri seti olarak kullanılmıştır. VS1 veri seti üzerinde aynı öznitelikler ve sınıflandırma aşamasında ÇD tekniği kullanılarak yapılan çalışma sonuçları Çizelge 4.2’de verilmiştir. Çizelge 4.1’e göre, Ağırlık merkezinin x ve y koordinatlarının öznitelik olarak sisteme birlikte verilmesiyle yapılan sınıflandırmada başarı oranı % 77.81, Entropi ve Standart sapma özniteliklerinin birlikte kullanılması durumunda ise başarı oranı % 67.81 olmaktadır. Sadece *HTP* ve *VTP* özniteliklerinin birlikte kullanılması durumunda sistemin başarı oranı % 81.88’e çıkarken, mevcut özniteliklerin tamamı kullanılırsa bu oran % 98.13’e ulaşmaktadır. Her bir özneliğin teker teker sınıflandırıcıya gönderilmesi çok büyük bir anlam ifade etmese de, henüz çalışmanın başlarında olduğu için yeni çıkarılan özniteliklerin toplam başarı oranına etkisi öğrenilmek istenilerek Çizelge 4.1 çıkarılmış ve özniteliklerin ikiyeşerli başarı oranları gösterilmiştir. Çizelge 4.1’e göre önerilen yeni özniteliklerin başarı oranını artırıcı yönde etki yaptığı görülmektedir. Buraya kadar KNN sınıflandırma algoritmasındaki k değeri 1 ola-

rak kabul edilmiştir. KNN sınıflandırma algoritmasında k değerinin 3 seçilmesi durumunda başarı oranı % 94.69, k değerinin 5 olarak kabul edilmesi durumunda ise başarı oranı % 92.19 olarak elde edilmiştir. Dolayısıyla k için en başarılı sonuç, k 'nın 1 olarak kabul edildiği f-KNN'de elde edilmiştir. Alınan başarılı sonuçlar nedeniyle çalışma detaylandırılmaya başlanmıştır.

Çizelge 4.1. Özniteliklerin başarı oranı üzerindeki etkilerinin KNN ile ölçülmesi

Öznitelikler	Başarı Oranı (%)
Ağırlık merkezi (x,y)	77.81
Entropi & Standart sapma	67.81
HTP & VTP	81.88
Hepsi	98.13

4.4. Sınıflandırma Sonuçları

4.4.1. Uzamsal domainde yapılan sınıflandırma sonuçları

Çıkarılan özneliğin sadece tek bir sınıflandırma algoritmasında iyi bir sonuç üretmiş olması tutarlı olduğunu göstermeyeceği için KNN dışında SVM, Topluluk Öğrenmesi, DA ve Karar Ağacı sınıflandırma algoritmaları kullanılarak çalışmalar yapılmıştır. Yapılan çalışmada Entropi, Standart sapma, Ağırlık merkezi (x, y), HTP ve VTP öznelikleri kullanılmıştır. VS1 veri seti kullanılarak elde edilen Çizelge 4.2'deki KNN sınıflandırma sonuçlarına, 3-kat ve 5-kat ÇD uygulanarak ulaşılmıştır. KNN sınıflandırma algoritmasında, f-KNN kullanılması, yani k 'nın 1 olarak seçilmesi durumunda en iyi sonuca ulaşılmıştır. Uzaklık metriği olarak Öklid, Mahalanobis ve Şehir Blok uzaklıkları incelenmiş, en başarılı sonuca Şehir Blok uzaklığı kullanılması durumunda ulaşılmıştır. Karar Ağaçlarından en iyi başarı oranının elde edildiği CT sınıflandırma algoritmasında maksimum bölme sayısı 100, bölünme kriteri olarak Gini'nin çeşitlilik indeksi kabul edilmiştir. Topluluk öğrenme sınıflandırıcısında, çeşitlilik oluşturma bileşeni olarak Torbalama, Adaboost, Alt Uzay ve RUSBoost kullanılmış ve en yüksek başarı oranının elde edildiği Torbalama sonuçları paylaşılmıştır. SVM için en iyi başarı, çoklu sınıflandırma için 1'e karşı 1 yöntemiyle ve Doğrusal Çekirdek Fonksiyonu seçilmesi durumunda elde edilmiştir. DA algoritmasında, LDA ve QDA uygulanmış olup, düzenleme (regularization) işlemi için köşegen kovaryans seçilmiştir. Daha başarılı sonuçlar üreten LDA sonuçları paylaşılmıştır. Çizelge 4.2'de gösterilen sonuçlar incelenecek olursa, hem 3-kat

hem de 5-kat ÇD sonuçlarının tamamında öznitelik vektörümüze *HTP* ve *VTP* öznitelikleri eklenmesi durumunda, tercih edilen sınıflandırma yöntemine bakılmaksızın başarı oranlarında artışlar gözlenmiştir.

Çizelge 4.2. HTP ve VTP özniteliklerinin, VS1 veri seti kullanılması durumunda uzamsal domainde elde edilen özniteliklerle füzyonu sonucu sınıflandırma başarı oranlarına etkisi

Uzamsal Domain				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		Seçili Öznitelikler	HVTP + Seçili Öznitelikler	Başarıya Etkisi
3 – kat	<i>Karar Ağacı</i>	89.00	89.80	+00.80
	<i>Topluluk</i>	84.20	88.40	+04.20
	<i>SVM</i>	93.20	94.10	+00.90
	<i>KNN</i>	95.80	96.90	+01.10
	<i>DA</i>	90.80	91.60	+00.80
	<i>Karar Ağacı</i>	90.80	91.90	+01.10
5 – kat	<i>Topluluk</i>	84.80	88.10	+03.30
	<i>SVM</i>	94.00	94.80	+00.80
	<i>KNN</i>	97.00	97.40	+00.40
	<i>DA</i>	91.30	91.40	+00.10

VS1 veri setinde kullanılan öznitelikler, aynı sınıflandırıcılar kullanılarak VS2 veri seti içinde uygulanmıştır. Ancak VS2 veri setinde sınıf sayısının 600 olması sebebiyle SVM sınıflandırıcısında çoklu sınıflandırma için, 1'e karşı 1 yönteminde yapması gereken $n*(n-1)/2$ adet sınıflandırma sayısının çok fazla çıkması nedeniyle yetersiz hafıza hatası vermiş bu nedenle 1'e karşı hepsi yöntemi tercih edilmiştir. Ayrıca VS2 için f-KNN'de uzaklık parametresi olarak daha iyi sonuç veren Öklid uzaklığının sonuçları paylaşılmıştır. Karar Ağaçlarından en iyi başarı oranının elde edildiği CT sınıflandırma algoritmasında ise VS2 veri setindeki sınıf sayısı fazla olması nedeniyle maksimum bölme sayısı 600 olarak belirlenmiştir. Topluluk öğrenme sınıflandırıcısında da aynı şekilde Torbalama sonuçları paylaşılmıştır. DA algoritmasında, LDA ve QDA uygulanmıştır. Düzenleme işlemi için köşegen kovaryans seçilmiş ve daha başarılı sonuçlar üreten LDA sonuçları paylaşılmıştır. Elde edilen sonuçlar Çizelge 4.3'de gösterilmiştir. Bu sonuçlara göre elde edilen başarı oranları düşük olsa dahi HVTP özniteliğinin başarı oranını artırıcı yöndeki etkisi çok net görülmektedir. Hem 3 hem de 5 kat ÇD sonuçları incelendiğinde tüm sınıflandırıcılar için HVTP özniteliklerinin başarı oranlarını artırdığı görülmektedir.

Çizelge 4.3. HTP ve VTP özniteliklerinin, VS2 veri seti kullanılması durumunda uzamsal domainde elde edilen özniteliklerle füzyonu sonucu sınıflandırma başarı oranlarına etkisi

Uzamsal Domain				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		Seçili Öznitelikler	HVTP + Seçili Öznitelikler	Başarıya Etkisi
3 – kat	Karar Ağacı	25.00	31.70	+06.70
	Topluluk	40.50	60.00	+19.50
	SVM	39.50	53.10	+13.60
	KNN	38.90	52.00	+13.10
	DA	22.70	28.80	+06.10
	Karar Ağacı	26.00	33.40	+07.40
5 – kat	Topluluk	42.10	62.40	+20.30
	SVM	41.50	54.80	+13.30
	KNN	40.50	54.30	+13.80
	DA	25.80	29.80	+04.00

4.4.2. Frekans domaininde yapılan sınıflandırma sonuçları

Şekil 4.2’de akış şeması gösterilen PD tanıma sistemi incelendiğinde; frekans domaininde elde edilen geometri tabanlı özniteliklerden olan Genel Fourier Tanımlayıcıları kullanılarak, morfolojik işlemler sonucunda damarlı bölgeleri çıkarılan her bir PD görüntüsü için 1x52 boyutlarında bir öznitelik vektörü elde edilmektedir. VS1 veri seti kullanılarak PD resimlerinin frekans domaini öznitelikleri çıkarıldıktan sonra, tercih edilen sınıflandırıcılardan olan SVM, KNN, Topluluk Öğrenmesi, DA ve Karar Ağacı sınıflandırma algoritmalarında, 3-kat ve 5-kat Çapraz Sorgulama yapılarak başarı oranları bulunmuş, sonrasında çıkarılan öznitelikler ile HTP ve VTP öznitelikleri füzyon yöntemi yardımıyla birleştirilerek yeniden sınıflandırma işlemi yapılmıştır. HVTP özniteliklerinin ölçümlerinin frekans domaini öznitelikleri üzerindeki etkilerinin farklı bir veri seti üzerinde de görülebilmesi adına aynı sınıflandırıcılar kullanılarak VS2 veri seti üzerinde de uygulanmıştır. Böylelikle yeni geliştirilen özniteliklerin başarı oranına etkisi gözlemlenmiştir.

