

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ORMAN YANGINLARININ GÖRÜNTÜ İŞLEME YÖNTEMLERİ ile
TESPİT EDİLMESİ ve SINIFLANDIRILMASI

MURAT TOPTAŞ

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ DONANIM ANABİLİMDALI

ARALIK 2018
MALATYA

Tezin Başlığı: Orman Yangınlarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi ve Sınıflandırılması

Tezi Hazırlayan: Murat TOPTAŞ

Sınav Tarihi: 06.12.2018

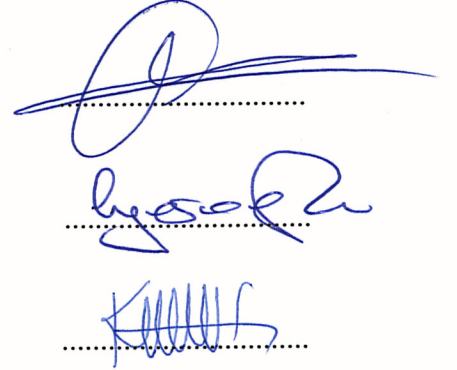
Yukarıda adı geçen tez jürimizce değerlendirilerek Bilgisayar Mühendisliği Ana Bilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danışmanı: Doç. Dr. Davut HANBAY
İnönü Üniversitesi

Doç. Dr. Celaleddin YEROĞLU
İnönü Üniversitesi

Prof. Dr. Abdulkadir ŞENGÜR
Fırat Üniversitesi



Prof. Dr. Halil İbrahim ADIGÜZEL
Enstitü Müdürü

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduđum “Orman Yangınlarının Görüntü İşleme Yöntemleri ile Tespit Edilmesi ve Sınıflandırılması” başlıklı çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Murat TOPTAŞ



ÖZET

Yüksek Lisans Tezi

ORMAN YANGINLARININ GÖRÜNTÜ İŞLEME YÖNTEMLERİ ile TESPİT EDİLMESİ ve SINIFLANDIRILMASI

Murat TOPTAŞ

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Donanım Ana Bilim Dalı

54 + viii sayfa

2018

Danışman: Doç. Dr. Davut Hanbay

Orman yangınları, orman ekosistemlerinde yıkıcı hasarlara sebep olmaktadır. Bu hasarların uzun süreli etkileri iklim değişikliğine ve kuraklığa neden olabilir. Orman yangınları sadece çevresel zararlara değil ayrıca ülkelerin ekonomik ve sosyal yaşamlarına da zarar vermektedir. Bu zararları en aza indirebilmek için orman yangınlarına erken müdahale etmek gerekir. Orman yangınlarına erken müdahale edebilmek yangının en kısa sürede algılanmasına bağlıdır. Yangının algılanmasında ise hızlı ve doğru uyarı verebilen sistemlere ihtiyaç vardır.

Bu tez çalışmasında, görüntü işleme teknikleri kullanılarak yangın erken uyarı sistemi tasarlanmıştır. Tasarlanan bu sistemde orman yangın görüntüleri kullanılarak dumanın algılanması üzerine bir çalışma gerçekleştirilmiştir. Duman, yangın anında alevden önce oluşmaktadır. Bu nedenle dumanın tespit edilmesi yangına erken müdahale de önemli bir rol oynar. Dumanı tespit etmek için dumanın doku ve renk özellikleri kullanılmıştır. Doku özniteliklerinin çıkarılmasında Yerel İkili Örüntüler (LBP) ve Law's Doku Enerji Değerler (LAWS) yöntemleri kullanılmıştır. Renk özniteliklerinin çıkarılmasında ise RGB renk uzayında duman rengini tanımlayan öznitelikler kullanılmıştır. Dumana ait doku ve renk öznitelikleri çıkarıldıktan sonra bu öznitelikler, Destek Vektör Makinaları (SVM), Yapay Sinir Ağı (ANN) ve k-En Yakın Komşu (KNN) sınıflandırıcıları kullanılarak sınıflandırılmıştır. Sınıflandırma sonucunda elde edilen başarılar gösterilmiş ve kıyaslanmıştır.

ANAHTAR KELİMELER: Yangın Tespiti, Duman Tespiti, Özellik Çıkarımı, Sınıflandırma

ABSTRACT

Master Thesis

DETERMINATION AND CLASSIFICATION OF FOREST FIRE WITH IMAGE PROCESSING METHODS

Murat TOPTAŞ

Inonu University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

54+ viii page

2018

Supervisor: Associate Prof. Davut Hanbay

Forest fires cause destructive damage in forest ecosystems. The long-term effects of these damages can lead to climate change and drought. Forest fires damage not only environment but also economic and social life of countries. In order to minimize these damages, forest fires should be take into control of early time. Early control of forest fires depends on the detection of the fire as soon as possible. There is a need for fast and accurate warning systems for fire detection.

In this thesis, early warning system is designed by using image processing techniques. In this designed system, a study was carried out on the detection of smoke by using forest fire images. Smoke occurs before the flame at the time of fire. Therefore, early detection of smoke plays an important role in the detection of forest fire. Texture and color characteristic of smoke were used to detect smoke. Local Binary Patterns (LBP) and Law's Texture Energy Values (LAWS) method were used for the extraction of texture features. In the extraction of color features, the features that define the smoke color in RGB color space are used. After the texture and color features of the smoke were extracted, these features were classified by using Support Vector Machines (SVM), Artificial Neural Network (ANN) and k-Nearest Neighbor (KNN) classifiers. Achievements obtained as a result of classification are shown and compared with each other.