Sınıflandırma algoritmalarında kullanılan parametreler, tercih edilen uzaklık metrikleri ve çalışılan yöntemlerden bahsedilecek olursa; KNN için en iyi sonuç, Şehir Blok Mesafesi yöntemi ile k değerinin 1 olması yani f-KNN kullanılması durumunda elde edilmektedir. SVM sınıflandırıcısında, çoklu sınıflandırma kullanılarak ulaşılan en iyi sonuca, 1’e karşı 1 yöntemiyle ve çekirdek fonksiyon olarak Doğrusal Çekirdek Fonksiyon seçilmesi ile ulaşılmaktadır. Karar Ağaçlarından en iyi başarı oranının elde edildiği CT sınıflandırma algoritmasında maksimum bölme sayısı 100, bölünme kriteri olarak Gini’nin çeşitlilik indeksi kabul edilmiştir. Topluluk Öğrenmesi için en yüksek başarı

oranına Torbalama ile ulaşılmaktadır. DA algoritmasında ise LDA ve QDA uygulanmış olup, düzenleme (regularization) işlemi için köşegen kovaryans seçilmiştir. Nispeten daha başarılı sonuçlar üreten LDA sonuçları paylaşılmıştır. Çizelge 4.4’de gösterilen sonuçlar incelenecek olursa, hem 3-kat hem de 5-kat ÇD sonuçlarının tamamında 52 boyutlu öz-nitelik vektörüne *HTP* ve *VTP* öz-nitelikleri eklenmesi durumunda, tercih edilen sınıflandırma yönteminden bağımsız olarak başarı oranı artmaktadır. Özellikle bu çalışmada düşük başarı oranına sahip Topluluk Öğrenmesi ve Karar Ağacının bir alt kolu olan CT yöntemlerinin *HTP* ve *VTP* öz-niteliklerinin eklenmesi durumunda başarı oranlarındaki artış, bu örnek için yüksek başarı oranına sahip SVM, DA ve KNN sınıflandırma algoritmalarındakine göre fazladır. Her iki ÇD sonuçları için bu çalışmada ulaşılan en iyi başarı oranı 5-kat ÇD kullanılması durumunda KNN ile % 99.20 olmuştur.

Çizelge 4.4. *HTP* ve *VTP* öz-niteliklerinin, VS1 kullanılması durumunda frekans domaininde elde edilen GFD öz-nitelikleriyle füzyonu sonucu sınıflandırma başarı oranlarına etkisi

Frekans Domaini				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		GFD	HVTP + GFD	Başarıya Etkisi
3 – kat	<i>Karar Ağacı</i>	62.90	76.00	+13.10
	<i>Topluluk</i>	62.30	73.10	+10.80
	<i>SVM</i>	97.60	97.80	+00.20
	<i>KNN</i>	98.75	99.10	+00.35
	<i>DA</i>	96.90	97.30	+00.40
5 – kat	<i>Karar Ağacı</i>	59.80	73.60	+13.80
	<i>Topluluk</i>	60.00	71.60	+11.60
	<i>SVM</i>	98.00	98.20	+00.20
	<i>KNN</i>	99.10	99.20	+00.10
	<i>DA</i>	96.80	97.20	+00.40

VS1 veri setinde kullanılan GFD ve HVTP öz-nitelikleri, aynı sınıflandırıcılar kullanılarak VS2 veri seti içinde uygulanmıştır. VS2 veri setindeki sınıf sayısının VS1 veri setindeki sınıf sayısına göre çok fazla olması nedeniyle SVM sınıflandırıcısında 1’e karşı 1 yöntemi kullanılınca yapması gereken çok sayıdaki sınıflandırma nedeniyle yetersiz hafıza hatası vermiş, bu nedenle 1’e karşı 1 yöntemi yerine 1’e karşı hepsi yöntemi tercih edilmiştir. Aynı zamanda VS2 için KNN’de uzaklık parametresi olarak daha iyi sonuç veren Öklid uzaklığı seçilmiş ve sonuçları paylaşılmıştır. Topluluk öğrenme sınıflandırıcısında da bir önceki VS1 sonuçlarında paylaşılan Torbalama sonuçları paylaşılmıştır. Karar Ağaçlarından en iyi başarı oranının elde edildiği CT sınıflandırma algoritmasında ise VS2 veri setindeki sınıf sayısının fazla olması sebebiyle maksimum bölme sayısı 600

seçilmiştir. DA algoritmasında ise LDA ve QDA uygulanmış, düzenleme işlemi için köşegen kovaryans seçilmiş ve daha başarılı sonuçlar üreten LDA sonuçları paylaşılmıştır. Çizelge 4.5’de gösterildiği haliyle, elde edilen bu sonuçlara göre hem 3 kat hem de 5 kat ÇD sonuçlarında, HVTP özniteliklerinin tüm sınıflandırıcılar için başarı oranlarında iyileştirmeler yaptığı görülmektedir.

Çizelge 4.5. HTP ve VTP özniteliklerinin, VS2 veri seti kullanılması durumunda frekans domaininde elde edilen GFD öznitelikleri ile füzyonu sonucu sınıflandırma başarı oranlarına etkisi

Frekans Domaini				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		GFD	HVTP + GFD	Başarıya Etkisi
3 – kat	Karar Ağacı	24.50	26.60	+02.10
	Topluluk	56.20	57.90	+01.70
	SVM	61.70	62.20	+00.50
	KNN	62.50	63.70	+01.20
	DA	50.20	52.20	+02.00
5 – kat	Karar Ağacı	25.60	29.40	+03.80
	Topluluk	57.60	61.50	+03.90
	SVM	65.00	65.70	+00.70
	KNN	65.10	66.10	+01.00
	DA	51.20	52.80	+01.60

VS1 ve VS2 veri setleri üzerinde yapılan çalışma sonuçlarının yer aldığı Çizelge 4.2, 4.3, 4.4 ve 4.5 incelendiğinde *HTP* ve *VTP* özniteliklerinin gerek uzamsal gerekse frekans domaininde PD tanıma sisteminin başarı oranını artırıcı yönde bir etki yaptığı görülmektedir. VS1 kullanılarak uzamsal domainde 3-kat ve 5-kat ÇD yapıldığı durumda elde edilen en yüksek başarı oranı % 97.40 ile KNN olmuştur. Frekans domaininde ise Fourier Tanımlayıcılar aracılığıyla çıkarılan 52 adet öznitelik, *HTP* ve *VTP* öznitelikleri ile birleşerek toplamda 54 öznitelik çıkarılmıştır. Yapılan çalışmalar sonucunda en yüksek başarı oranı, KNN sınıflandırma algoritması 5-kat ÇD yöntemi kullanılarak % 99.20 olarak bulunmuş ve SCI-e indeksli bir dergide 2020 yılında yayınlanmıştır (Titrek ve Baykan, 2020).

Literatürde yapılmış benzer çalışmalar, yararlanılan metotlar ve öznitelik çıkarma algoritmaları, kullanılan veri setleri ve sınıflandırıcılar ile başarı oranlarının karşılaştırmalı gösterimi Çizelge 4.14’de gösterilmektedir. Kullanılan veri setinin, sınıf ve örneklerin boyutları dikkate alındığında önerilen öznitelik çıkarma yönteminin PD görüntülerindeki başarısı görülmektedir.

4.4.3. GLRLM, GLCM ve SFTA kullanılarak çıkarılan özniteliklerin HVTP öznitelikleri ile füzyon sonuçları

Geliştirilen HVTP öznitelik çıkarma yönteminin etkinliğini daha detaylı incelemek amacıyla, *HTP* ve *VTP* öznitelikleri GLRLM, GLCM ve SFTA yöntemlerinden elde edilecek özniteliklerle füzyon yöntemi yardımıyla birleştirilmiştir. Önerilen yöntemin daha büyük veri setlerindeki başarıya etkisini görmek için 64 sınıflık 960 örneğe sahip VS1'in yanında, 600 sınıflık ve 6000 PD örneğine sahip VS2 veri seti üzerinde de çalışmalar yapılmıştır.

Sınıflandırma algoritması olarak Topluluk Öğrenmesi, KNN, SVM, Karar Ağacı ve DA algoritmaları uygulanmış ve başarı oranı en yüksek çıkan sınıflandırıcı sonuçları paylaşılmıştır. Sınıflandırma algoritmalarından Topluluk Öğrenmesi algoritmasında, Adaboost, RUSBoost, Torbalama ve SD yöntemleri tercih edilerek sonuçlar değerlendirilmiştir. Topluluk Öğrenmesi algoritmasının kullanıldığı sınıflandırmalarda en başarılı sonuçlar SD yöntemi tercih edilmesi durumunda elde edilmiştir. Öğrenen tipinin (Learner Type) diskriminant olduğu SD yönteminde, öğrenen sayısı ise 30 olarak belirlenmiştir. Kullanılan özniteliklerin toplam sayısına göre alt uzay boyutu belirlenmektedir. KNN sınıflandırma algoritmasında ise k değeri 1, 2, 3, ..., 10 değerleri iterative olarak çalışılmış ve en yüksek sınıflandırma başarısı k 'nın değerinin 1 olduğu f -KNN için elde edilmiştir. Uzaklık metriği olarak en iyi başarının elde edildiği Öklid uzaklığı kullanılmıştır. SVM sınıflandırıcısında, çekirdek fonksiyonları olarak Doğrusal, İkinci Dereceden (Quadratic - Karesel), Kübik ve Gaussian çekirdek fonksiyonları seçilerek ayrı ayrı sınıflandırma işlemleri yapılmıştır. VS1 veri seti için çoklu sınıflandırma kullanılarak ulaşılan en iyi sonuca, 1'e karşı 1 yöntemiyle ve çekirdek fonksiyon olarak Doğrusal Çekirdek Fonksiyon seçilmesi ile ulaşılmaktadır. Ancak VS2 veri seti için sınıf sayısının 600 olması nedeniyle SVM sınıflandırıcısında çoklu sınıflandırma için, 1'e karşı 1 yönteminde yapması gereken sınıflandırma sayısının çok fazla çıkması nedeniyle yetersiz hafıza hatası vermiş bu nedenle 1'e karşı hepsi yöntemi tercih edilmiştir. Karar Ağacının kullanıldığı sınıflandırma algoritmasında, maksimum bölünme sayısı 4, 20 ve 100 olarak seçilerek sırasıyla basit, orta ve karmaşık ağaç yapısı denenmiş, bölünme kriteri olarak Gini'nin çeşitlilik indeksi kabul edilmiş ve en iyi başarı oranının elde edildiği CT sonuçları verilmiştir. DA algoritmasında ise LDA ve QDA uygulanmış olup, düzenleme (regularization) işlemi için

köşegen kovaryans seçilmiştir. Nispeten daha başarılı sonuçlar üreten LDA sonuçları paylaşılmıştır.

Şekil 4.3'deki akış diyagramında görüldüğü üzere GLRLM, GLCM ve SFTA yöntemlerinden elde edilen öznitelikler, ön işlem aşamasında HF ve PMAD uygulanması sonucu elde edilen görüntüler kullanılarak çıkarılmaktadır. GLRLM öznitelik çıkarma yöntemi kullanılarak özniteliklerin çıkarılabilmesi için ilk olarak, resmin kaç bitlik bir resme dönüştürüleceği parametresinin belirlenmesi gerekmektedir. Bu tez çalışmasında ölçeklenecek bit seviyesi 8 olarak seçilmiştir. GLRLM öznitelik çıkarma yöntemi tarafından çıkarılan 11 öznitelik, dört yönde ($\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135°) hesaplanarak toplam 44 öznitelik elde edilmiştir. GLCM öznitelik çıkarma yöntemi kullanılarak çıkarılan 20 öznitelik, iki yönde ($\theta = 0^\circ$ ve 90°) ve dört yönde ($\theta = 0^\circ, 45^\circ, 90^\circ$ ve 135°) ayrı ayrı hesaplanmıştır. Pikseller arası mesafe 1 olarak belirlenmiştir. İki yönde yapılan hesaplama sonucunda 40 öznitelik çıkarılırken, dört yönde yapılan hesaplama sonucunda 80 öznitelik elde edilmiştir. SFTA öznitelik çıkarma yöntemini kullanarak özniteliklerin çıkarılabilmesi için ilk olarak, kullanılacak eşik seviyesi sayısının parametre olarak belirlenmesi gerekmektedir. Bu amaçla, [2, 70] arasındaki eşik seviyesi sayıları yinelemeli olarak çalıştırılmış ve en başarılı sonucun elde edildiği değer olan 7 değeri, kullanılacak eşik seviyesi sayısı olarak belirlenmiştir. Böylelikle SFTA öznitelik çıkarma yöntemi kullanılarak 39 öznitelik elde edilmiştir.

Çıkarılan öznitelikler Topluluk Öğrenmesi, KNN, SVM, Karar Ağacı ve DA sınıflandırıcılarına, 3-kat ve 5-kat ÇD tekniği kullanılarak gönderilmiş ve başarı oranları elde edilmiştir. Sınıflandırıcılarda kullanılan parametreler daha önceden anlatılmış ve çizelgelerde, sınıfına göre elde edilen en başarılı sonuçlar kalın yazı tipi ile vurgulanmıştır. Yapılan çalışmalar sonucunda Çizelge 4.6'ya göre VS1 için GLRLM öznitelik çıkarma yönteminin kullanıldığı çalışmada, 5-kat ÇD tekniği ile hem Topluluk Öğrenme, hem de KNN sınıflandırıcılarında en yüksek başarı oranı olarak % 99.50 değerine ulaşılmıştır. GLRLM öznitelik çıkarma yönteminin kullanıldığı çalışmada, VS2 için Topluluk Öğrenme sınıflandırıcı kullanılarak en yüksek başarı oranı elde edilmiştir. 5-kat ÇD tekniği kullanılarak yapılan çalışmada, % 91.80'lik bir başarı oranı elde edilmiştir (Titrek ve Baykan, 2023).

Çizelge 4.6. VS1 ve VS2 veri setleri için GLRLM sonuçları (%)

ÇD	Sınıflandırıcılar	VS1	VS2
3 – kat	<i>Karar Ağacı</i>	91.00	09.70
	<i>Topluluk</i>	99.20	91.30
	SVM	97.80	88.30
	KNN	99.40	82.90
	DA	95.80	70.00
	<i>Karar Ağacı</i>	91.80	09.80
5 – kat	<i>Topluluk</i>	99.50	91.80
	SVM	98.20	88.70
	KNN	99.50	84.90
	DA	95.70	70.30

GLCM ve 3-kat ve 5-kat ÇD teknikleri kullanılarak VS1 ve VS2 üzerinde yapılan sınıflandırma çalışmasının sonuçları Çizelge 4.7'de görülmektedir. Çizelge 4.7'ye göre, GLCM yöntemi kullanılarak, iki yönde ve dört yönde öznitelik vektörleri çıkarılmıştır. İki yönde GLCM öznitelik çıkarma yöntemi kullanılarak yapılan çalışmada, VS1 için 5-kat ÇD tekniği ve Topluluk Öğrenme sınıflandırıcısı kullanılarak % 99.30'luk bir başarı oranı yakalanmıştır. VS2 için en yüksek başarı oranı ise, dört yönde GLCM öznitelik çıkarma yöntemi kullanılarak, Topluluk Öğrenme sınıflandırıcısı ve 5-kat ÇD tekniklerinin uygulanmasıyla % 91.10 olarak elde edilmiştir (Titrek ve Baykan, 2023).

Çizelge 4.7. VS1 ve VS2 veri setleri için GLCM sonuçları (%)

İki yönde GLCM			
ÇD	Sınıflandırıcılar	VS1	VS2
3 – kat	<i>Karar Ağacı</i>	92.30	08.40
	<i>Topluluk</i>	99.20	83.20
	SVM	95.70	73.10
	KNN	97.80	58.10
	DA	93.90	48.20
	<i>Karar Ağacı</i>	92.80	09.30
5 – kat	<i>Topluluk</i>	99.30	84.10
	SVM	96.70	75.30
	KNN	98.00	60.40
	DA	93.90	48.30
Dört yönde GLCM			
3 – kat	<i>Karar Ağacı</i>	90.60	09.10
	<i>Topluluk</i>	99.10	91.00
	SVM	95.70	74.20
	KNN	97.50	63.90
	DA	91.50	51.90
	<i>Karar Ağacı</i>	90.80	09.80
5 – kat	<i>Topluluk</i>	99.20	91.10
	SVM	96.00	75.10
	KNN	97.50	65.60
	DA	92.00	52.80

VS1 ve VS2 veri setleri için SFTA öznitelik çıkarma yöntemiyle elde edilen öznitelik vektörü kullanılarak, 3-kat ve 5-kat ÇD teknikleri yardımıyla yapılan sınıflandırma çalışmasını sonuçları Çizelge 4.8’de görülmektedir. Çizelge 4.8’e göre, VS1 üzerinde yapılan çalışmada elde edilen en yüksek başarı oranını, 5-kat ÇD tekniği kullanan Topluluk Öğrenme sınıflandırıcısı % 99.00’lık başarı oranı ile yakalamıştır. VS2 üzerinde yapılan çalışmada da yine aynı Topluluk Öğrenmesi sınıflandırıcısı 5-kat ÇD kullanarak % 84.80 ile en yüksek başarıya ulaşmıştır (Titrek ve Baykan, 2023).

Çizelge 4.8. VS1 ve VS2 veri setleri için SFTA sonuçları (%)

ÇD	Sınıflandırıcılar	VS1	VS2
3 – kat	<i>Karar Ağacı</i>	87.40	09.20
	<i>Topluluk</i>	98.90	83.70
	<i>SVM</i>	97.40	69.00
	<i>KNN</i>	98.40	77.00
	<i>DA</i>	94.20	69.30
5 – kat	<i>Karar Ağacı</i>	91.10	09.50
	<i>Topluluk</i>	99.00	84.80
	<i>SVM</i>	97.60	70.80
	<i>KNN</i>	98.80	79.10
	<i>DA</i>	94.10	70.00

GLRLM, GLCM, SFTA öznitelik çıkarma yöntemleri kullanılarak elde edilen başarılı sınıflandırıcılar Topluluk Öğrenmesi ve KNN sınıflandırıcılar olmuştur. Topluluk Öğrenmesi algoritmasının kullanıldığı sınıflandırmalarda en başarılı sonuçlar, SD yöntemi tercih edilmesi durumunda, KNN sınıflandırıcılarda ise k değerinin 1 olduğu f-KNN durumunda elde edilmiştir. Karar Ağacı algoritmasındaki en başarılı sonuca CT, DA algoritmasındaki en başarılı sonuca ise LDA kullanılması durumunda ulaşılmıştır.

HTP ve *VTP* öznitelikleri, Şekil 4.3’de bulunan akış diyagramındaki son işlem aşamasından sonra elde edilen ve Şekil 4.5 - (c) ile de gösterilen damar resmi kullanılarak çıkarılmaktadır. Çıkarılan *HTP* ve *VTP* öznitelikleriyle GLRLM, GLCM ve SFTA yöntemlerinden çıkarılan öznitelikler ayrı ayrı veya hepsi olacak biçimde, Şekil 4.3’de gösterildiği gibi öznitelik füzyonu yöntemi kullanılarak birleştirilmesi sonucu öznitelik vektörü oluşturulmuştur. Oluşturulan öznitelik vektörü, sınıflandırma algoritmalarından Topluluk Öğrenmesi, KNN, SVM, Karar Ağacı ve DA sınıflandırıcılarına, 3-kat ve 5-kat ÇD tekniği kullanılarak gönderilmiş ve elde edilen başarı oranları ile sonuçlar değerlendirilmiştir. Sınıflandırıcılarda kullanılan parametreler daha önceden anlatılmış ve çizelgelerde, sınıfına göre elde edilen en başarılı sonuçlar kalın yazı tipi ile vurgulanmıştır.

GLRLM, GLCM, SFTA yöntemlerinin farklı kombinasyonlarda HVTP yöntemiyle füzyon yapılması sonucu elde edilen sonuçlar değerlendirilecek olursa; GLRLM ve HVTP öznitelik çıkarma yönteminden elde edilen sonuçların öznitelik füzyonu yöntemi yardımıyla birleştirilip, sınıflandırıcılara 3-kat ve 5-kat ÇD kullanılarak gönderilmesi sonucu, VS1 ve VS2 üzerinde yapılan çalışmalar Çizelge 4.9'da gösterilmektedir. Çizelge 4.9'da, VS1 için elde edilen ve kalın yazı tipi ile gösterilen sonuçlara göre, HVTP ve GLRLM füzyonundan ulaşılan en yüksek başarı, Topluluk Öğrenme algoritmasında 3-kat ÇD tekniği ile % 99.20'den % 99.70'e çıkarak elde edilmiştir. 5-kat ÇD tekniği kullanılması durumunda elde edilen en yüksek başarı oranına HVTP ve GLRLM füzyonunda, Topluluk Öğrenme ile % 99.50'den % 99.70'e çıkarak ulaşılmıştır. Bu sonuçlarla Çizelge 4.14'de gösterildiği üzere VS1 için en iyi başarı oranı olan % 99.70'e ulaşılmış ve SCI-e indeksli bir dergide 2023 yılında yayınlanmıştır (Titrek ve Baykan, 2023). VS2 için elde edilen en yüksek başarı oranı değerlendirildiğinde HVTP ve GLRLM füzyonu ile Topluluk Öğrenme ve 5-kat ÇD tekniği ile % 93.30 olarak elde edilmiştir. GLRLM ve HVTP öznitelik füzyonu yönteminde, SVM ve KNN sınıflandırıcıları kullanılması durumunda başarıda bir miktar gerileme olsa da, en iyi başarı oranları öznitelik füzyonu yöntemi sonucu Topluluk Öğrenmesi ile elde edilmiştir (Titrek ve Baykan, 2023).

Çizelge 4.9. VS1 ve VS2 veri setleri için HVTP ve GLRLM özniteliklerinin füzyon sonuçları

VS1				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		GLRLM	HVTP + GLRLM	Başarıya Etkisi
3 – kat	<i>Karar Ağacı</i>	91.00	91.60	+00.60
	<i>Topluluk</i>	99.20	99.70	+00.50
	<i>SVM</i>	97.80	97.70	-00.10
	<i>KNN</i>	99.40	99.20	-00.20
	<i>DA</i>	95.80	95.90	+00.10
5 – kat	<i>Karar Ağacı</i>	91.80	92.20	+00.40
	<i>Topluluk</i>	99.50	99.70	+00.20
	<i>SVM</i>	98.20	98.00	-00.20
	<i>KNN</i>	99.50	99.30	-00.20
	<i>DA</i>	95.70	95.80	+00.10
VS2				
3 – kat	<i>Karar Ağacı</i>	09.70	09.90	+00.20
	<i>Topluluk</i>	91.30	92.90	+01.60
	<i>SVM</i>	88.30	87.90	-00.40
	<i>KNN</i>	82.90	81.60	-01.30
	<i>DA</i>	70.00	70.80	+00.80
5 – kat	<i>Karar Ağacı</i>	09.80	10.40	+00.60
	<i>Topluluk</i>	91.80	93.30	+01.50
	<i>SVM</i>	88.70	88.20	-00.50
	<i>KNN</i>	84.90	83.80	-01.10
	<i>DA</i>	70.30	71.80	+01.50

GLCM ve HVTP öznitelik çıkarma yönteminden iki yönde ve dört yönde elde edilen sonuçların öznitelik füzyonu yöntemi yardımıyla birleştirilip, sınıflandırıcılara 3-kat ve 5-kat ÇD kullanılarak gönderilmesi sonucu, VS1 ve VS2 üzerinde yapılan çalışma sonuçları Çizelge 4.10'da gösterilmektedir. Çizelge 4.10'a göre VS1'de en yüksek başarı oranı, HVTP ve iki yönde GLCM öznitelik çıkarma yönteminden elde edilen özniteliklerin füzyon yöntemi yardımıyla birleştirilerek Topluluk Öğrenme algoritmasında 3-kat ÇD ile sınıflandırılması sonucu % 99.50 olarak elde edilmiştir. Bir başka ifadeyle *HTP* ve *VTP* özniteliklerinin, GLCM öznitelikleriyle füzyon yöntemi kullanılarak birleştirilmesi başarı oranını % 99.20'den % 99.50'ye yükselterek iyileştirme sağlamıştır. VS2 üzerinde yapılan çalışmada, HVTP ve dört yönde GLCM yönteminden çıkarılan özniteliklerin füzyonu sonucunda, Topluluk Öğrenme sınıflandırıcısında 5-kat ÇD tekniği kullanılarak elde edilen başarı oranı % 91.10'dan % 91.80'e yükseltilmiştir. Çizelge 4.10'daki sonuçlar, HVTP öznitelik çıkarma yönteminin, VS1 veri seti için kullanılan sınıflandırıcılardan elde edilen başarı oranlarının büyük çoğunluğu üzerinde başarıyı artırıcı yönde etki yaptığını göstermektedir. VS2 veri seti için kullanılan sınıflandırıcılardan 1'e karşı hepsi yönteminin tercih edildiği bütün SVM sınıflandırıcılarında başarı oranını azaltıcı yönde etki yaparken, SVM dışındaki bütün sınıflandırıcılarda başarıyı artırıcı yönde etki yaptığını göstermektedir (Titrek ve Baykan, 2023).

SFTA ve HVTP öznitelik çıkarma yönteminden elde edilen sonuçların öznitelik füzyonu yöntemi yardımıyla birleştirilip, sınıflandırıcılara 3-kat ve 5-kat ÇD kullanılarak gönderilmesi sonucu, VS1 ve VS2 üzerinde yapılan çalışma sonuçları Çizelge 4.11'de verilmiştir. Çizelge 4.11'e göre VS1 için en yüksek başarı oranı, HVTP ve SFTA yöntemlerinden elde edilen özelliklerin, öznitelik füzyonu yöntemi kullanılarak birleştirilmesi ve Topluluk Öğrenme algoritmasında 5-kat ÇD ile sınıflandırılması sonucu % 99.20 olmuştur. Bir başka ifadeyle *HTP* ve *VTP* özniteliklerinin, SFTA yönteminden elde edilen özniteliklerle füzyon yöntemi yardımıyla birleştirilmesi, başarı oranını % 99.00'dan % 99.20'ye yükseltmiştir. VS2 sonuçlarına göre, Topluluk Öğrenme algoritmasında 5-kat ÇD kullanılarak yapılan sınıflandırmada HVTP ile elde edilen özniteliklerin, SFTA kullanılarak çıkarılan özniteliklerle füzyonunun en yüksek elde edilen başarısını % 84.80 oranından % 86.00'ya yükseltmiştir. Çizelge 4.11'e göre, HVTP öznitelik çıkarma yönteminin VS1 ve VS2 veri setleri için, bütün sınıflandırıcılardaki denemelerin çoğunluğu için başarı oranlarına olumlu katkılar yaptığı görülmektedir (Titrek ve Baykan, 2023).

Çizelge 4.10. VS1 ve VS2 veri setleri için HVTP ve GLCM özniteliklerinin füzyon sonuçları (%)

VS1				
ÇD	Sınıflandırıcılar	GLCM	HVTP + GLCM	Başarıya Et-kisi
İki yönde başarı oranı (%)				
3 – kat	<i>Karar Ağacı</i>	92.30	93.00	+00.70
	<i>Topluluk</i>	99.20	99.50	+00.30
	<i>SVM</i>	95.70	96.70	+01.00
	<i>KNN</i>	97.80	98.00	+00.20
	<i>DA</i>	93.90	94.60	+00.70
5 – kat	<i>Karar Ağacı</i>	92.80	94.10	+01.30
	<i>Topluluk</i>	99.30	99.40	+00.10
	<i>SVM</i>	96.70	97.20	+00.50
	<i>KNN</i>	98.00	97.90	-00.10
	<i>DA</i>	93.90	94.10	+00.20
Dört yönde başarı oranı (%)				
3 – kat	<i>Karar Ağacı</i>	90.60	91.80	+01.20
	<i>Topluluk</i>	99.10	99.30	+00.20
	<i>SVM</i>	95.70	96.40	+00.70
	<i>KNN</i>	97.50	97.80	+00.30
	<i>DA</i>	91.50	92.60	+01.10
5 – kat	<i>Karar Ağacı</i>	90.80	92.30	+01.50
	<i>Topluluk</i>	99.20	99.40	+00.20
	<i>SVM</i>	96.00	97.20	+01.20
	<i>KNN</i>	97.50	97.70	+00.20
	<i>DA</i>	92.00	92.70	+00.50
VS2				
İki yönde başarı oranı (%)				
3 – kat	<i>Karar Ağacı</i>	08.40	10.50	+02.10
	<i>Topluluk</i>	83.20	84.70	+01.50
	<i>SVM</i>	73.10	71.80	-01.30
	<i>KNN</i>	58.10	64.80	+06.70
	<i>DA</i>	48.20	53.60	+05.40
5 – kat	<i>Karar Ağacı</i>	09.30	10.30	+01.00
	<i>Topluluk</i>	84.10	84.70	+00.60
	<i>SVM</i>	75.30	73.90	-01.40
	<i>KNN</i>	60.40	66.70	+06.30
	<i>DA</i>	48.30	54.70	+06.40
Dört yönde başarı oranı (%)				
3 – kat	<i>Karar Ağacı</i>	09.10	09.90	+00.80
	<i>Topluluk</i>	91.00	91.10	+00.10
	<i>SVM</i>	74.20	72.80	-01.40
	<i>KNN</i>	63.90	67.00	+03.10
	<i>DA</i>	51.90	55.50	+03.60
5 – kat	<i>Karar Ağacı</i>	09.80	10.70	+00.90
	<i>Topluluk</i>	91.10	91.80	+00.70
	<i>SVM</i>	75.10	74.50	-00.60
	<i>KNN</i>	65.60	68.90	+03.30
	<i>DA</i>	52.80	56.00	+03.20

Çizelge 4.11. VS1 ve VS2 veri setleri için HVTP ve SFTA özniteliklerinin füzyon sonuçları

VS1				
ÇD	Sınıflandırıcılar	Başarı oranı (%)		
		SFTA	HVTP + SFTA	Başarıya Etkisi
3 – kat	<i>Karar Ağacı</i>	87.40	90.60	+03.20
	<i>Topluluk</i>	98.90	99.10	+00.20
	<i>SVM</i>	97.40	97.50	+00.10
	<i>KNN</i>	98.40	98.40	+00.00
	<i>DA</i>	94.20	94.50	+00.30
5 – kat	<i>Karar Ağacı</i>	91.10	91.60	+00.50
	<i>Topluluk</i>	99.00	99.20	+00.20
	<i>SVM</i>	97.60	97.80	+00.20
	<i>KNN</i>	98.80	98.40	-00.40
	<i>DA</i>	94.10	94.60	+00.50
VS2				
3 – kat	<i>Karar Ağacı</i>	09.20	09.60	+00.40
	<i>Topluluk</i>	83.70	84.90	+01.20
	<i>SVM</i>	69.00	71.50	+02.50
	<i>KNN</i>	77.00	80.00	+03.00
	<i>DA</i>	69.30	72.30	+03.00
5 – kat	<i>Karar Ağacı</i>	09.50	10.00	+00.50
	<i>Topluluk</i>	84.80	86.00	+01.20
	<i>SVM</i>	70.80	72.20	+01.40
	<i>KNN</i>	79.10	81.60	+02.50
	<i>DA</i>	70.00	73.40	+03.40

GLRLM, GLCM, SFTA ve HVTP öznitelik çıkarma yöntemlerinden çıkarılan özelliklerin, öznitelik füzyonu yöntemi yardımıyla kombinasyonel olarak birleştirilmesiyle, HVTP'nin başarı oranına etkisi incelenmiştir. Dört yönde GLCM'nin, iki yönde GLCM öznitelikleri ile elde edilen sonuçlara göre daha başarılı olması nedeniyle bu çalışmada dört yönde GLCM ile devam edilmiştir. Sınıflandırıcı olarak en iyi sonuçların elde edildiği Topluluk Öğrenmesi (SD), KNN (f-KNN) seçilmiş ve 5-kat ÇD sonuçları Çizelge 4.12'de paylaşılmıştır.

VS1 kullanılarak, GLCM, GLRLM ve HVTP yöntemlerinden çıkarılan özniteliklerin füzyon yöntemiyle birleştirilerek elde edilen öznitelik vektörü, Topluluk Öğrenmesinde 5-kat ÇD tekniği kullanılarak sınıflandırılmış ve % 99.60'lık bir başarı elde edilmiştir. Benzer şekilde VS1 kullanılarak GLRLM, SFTA ve HVTP yöntemlerinden çıkarılan özniteliklerin füzyon yöntemi kullanılarak birleştirilmeleri sonucunda, eşdeğer koşullar altında Topluluk Öğrenmesinde % 99.60'lık bir başarı oranı elde edilmiştir. VS2 için ise en yüksek başarı oranı, GLCM, GLRLM, SFTA ve HVTP yöntemlerinden çıkarılan özniteliklerin füzyon yöntemi kullanılarak birleştirilmesi sonucu elde edilen öznitelik vektörünün Topluluk Öğrenmesinde 5-kat ÇD tekniği ile sınıflandırılmasıyla % 97.60 olarak

bulunmuştur. VS2 için elde edilen % 97.60'lık başarı bu çalışmada ulaşılan en iyi sonuç olmuştur. Çizelge 4.12'deki sonuçlara göre HVTP öznitelik çıkarma yöntemi her iki veri seti için, kullanılan Topluluk Öğrenmesi ve KNN sınıflandırıcılarında elde edilen başarı oranlarına artırıcı yönde olumlu katkı yapmıştır (Titrek ve Baykan, 2023).

Çizelge 4.12. VS1 ve VS2 veri setleri için HVTP ile GLRLM, GLCM, SFTA öznitelik çıkarma yöntemlerinden elde edilen özniteliklerin kombinasyonel füzyon sonuçları (%)


VS1			
Sınıflandırıcılar	Öznitelik çıkarma yöntemi başarı oranı (%)		Başarıya Etkisi
	GLRLM + GLCM	HVTP + GLRLM + GLCM	
<i>Topluluk</i>	99.40	99.60	+00.20
<i>KNN</i>	98.90	99.00	+00.10
	GLCM + SFTA	HVTP + GLCM + SFTA	
<i>Topluluk</i>	99.30	99.40	+00.10
<i>KNN</i>	98.80	98.80	00.00
	GLRLM + SFTA	HVTP + GLRLM + SFTA	
<i>Topluluk</i>	99.50	99.60	+00.10
<i>KNN</i>	99.00	99.20	+00.20
	GLRLM + GLCM + SFTA	HVTP + GLRLM + GLCM + SFTA	
<i>Topluluk</i>	99.40	99.50	+00.10
<i>KNN</i>	99.10	99.00	-00.10
VS2			
	GLRLM + GLCM	HVTP + GLRLM + GLCM	
<i>Topluluk</i>	96.00	96.10	+00.10
<i>KNN</i>	83.20	84.00	+00.80
	GLCM + SFTA	HVTP + GLCM + SFTA	
<i>Topluluk</i>	95.30	95.40	+00.10
<i>KNN</i>	89.10	89.40	+00.30
	GLRLM + SFTA	HVTP + GLRLM + SFTA	
<i>Topluluk</i>	97.10	97.20	+00.10
<i>KNN</i>	93.00	93.10	+00.10
	GLRLM + GLCM + SFTA	HVTP + GLRLM + GLCM + SFTA	
<i>Topluluk</i>	97.50	97.60	+00.10
<i>KNN</i>	91.80	92.20	+00.40

4.4.4. Özniteliklerin Relieff algoritması kullanılarak önem sıralamalarına göre ağırlıklandırma işlemi

Relieff algoritması, ağırlıklandırma tabanlı bir öznitelik seçme yöntemidir. Makine öğrenmesinde kullanılan öğrenme sürecine olumlu katkı yapan, güvenilir ve nispeten etkili bir algoritmadır. Özniteliklerin önem derecelerini hesaplamak için rastgele seçilen eğitim örneklerinin kullanıldığı algorithmada her bir özneliğin önem sıralaması, ağırlıkların güncellenmesi ile tahmin edilir. Özniteliklerdeki koşullu bağımlılıkları tespit etme


yeteneği sayesinde öznitelik seçimindeki ağırlıklandırma işlemi için güvenilir bir araç olarak kullanılmaktadır (Robnik-Šikonja ve Kononenko, 2003).

GLRLM ve HVTP yöntemlerinden elde edilen özniteliklerden sınıflandırma işlemindeki başarı oranına etki eden özniteliklerin VS1 veri seti için Relieff algoritması kullanılarak yapılan önem ağırlığı sonuçları Şekil 4.6’da paylaşılmıştır. Bu sonuca göre kırmızı renk ile gösterilen HVTP yönteminden elde edilen özniteliğin en büyük önem ağırlığına sahip olduğu görülmektedir.




Şekil 4.6. VS1 veri seti için, HVTP yöntemi kullanılarak çıkarılan özniteliklerin GLRLM yöntemi kullanılarak çıkarılan özniteliklerle füzyonu sonucu, öznitelik önem sıralaması

Şekil 4.6’daki özellikler kullanılarak VS2 veri seti için yapılan özniteliklerin önem ağırlığı sonuçları Şekil 4.7’de gösterilmiş ve kırmızı renkte görülen HVTP yönteminden elde edilen özniteliğin en yüksek öneme sahip olduğu anlaşılmıştır.




Şekil 4.7. VS2 veri seti için, HVTP yöntemi kullanılarak çıkarılan özniteliklerin GLRLM yöntemi kullanılarak çıkarılan özniteliklerle füzyonu sonucu, öznitelik önem sıralaması

VS1 veri seti için, dört yönde GLCM ve HVTP yöntemlerinden elde edilen özneliklerden sınıflandırma işlemindeki başarı oranına etki eden özelliklerin önem ağırlığı sonuçları Şekil 4.8’de verilmiştir. Kırmızı renk ile gösterilen HVTP yönteminden elde edilen özneliğin en büyük önem ağırlığına sahip olduğu görülmektedir.




Şekil 4.8. VS1 veri seti için, HVTP yöntemi kullanılarak çıkarılan özneliklerin dört yönde GLCM yöntemi kullanılarak çıkarılan özneliklerle füzyonu sonucu, öznelik önem sıralaması

VS2 veri seti için Şekil 4.8’deki özellikler kullanılarak yapılan öznelik önem ağırlığı sonuçları Şekil 4.9’da paylaşılmış ve kırmızı renk ile gösterilen HVTP yönteminde elde edilen özneliğin en yüksek öneme sahip olduğu görülmüştür.




Şekil 4.9. VS2 veri seti için, HVTP yöntemi kullanılarak çıkarılan özneliklerin dört yönde GLCM yöntemi kullanılarak çıkarılan özneliklerle füzyonu sonucu, öznelik önem sıralaması

SFTA ve HVTP yöntemlerinden elde edilen özneliklerden sınıflandırma işlemindeki başarı oranına etki eden özelliklerin VS1 veri seti için yapılan önem ağırlığı sonuçları Şekil 4.10’da paylaşılmıştır. Çıkan sonuca göre kırmızı renk ile gösterilen HVTP yönteminden elde edilen özneliğin en büyük önem ağırlığına sahip olduğu tespit edilmiştir.



Şekil 4.10. VS1 veri seti için, HVTP yöntemi kullanılarak çıkarılan özniteliklerin SFTA yöntemi kullanılarak çıkarılan özniteliklerle füzyonu sonucu, öznitelik önem sıralaması

Şekil 4.10'daki özellikler kullanılarak VS2 veri seti için yapılan özniteliklerin önem ağırlığı sonuçları Şekil 4.11'de gösterilmiş ve kırmızı renkle gösterilen HVTP yönteminden elde edilen özniteliğin en yüksek öneme sahip olduğu anlaşılmıştır.



Şekil 4.11. VS2 veri seti için, HVTP yöntemi kullanılarak çıkarılan özniteliklerin SFTA yöntemi kullanılarak çıkarılan özniteliklerle füzyonu sonucu, öznitelik önem sıralaması

4.4.5. Öznitelik ağırlıklandırma yardımıyla öznitelik azaltma yöntemi

Bir öznitelik vektöründen en önemli ve ilgili özelliklerin seçimi, sınıflandırma adımında kullanılan özelliklerin etkisini öğrenmek, sınıflandırma işleminden yüksek performans ve başarı elde etmek için önemlidir. En bilgilendirici olan öznitelikleri koruyarak özelliklerin sayısının azaltılması işlemi öznitelik azaltma olarak bilinmektedir. Öznitelik azaltma amacıyla özelliklerin ağırlıklandırma işlemleri iyi bilinen algoritmalarından biri olan Relieff algoritması aracılığıyla yapılmaktadır (Kononenko ve diğ., 1997; Robnik-

Šikonja ve Kononenko, 1997). Relieff algoritmasında, veri setinde bulunan sınıfların tahmini sonucu elde edilen başarı oranı belirlenirken kullanılan özniteliklerin, başarı oranına etkileri değerlendirilmekte ve özniteliklerin hesaplanan ağırlıklandırma değerlerine göre bir sonraki sınıflandırma işleminde kullanılacak olan öznitelikler seçilmektedir. Seçilen özellikler kullanılarak öznitelik azaltma işlemi gerçekleştirildikten sonra sınıflandırma işlemi yeniden yapılmakta ve başarı oranları hesaplanmaktadır.

HVTP öznitelik çıkartma yönteminden ve GLRLM, GLCM ve SFTA yöntemlerinden elde edilen öznitelikler füzyon yardımıyla ayrı ayrı birleştirilmiş ve ayırt ediciliği en yüksek olan 10'ar özellik seçilmiştir. Çizelge 4.13'de sonuçları gösterilen ve 10'ar öznitelikten oluşan bu öznitelik vektörleri, en iyi başarının elde edildiği Topluluk Öğrenmesi sınıflandırıcısında Torbalama yöntemi ve 5-kat ÇD kullanılarak sınıflandırılmıştır. Relieff algoritması kullanılarak, GLRLM ve HVTP öznitelik çıkartma yöntemlerinden elde edilen özniteliklerin, füzyon yöntemi yardımıyla birleştirilmesi sonucu elde edilen vektördeki ayırt ediciliği ve önem derecesi en yüksek olan ilk 10 özellik belirlenerek 5-kat ÇD tekniği yardımıyla sınıflandırma işlemi gerçekleştirilmiş ve elde edilen başarı oranları Çizelge 4.13'de gösterilmiştir. Çizelge 4.9'da verilen sonuçlara göre 46 adet öz-niteliğin tamamının kullanılması durumunda VS1 için % 99.70 olan başarı oranı, öz-nitelik füzyonu yöntemi sonucu elde edilen özniteliklerden en önemli ilk 10 tanesinin kullanılması durumunda Çizelge 4.13'e göre % 98.90 olarak bulunmuş, VS2 için ise tüm özniteliklerin kullanılması sonucu % 93.30 olan başarı oranı, öznitelik füzyonu sonucu en önemli ilk 10 öz-niteliğin kullanılması durumunda % 69.30 olarak hesaplanmıştır.

GLCM ve HVTP yöntemlerinden elde edilen özniteliklerin füzyon yöntemi yardımıyla birleştirilmesi sonucu elde edilen öznitelik vektörünün ağırlıklandırma sonucuna göre en yüksek ilk 10 öznitelik tespit edilerek 5.kat ÇD tekniği yardımıyla sınıflandırılmış ve başarı oranları Çizelge 4.13'de paylaşılmıştır. Çizelge 4.10'da dört yönde verilen sonuçlara göre 82 adet öznitelik kullanılması durumunda VS1 ve 5-kat ÇD için % 99.40 olan başarı oranı, öznitelik füzyonu yöntemi sonucu elde edilen öznitelik vektöründeki en önemli ilk 10 öznitelik kullanılması durumunda, Çizelge 4.13'e göre % 95.70 olarak bulunmuştur. Aynı şekilde VS2 için tüm özniteliklerin kullanılması durumunda % 91.80 olan başarı oranı, öznitelik füzyonu sonucu en ayırt edici ilk 10 öz-niteliğin kullanılmasıyla % 58.40 olarak tespit edilmiştir.

Öznitelik çıkartma yöntemi olan SFTA ve HVTP'den çıkarılan özniteliklerin, füzyon yöntemi yardımıyla birleştirilmesi sonucu elde edilen öznitelik vektörünün ağırlıklandırma sonucu en yüksek olan ilk 10 öznitelik tespit edilip 5.kat ÇD tekniği kullanılarak sınıflandırılmış ve başarı oranları Çizelge 4.13'de paylaşılmıştır. Çizelge 4.11'deki sonuçlara göre, öznitelik füzyonu sonucu elde edilen öznitelik vektöründeki tüm 41 özneliğin kullanılması durumunda VS1 için % 99.20 olan başarı oranı, öznitelik vektöründeki en ayırt edici ilk 10 özelliğin kullanılmasıyla Çizelge 4.13'de % 97.10 olarak elde edilmiştir. Aynı şekilde, VS2 için öznitelik füzyonu yöntemi sonucu elde edilen tüm özniteliklerin kullanıldığı durumda % 86.00 başarı oranı elde edilmişken, öznitelik vektöründeki en önemli ilk 10 özneliğin kullanılmasıyla bu oran % 66.10 olarak hesaplanmıştır.

HVTP ile GLCM, GLRLM ve SFTA öznitelik çıkartma yöntemlerinden elde edilen özniteliklerin ayrı ayrı füzyonları sonucu elde edilen öznitelikler Relieff algoritmasından elde edilen ağırlıklar kullanılarak önem sıralamalarına göre sıralanmıştır. Elde edilen öznitelik kümelerindeki HVTP öznitelikleri tekrarlanmayacak şekilde GLCM, GLRLM ve SFTA sırasında olmak üzere en önemli 10'ar öznitelik seçilerek öznitelik azaltma yöntemine gidilmiş ve elde edilen öznitelikler kullanılarak yapılan öznitelik füzyonuyla toplamda 30 adet öznitelik elde edilmiştir. En önemli ilk 30 öznitelikten oluşan öznitelik kümesi, 5-kat ÇD yöntemiyle en iyi başarının elde edildiği Topluluk Öğrenmesi sınıflandırıcısında SD yöntemi kullanılarak sınıflandırılmış ve başarı oranları Çizelge 4.13'de paylaşılmıştır. Çizelge 4.13'e göre VS1 veri seti için yapılan sınıflandırma işlemi sonucunda % 99.30, VS2 veri seti için ise % 91.00'lik başarı oranları elde edilmiştir.

Çizelge 4.13. Önem sıralamasına göre en ayırt edici ilk 10 / 30 öznitelik kullanılarak yapılan öznitelik azaltma işlemi sonrası, VS1 ve VS2 veri setleri için öznitelik füzyonu sınıflandırma sonuçları (%)

İlk 10 özneliğin seçildiği öznitelik çıkartma yöntemleri	Sınıflandırıcılar	VS1	VS2
HVTP + GLRLM	<i>Topluluk</i>	98.90	69.30
HVTP + GLCM	<i>Topluluk</i>	95.70	58.40
HVTP + SFTA	<i>Topluluk</i>	97.10	66.10
İlk 30 özneliğin seçildiği öznitelik çıkartma yöntemi			
HVTP + GLCM + GLRLM + SFTA	<i>Topluluk</i>	99.30	91.00

4.4.6. Literatürde yapılan çalışmalar ve bulunan sonuçların karşılaştırılması

Literatürde geleneksel yöntemler yardımıyla yapılmış benzer çalışmalarda elde edilen başarı oranları, yararlanılan metotlar ile kullanılan öznelilik çıkarma algoritmaları ve sınıflandırıcı bilgileri, karşılaştırmalı olarak Çizelge 4.14’de verilmiştir.

Çizelge 4.14. Çalışma sonucunun literatürdeki benzer çalışmalarla karşılaştırılması

Çalışmalar	Kullanılan metotlar	Öznelilik çıkarma yöntemleri	Veri setleri	Sınıflandırıcılar	Başarı oranı
(Guan ve diğ., 2009)	Dalgacık Dönüşümü, PCA	Dalgacık Dönüşümü, Moments	292 sınıf x 7 örnek resim. İşlenen boyut: 80x160 piksel	KNN	% 94.35
(Wu ve Ye, 2009)	Sinir Ağları, Radon Dönüşümü	Radon Dönüşümü	25 sınıf x 20 örnek resim (işaret ve orta parmak). İşlenen boyut: 130x130 piksel	RBF, PNN	RBF = % 98.30 PNN = % 99.20
(Yang ve Li, 2010)	Yönlendirilebilir Filtre	Yönlendirilebilir Filtre tarafından çıkarılan enerji öznelilikleri	100 sınıf x 10 örnek resim (sağ işaret parmağı). İşlenen boyut: 70x170 piksel	KNN	% 98.70
(Wang ve diğ., 2011)	Yönlendirmeli Filtreleme, Niblack Segmentasyon	Bağıl mesafe, açılar ve PCA ile birleştirilen Dalgacık Momentleri	300 sınıf x 5 örnek resim. İşlenen boyut: 320x240 piksel	LDA	FAR = 0.70 FRR = 1.05
(Zou ve diğ., 2016)	Şablon Karşılaştırma	Şablon kalite raporu	35 sınıf x 10 örnek resim. İşlenen boyut: 45x121 piksel	MHD	% 97.14
(Xie ve Kumar, 2019)	Derin Öğrenme, Hafif Evrişimli Sinir Ağı (LCNN)	Üçlü benzerlik kaybı olan LCNN, Denetimli Ayırık Karma (SDH)	105 sınıf x (24+24) örnek resim (işaret & orta parmak). İşlenen boyut ROI: 256x513 piksel, enhanced ROI: 218x488 piksel.	CNN	EER = 0.0977
(Titrek ve Baykan, 2020)	Homomorfik Filtre & Perona-Malik Difüzyon, Niblack Segmentasyon	GFD, HVTP	VS1: 64 sınıf x 15 örnek resim (işaret parmağı). İşlenen boyut: 170x80 piksel	KNN	% 99.20
(Titrek ve Baykan, 2023)	Homomorfik Filtre & Perona-Malik Difüzyon, Niblack Segmentasyon	GLRLM, HVTP	VS1: 64 sınıf x 15 örnek resim (işaret parmağı). İşlenen boyut: 170x80 piksel	Topluluk	% 99.70

Literatürde geleneksel yöntemler yardımıyla VS2 kullanılarak yapılmış benzer çalışmalarda elde edilen başarı oranları ve kullanılan yöntemler karşılaştırmalı olarak Çizelge 4.15’ de verilmiştir. Çizelge 4.15’e göre bu tez çalışması kapsamında VS2 için elde edilen başarı oranına en yakın çalışma, Azaltılmış Görüş Alanı kullanılarak % 97.10’luk bir başarı oranının yakalandığı çalışma olmuştur (Jin ve diğ., 2021). Bu tez kapsamında yapılan çalışmanın, Çizelge 4.15’e göre literatürde yapılan çalışmalarla karşılaştırıldığında, kabul edilebilir sonuçlar ürettiği görülmektedir (Titrek ve Baykan, 2023).

Çizelge 4.15. VS2 üzerinde yapılan çalışma sonuçları

Kullanılan Yöntem	Başarı Oranı (%)
AGCNN-RAW (Zhang ve diğ., 2022b)	86.38
Maximum Curvature (Lu ve diğ., 2021)	EER: 5.49
DintyNet (Zhang ve diğ., 2022a)	90.90
AGCNN-ROI (Zhang ve diğ., 2022b)	91.06
CNN-ROI (Zhang ve diğ., 2022b)	91.51
Repeated Line Tracking (Lu ve diğ., 2021)	EER: 3.33
CNN-RAW (Zhang ve diğ., 2022b)	91.72
PCLPP (Feng ve diğ., 2022)	92.33
LadderNet (Zhang ve diğ., 2022a)	93.93
Reduced Field of View (Jin ve diğ., 2021)	97.10
HVTP, GLRLM, GLCM, SFTA (Titrek ve Baykan, 2023)	97.60
Lightweight CNN (Zhang ve diğ., 2022a)	99.05

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Tez çalışmasının amacı, BR sistemlerinden olan PD tanıma sistemlerinden elde edilen görüntülerin görüntü işleme yöntemleri kullanılarak zenginleştirilmesi, PD tanıma sistemlerinde kullanılmamış yeni bir öznitelik çıkarma yönteminin geliştirilmesi, literatürde bilinen bazı mevcut öznitelik çıkarma yöntemleri yardımıyla özniteliklerin çıkarılması ve geliştirilen yeni öznitelik çıkarma yöntemi ile öznitelik füzyonu yapılarak yeni özniteliklerin başarı sonuçları üzerine etkilerinin değerlendirilmesi üzerine çalışmalar yapmaktır. Bu amaç doğrultusunda PD tanıma sistemleri üzerine yapılan bu çalışmada, PD tanıma sistemlerinin barındırdığı yapısal zorluklar üzerine değinilmiş, mevcut öznitelik çıkarma yöntemlerine ilave olarak yeni geliştirilen HVTP öznitelik çıkarma yöntemi tarafından çıkarılan *HTP* ve *VTP* özniteliklerinin sistemin başarı oranına etkisi araştırılmış, çıkarılan özniteliklerin uzamsal ve frekans domainindeki özniteliklerle ve GLRLM, GLCM, SFTA gibi popüler öznitelik çıkarma yöntemlerinden elde edilen özniteliklerle füzyon yardımıyla birleştirilmesi durumunda başarı oranına olan etkisi incelenmiştir. Bu çalışmalar, VS1 ve VS2 veri setleri üzerinde yürütülmüştür. VS1 veri seti 64 sınıf ve 960 resimden, VS2 veri seti ise 600 sınıf ve 6000 resimden oluşmaktadır.

PD görüntüsünde, NIR ışınlarının doku içerisinden geçerek CCD kameraya ulaşana kadar meydana gelen ışık saçılması probleminin HF ve PMAD kullanarak büyük oranda azaltıldığı görülmüştür. Geliştirilen HVTP özniteliğinin, hem uzamsal domainde hem de frekans domaininde sistemin tanıma başarısına olumlu yönde katkılar sağladığı görülmüştür.

Uzamsal domain özniteliklerinden Standart sapma, Entropi ve Ağırlık merkezinin HVTP öznitelik çıkarma yöntemi aracılığıyla çıkarılan *HTP* ve *VTP* öznitelikleriyle birleştirilmesi sonucu VS1 üzerinde yapılan çalışmada elde edilen sonuç Çizelge 4.2’de gösterildiği gibi, f-KNN ile 5-kat ÇD tekniği kullanılarak yapılan sınıflandırmadan elde edilmiş ve % 97.40 olarak belirlenmiştir. Sınıf sayısı 64 olan VS1 veri setinde kullanılan uzamsal öznitelikler, sınıf sayısı 600 olan VS2 veri setinde kullanılması durumunda genel başarı oranı istenilen seviyede çıkmamış olsa dahi, HVTP özniteliklerinin başarı oranını artırıcı yönde etki yaptığı görülmüş ve Çizelge 4.3’de gösterilmiştir.

Frekans domain özniteliklerinden olan GFD özniteliklerinin *HTP* ve *VTP* öznitelikleriyle birleştirilmesi sonucu VS1 üzerinde yapılan çalışmada elde edilen başarı oranları Çizelge 4.4’de gösterilmiş olup, en yüksek başarı oranı f-KNN algoritmasında 5-kat ÇD tekniği kullanılarak yapılan sınıflandırmadan % 99.20 olarak elde edilmiştir. VS1 veri setinde kullanılan bu öznitelikler, aynı şekilde 600 sınıfa sahip olan VS2 veri setinde kullanılması durumunda HVTP özniteliklerinin başarı oranını artırıcı yönde etki yaptığı görülmüş ve Çizelge 4.5’de paylaşılmıştır.

Doku tabanlı öznitelik çıkarma yöntemlerinden olan GLRLM, GLCM ve SFTA yöntemleri ile HVTP yönteminden çıkarılan özniteliklerin, füzyon yöntemi yardımıyla birleştirilmesi sonucu elde edilen öznitelik vektörünün, Topluluk Öğrenmesi, KNN, SVM, Karar Ağacı ve DA gibi sınıflandırma algoritmalarında 3-kat ve 5-kat ÇD tekniği kullanılarak sınıflandırılmasıyla, başarı oranlarında iyileşmeler olduğu Çizelge 4.9, 4.10, 4.11 ve 4.12’de gösterilmiştir.

Yapılan çalışmalar sonucunda, VS1 için en yüksek başarı oranı, Çizelge 4.9’da da gösterilen, HVTP ve GLRLM yöntemlerinden çıkarılan özniteliklerin füzyonu ile elde edilen öznitelik vektörünün, Topluluk Öğrenme 3-kat ÇD tekniği ile sınıflandırılması sonucu % 99.70 olarak bulunmuştur.

VS2 için elde edilen en yüksek başarı oranı Çizelge 4.12’de gösterilmiştir. Çizelge 4.12’ye göre GLRLM, GLCM, SFTA ve HVTP metotlarından VS2 üzerinden çıkarılan öznitelikler kullanılarak, öznitelik füzyonu yöntemi yardımıyla öznitelik vektörü oluşturulmuştur. Oluşturulan bu öznitelik vektörü, Topluluk Öğrenme 5-kat ÇD tekniği ile sınıflandırılmış ve sınıflandırma sonucunda % 97.60 başarı oranına ulaşmıştır.

Buraya kadar yapılan bütün çalışmalar, HF ve PMAD algoritmalarının PD tanıma sistemlerinden elde edilen görüntülerdeki ışık saçılması problemini ve gürültüleri azalttığını, geliştirilen öznitelik çıkarma yöntemi olan HVTP’den çıkarılan *HTP* ve *VTP* özniteliklerinin PD tanıma sistemlerinde geçerliliği olan birer öznitelik olduğunu göstermektedir. HVTP yardımıyla elde edilen özniteliklerin tez çalışması kapsamında kullanılan diğer özniteliklerle füzyonu sonucunda başarı oranına olumlu yönde katkı yaptığı görülmüştür. PD tanıma sistemlerinde başarı oranının artması, bu sistemlerin kullanıldığı BR

sistemlerinin güvenilirliğinin artmasına ve dolayısıyla kullanım alanlarının genişlemesine katkı sağlayabilecektir.

5.2 Öneriler

Elde edilen PD görüntülerinin iyileştirilmesi veya farklı bir teknik ile PD görüntüsü elde etme üzerine çalışmalar yapılabilir. HVTP öznelik çıkarma yöntemindeki temel yaklaşımlar kullanılarak, çıkarılan öznelik sayıları artırılabilir. HVTP yöntemi sadece PD görüntüleriyle sınırlı kalmayıp, damar görüntüsü elde edilen diğer biyometrik yaklaşımlara veya literatürde iyileştirme bekleyen farklı problemlere uyarlanarak, yöntemin bu alanlardaki başarıya etkisi incelenebilir. Diğer biyometrik sistemlere göre PD tanıma sistemlerinin sahip olduğu avantajların büyük olması sebebiyle, bu tez çalışmasında önerilen yöntemler ve öznelikler kullanılarak biyometrik tanıma sistemleri geliştirilebilir. Farklı koşullarda elde edilmiş daha büyük veri setleri üzerinde performans değerlendirmesi yapılabilir. Derin sinir ağı modelleri kullanılarak görüntü zenginleştirme işlemleri gerçekleştirilebilir.

KAYNAKLAR

- Al-amri, S. S., Kalyankar, N. and Khamitkar, S., 2010, Linear and non-linear contrast enhancement image, *International Journal of Computer Science and Network Security*, 10 (2), 139-143.
- Aljarah, I., Habib, M., Nujoom, R., Faris, H. and Mirjalili, S., 2021, A comprehensive review of evaluation and fitness measures for evolutionary data clustering, *Evolutionary Data Clustering: Algorithms and Applications*, 23-71.
- Aziz, A. A., Izhar, L. I., Asirvadam, V. S., Tang, T. B., Ajam, A., Omar, Z. and Muda, A. S., 2021, Detection of Collaterals from Cone-Beam CT Images in Stroke, *Sensors (Basel, Switzerland)*, 21.
- Azmi, S. S. and Baliga, S., 2020, An overview of boosting decision tree algorithms utilizing AdaBoost and XGBoost boosting strategies, *Int. Res. J. Eng. Technol*, 7 (5).
- Babu, G. S., Bobby, N. D., Bennet, M. A., Shalini, B. and Srilakshmi, K., 2017, Multistage Feature Extraction of Finger Vein Patterns Using Gabor Filters, *Iioab Journal*, 8 (2), 84-91.
- Bansal, M., Goyal, A. and Choudhary, A., 2022, A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning, *Decision Analytics Journal*, 3, 100071.
- Belur, V. D. and Edwin, B. H., 1991, Image characterizations based on joint gray level—run length distributions, *Pattern Recognition Letters*, 12 (8), 497-502.
- Çetinkaya, Z. and Horasan, F., 2021, Decision trees in large data sets, *International Journal of Engineering Research and Development*, 13 (1), 140-151.
- Chih-Wei, H. and Chih-Jen, L., 2002, A comparison of methods for multiclass support vector machines, *IEEE transactions on neural networks*, 13 (2), 415-425.
- Choi, J., Hong, J. S., Owais, M., Kim, S. G. and Park, K. R., 2021, Restoration of Motion Blurred Image by Modified DeblurGAN for Enhancing the Accuracies of Finger-Vein Recognition, *Sensors*, 21 (14), 4635.
- Chu, A., Sehgal, C. M. and Greenleaf, J. F., 1990, Use of gray value distribution of run lengths for texture analysis, *Pattern Recognition Letters*, 11 (6), 415-419.
- Clausi, D. A., 2002, An analysis of co-occurrence texture statistics as a function of grey level quantization, *Canadian Journal of Remote Sensing*, 28 (1), 45-62.
- Cortes, C. and Vapnik, V., 1995, Support-vector networks, *Machine Learning*, 20 (3), 273-297.

- Costa, A. F., Humpire-Mamani, G. and Traina, A. J. M., 2012, An Efficient Algorithm for Fractal Analysis of Textures, *2012 25th SIBGRAPI Conference on Graphics, Patterns and Images*, 39-46.
- Faloutsos, C., Wu, L., Traina, A. and Traina Jr, C., 2021, Fast feature selection using fractal dimension, *Journal of Information and Data Management*, 1 (1), 3.
- Feng, D. Z., He, S. Y., Zhou, Z. H. and Zhang, Y., 2022, A Finger Vein Feature Extraction Method Incorporating Principal Component Analysis and Locality Preserving Projections, *Sensors*, 22 (10).
- Fisher, R. A., 1938, The Statistical Utilization of Multiple Measurements, *Annals of Eugenics*, 8 (4), 376-386.
- Flynn, G. L., Yalkowsky, S. H. and Roseman, T. J., 1974, Mass transport phenomena and models: theoretical concepts, *J Pharm Sci*, 63 (4), 479-510.
- Freund, Y. and Schapire, R. E., 1997, A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting, *Journal of Computer and System Sciences*, 55 (1), 119-139.
- Fu, B., Cui, J. and Xiong, X., 2010, A novel adaptive vein image contrast enhancement method based on fuzzy and retinex theory, *The 2010 IEEE International Conference on Information and Automation*, 2447-2450.
- Gao, X., Ma, J. and Wu, J., 2010, The research of finger-vein image enhancement algorithm, *Opt. Instrum*, 32, 29-32.
- Guan, F., Wang, K., Mo, H., Ma, H. and Liu, J., 2009, Research of Finger Vein Recognition Based on Fusion of Wavelet Moment and Horizontal and Vertical 2DPCA, *2009 2nd International Congress on Image and Signal Processing*, 1-5.
- Haralick, R. M., Shanmugam, K. and Dinstein, I., 1973, Textural Features for Image Classification, *IEEE Trans Syst Man Cybern*, SMC-3, 610-621.
- He, J., Shen, L., Yao, Y., Wang, H., Zhao, G., Gu, X. and Ding, W., 2023, Finger Vein Image Deblurring Using Neighbors-Based Binary-GAN (NB-GAN), *Ieee Transactions on Emerging Topics in Computational Intelligence*, 7 (2), 295-307.
- Jin, J., Di, S., Li, W., Sun, X. and Wang, X., 2021, Finger vein recognition algorithm under reduced field of view, *Iet Image Processing*, 15 (4), 947-955.
- JosephP, R. B. and Ezhilmaran, D., 2018, A smart computing algorithm for finger vein matching with affine invariant features using fuzzy image retrieval, *Procedia Computer Science*, 125, 172-178.
- Kaur, A. and Mishra, A., 2015, Finger Vein Image Enhancement Using RPL , Segmentation with Neural Networks.

- Khan, A. A., Chaudhari, O. and Chandra, R., 2023, A review of ensemble learning and data augmentation models for class imbalanced problems: combination, implementation and evaluation, *arXiv preprint arXiv:2304.02858*.
- Khellat-Kihel, S., Abrishambaf, R., Monteiro, J. L. and Benyettou, M., 2016, Multimodal fusion of the finger vein, fingerprint and the finger-knuckle-print using Kernel Fisher analysis, *Applied Soft Computing*, 42, 439-447.
- Kononenko, I., Šimec, E. and Robnik-Šikonja, M., 1997, Overcoming the myopia of inductive learning algorithms with RELIEFF, *Applied Intelligence*, 7, 39-55.
- Lu, H. M., Wang, Y. F., Gao, R. R., Zhao, C. C. and Li, Y., 2021, A Novel ROI Extraction Method Based on the Characteristics of the Original Finger Vein Image, *Sensors*, 21 (13).
- Lu, Y., Xie, S. J., Yoon, S., Yang, J. C. and Park, D. S., 2013, Robust Finger Vein ROI Localization Based on Flexible Segmentation, *Sensors*, 13 (11), 14339-14366.
- Luo, H., Yu, F.-X., Pan, J.-S., Chu, S.-C. and Tsai, P.-W., 2010, A survey of vein recognition techniques, *Information Technology Journal*, 9 (6), 1142-1149.
- Ma, H., Popoola, O. P. and Sun, S. L., 2015, Research of dual-modal decision level fusion for fingerprint and finger vein image, *International Journal of Biometrics*, 7 (3), 271-285.
- Ma, H. and Zhang, S. Y., 2019, Contactless finger-vein verification based on oriented elements feature, *Infrared Physics & Technology*, 97, 149-155.
- Mary, M. G., 1975, Texture analysis using gray level run lengths, *Computer Graphics and Image Processing*, 4 (2), 172-179.
- Matsuda, Y., Miura, N., Nagasaka, A., Kiyomizu, H. and Miyatake, T., 2016, Finger-vein authentication based on deformation-tolerant feature-point matching, *Machine Vision and Applications*, 27 (2), 237-250.
- Meng, X., Yang, G., Yin, Y. and Xiao, R., 2012, Finger Vein Recognition Based on Local Directional Code, *Sensors*, 12 (11), 14937-14952.
- Meng, X., Xi, X., Yang, G. and Yin, Y., 2017, Finger vein recognition based on deformation information, *Science China Information Sciences*, 61 (5), 052103.
- Mutlag, W. K., Ali, S. K., Aydam, Z. M. and Taher, B. H., 2020, Feature extraction methods: a review, *Journal of Physics: Conference Series*, 012028.
- Niblack, W., 1986, An Introduction to Digital Image Processing, *Prentice Hall*, p.
- Nisa, M., Shah, J. H., Kanwal, S., Raza, M., Khan, M. A., Damaševičius, R. and Blažauskas, T., 2020, Hybrid Malware Classification Method Using Segmentation-Based Fractal Texture Analysis and Deep Convolution Neural Network Features, *Applied Sciences*, 10 (14), 4966.

- Oh, J. and Hwang, H., 2010, Feature enhancement of medical images using morphology-based homomorphic filter and differential evolution algorithm, *International Journal of Control, Automation and Systems*, 8 (4), 857-861.
- Oppenheim, A. V. and Schaffer, R. W., 2004, From frequency to quefrequency: A history of the cepstrum, *IEEE signal processing Magazine*, 21 (5), 95-106.
- Perona, P. and Malik, J., 1990, Scale-space and edge detection using anisotropic diffusion, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12 (7), 629-639.
- Ponomarev, V. I. and Pogrebniak, A. B., 1995, Image enhancement by homomorphic filters, *Applications of Digital Image Processing Xviii*, 2564, 153-159.
- Robnik-Šikonja, M. and Kononenko, I., 1997, An adaptation of Relief for attribute estimation in regression, *Machine learning: Proceedings of the fourteenth international conference (ICML '97)*, 296-304.
- Robnik-Šikonja, M. and Kononenko, I., 2003, Theoretical and Empirical Analysis of ReliefF and RReliefF, *Machine Learning*, 53 (1), 23-69.
- Rokach, L., 2010, Ensemble-based classifiers, *Artificial Intelligence Review*, 33 (1), 1-39.
- Rosdi, B. A., Shing, C. W. and Suandi, S. A., 2011, Finger Vein Recognition Using Local Line Binary Pattern, *Sensors*, 11 (12), 11357.
- Şamlı, R. and Yüksel, M. E., 2009, Biyometrik güvenlik sistemleri, *XI. Akademik Bilişim Konferansı Bildirileri*, 11-13.
- Sanjekar, P. and Patil, J., 2013, An overview of multimodal biometrics, *Signal & Image Processing*, 4 (1), 57.
- Seiffert, C., Khoshgoftaar, T. M., Hulse, J. V. and Napolitano, A., 2010, RUSBoost: A Hybrid Approach to Alleviating Class Imbalance, *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 40 (1), 185-197.
- Sekhavati, J., Hashemabadi, S. H. and Soroush, M., 2022, Computational methods for pipeline leakage detection and localization: A review and comparative study, *Journal of Loss Prevention in the Process Industries*, 77, 104771.
- Shahamat, H. and Pouyan, A. A., 2014, Face recognition under large illumination variations using homomorphic filtering in spatial domain, *Journal of Visual Communication and Image Representation*, 25 (5), 970-977.
- Shin, K., Park, Y., Nguyen, D. and Park, K., 2014, Finger-Vein Image Enhancement Using a Fuzzy-Based Fusion Method with Gabor and Retinex Filtering, *Sensors*, 14 (2), 3095.

- Sikarwar, P. and Manmohan, 2016, Finger vein recognition using local directional pattern, *2016 International Conference on Inventive Computation Technologies (ICICT)*, 1-5.
- Soh, L. K. and Tsatsoulis, C., 1999, Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices, *IEEE Transactions on Geoscience and Remote Sensing*, 37 (2), 780-795.
- Tabachnick, B. G., Fidell, L. S. and Ullman, J. B., 2013, Using multivariate statistics, *pearson Boston, MA*, p.
- Tang, X. O., 1998, Texture information in run-length matrices, *IEEE Transactions on Image Processing*, 7 (11), 1602-1609.
- Tharwat, A., 2016, Linear vs. quadratic discriminant analysis classifier: a tutorial, *International Journal of Applied Pattern Recognition*, 3 (2), 145-180.
- Titrek, F. and Baykan, O. K., 2020, Finger Vein Recognition by Combining Anisotropic Diffusion and a New Feature Extraction Method, *Traitement Du Signal*, 37 (3), 433-441.
- Titrek, F. and Baykan, Ö. K., 2023, Finger Vein Recognition Based on Multi-Features Fusion, *Traitement Du Signal*, 40 (1), 101.
- Vapnik, V. N., 1999, An overview of statistical learning theory, *IEEE transactions on neural networks*, 10 (5), 988-999.
- Wang, K., Ma, H., Popoola, O. P. and Liu, J., 2011, Finger vein recognition, In: *Biometrics*, Eds: Yang, J.: InTech, p. 29-53.
- Wang, W. and Chang, F., 2011, A Multi-focus Image Fusion Method Based on Laplacian Pyramid, *J. Comput.*, 6 (12), 2559-2566.
- Wang, Y., Liu, T. and Jiang, J., 2008, A multi-resolution wavelet algorithm for hand vein pattern recognition, *Chinese Optics Letters*, 6 (9), 657-660.
- Weickert, J., 1998, Anisotropic diffusion in image processing, *Teubner*, Stuttgart, p. 15-20.
- Woods, R. E. and Gonzalez, R. C., 2008, Digital image processing, Pearson Education Ltd.
- Wu, J.-D. and Ye, S.-H., 2009, Driver identification using finger-vein patterns with Radon transform and neural network, *Expert Systems with Applications*, 36 (3), 5793-5799.
- Xie, C. H. and Kumar, A., 2019, Finger vein identification using Convolutional Neural Network and supervised discrete hashing, *Pattern Recognition Letters*, 119, 148-156.

- Yang, J., Yang, J. and Shi, Y., 2009, Combination of gabor wavelets and circular gabor filter for finger-vein extraction, *Emerging Intelligent Computing Technology and Applications*, 346-354.
- Yang, J. and Li, X., 2010, Efficient Finger Vein Localization and Recognition, *2010 20th International Conference on Pattern Recognition*, 1148-1151.
- Yang, J., Zhang, B. and Shi, Y., 2012, Scattering removal for finger-vein image restoration, *Sensors (Basel)*, 12 (3), 3627-3640.
- Yang, J. and Shi, Y., 2013, Finger-vein network enhancement and segmentation, *Pattern Analysis and Applications*, 17 (4), 783-797.
- Yang, J., Shi, Y. and Jia, G., 2017, Finger-vein image matching based on adaptive curve transformation, *Pattern Recognition*, 66, 34-43.
- Yang, S., Qin, H., Liu, X. and Wang, J., 2020, Finger-Vein Pattern Restoration With Generative Adversarial Network, *Ieee Access*, 8, 141080-141089.
- Yang, W. M., Ji, W. Y., Xue, J. H., Ren, Y. and Liao, Q. M., 2019, A hybrid finger identification pattern using Polarized depth-Weighted Binary Direction Coding, *Neurocomputing*, 325, 260-268.
- Yong, Y., 2020, Research on Technology of Finger Vein Pattern Recognition Based on FPGA, *Journal of Physics: Conference Series*, 1453, 012037.
- You, W., Zhou, W., Huang, J., Yang, F., Liu, Y. and Chen, Z., 2019, A bilayer image restoration for finger vein recognition, *Neurocomputing*, 348, 54-65.
- Zhang, D. S. and Lu, G. J., 2002, Shape-based image retrieval using generic Fourier descriptor, *Signal Processing-Image Communication*, 17 (10), 825-848.
- Zhang, H. Y., Hung, C. L., Min, G. Y., Guo, J. P., Liu, M. Y. and Hu, X. Y., 2020, GPU-Accelerated GLRLM Algorithm for Feature Extraction of MRI (vol 9, 10883, 2019), *Scientific Reports*, 10 (1).
- Zhang, R., Yin, Y., Deng, W., Li, C. and Zhang, J., 2022a, Deep learning for finger vein recognition: A brief survey of recent trend, *arXiv preprint arXiv:2207.02148*.
- Zhang, Y., Li, W., Zhang, L., Ning, X., Sun, L. and Lu, Y., 2022b, AGCNN: Adaptive Gabor Convolutional Neural Networks with Receptive Fields for Vein Biometric Recognition, *Concurrency and Computation: Practice and Experience*, 34 (12), e5697.
- Zou, H., Zhang, B., Tao, Z. and Wang, X., 2016, A Finger Vein Identification Method Based on Template Matching, *Journal of Physics: Conference Series*, 680 (1), 012001.