KEYWORDS: Fire Detection, Smoke Detection, Feature Extraction, Classification

TEŐEKKÖR

Bu tezin oluŐturulmasında, deęerli bilgilerini benimle paylaŐan, her tÖrlÖ yardımı ve desteęi eksik etmeyen danıŐman hocam Sayın Doę. Dr. Davut HANBAY'a;

YÖksek lisans Tez hazırlama sÖrecinde sÖrekli yanımda olan ve destek veren aileme;

YÖksek Lisans Tez hazırlama sÖrecinde ve hayatımın tÖm evrelerinde bana sınırsız özveri ile yÖrekten destek olan ve beni hiębir zaman yalnız bırakmayan deęerli eŐim Bilgisayar YÖksek MÖhendisi Buket TOPTAŐ'a

TeŐekkÖr ederim.



İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ	viii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Literatür Taraması ve Değerlendirilmesi	3
1.3 Tezin Organizasyonu	6
2. TEORİK BİLGİLER.....	8
2.1 RGB Renk Uzayı	8
3. DOKU ÖZELLİK ÇIKARIM YÖNTEMLERİ.....	10
3.1 Yerel İkili Örüntüler (LBP).....	10
3.2 Yerel Üçlü Örüntüler (LTP).....	13
3.3 Law's Doku Enerji Değerleri (LAWS).....	15
3.4 Gri Seviye Eş Oluşum Matrisi (GLCM)	17
3.5 Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)	20
4. SINIFLANDIRICILAR	23
4.1 Destek Vektör Makinaları (SVM).....	23
4.1.1 Doğrusal Ayrılan Veriler.....	23
4.1.2 Doğrusal Ayrılamayan Veriler	26
4.2 Yapay Sinir Ağları (ANN).....	27
4.3 K-En Yakın Komşu (KNN)	32
5. ÖNERİLEN ERKEN DUMAN ALGILAMA SİSTEMİ	34
5.1 Veri Seti	34
5.2 Önerilen Yöntem.....	36
5.2.1 RGB Renk Uzayından Gri Ölçekli Renk Uzayına Dönüşüm	38
5.2.2 Kontrast Germe	40
5.2.3 Özellik Çıkarımı.....	41
5.2.3.1 Doku Özellik Çıkarımı	42
5.2.3.2 Renk Özellik Çıkarımı	45

5.2.4	Sınıflandırma.....	46
6.	SONUÇLAR VE DEĞERLENDİRME.....	49
7.	KAYNAKLAR	51



SİMGELER VE KISALTMALAR

LBP	Local Binary Pattern	Yerel İkili Örüntüler
LAWS	Law's Texture Energy	Law's Doku Enerji Değerleri
RGB	Red Gren Blue	Kırmızı Yeşil Mavi
SVM	Support Vector Machine	Destek Vektör Makinaları
ANN	Artificial Neural Network	Yapay Sinir Ağları
KNN	k-Nearest Neighbors	k-En Yakın Komşu
HMM	Hidden Markov Model	Gizli Markov Modeli
LTP	Local Ternary Pattern	Yerel Üçlü Örüntüler
GLCM	Gray-Level Co-Occurrence Matrix	Gri Seviyeli Eş Oluşum Matrisi
GLRLM	Gray-Level Run Length Matrix	Gri Seviye Koşu Uzunluğu Matrisi
DCT	Discrete Cosine Transform	Ayrık Kosinüs Dönüşümü
MSER	Maximally Stable Extremal Regions	Maksimum Kararlı Ekstrem Bölgeler

ŞEKİLLER DİZİNİ

Şekil 2.1. RGB Renk Uzayı	8
Şekil 3.1. Bir Matrisin LBP Sonucu.....	11
Şekil 3.2. Bir Matrisin LTP değerinin bulunması	14
Şekil 3.3. LTP Matrisinin Pozitif ve Negatif Matrisleri.....	15
Şekil 3.4. GLCM Yön Bilgisi	17
Şekil 3.5. GLCM Matrisinin Hesaplanması	18
Şekil 3.6. GLRLM Matrisinin Hesaplanması	21
Şekil 4.1. Doğrusal SVM Gösterimi	24
Şekil 4.2. Doğrusal Ayrılamayan SVM	27
Şekil 4.3. Sinir Hücresi	28
Şekil 4.4. ANN Yapısı	29
Şekil 4.5. KNN Gösterimi.....	33
Şekil 5.1. Veri Seti Örnek Duman Görüntüleri.....	35
Şekil 5.2. Veri Seti Örnek Duman Olmayan Görüntüler	35
Şekil 5.3. Akış Şeması	37
Şekil 5.4. Orjinal Görüntülerde RGB Renk Değerleri	39
Şekil 5.5. Ön İşleme a) Orjinal Görüntü b) Ön İşleme Yapılmış Görüntüler.....	40
Şekil 5.6. Özellik Sayıları	42
Şekil 5.7. Veri Setinden Örnek Görüntüler.....	42
Şekil 5.8. LBP Düzgün Örüntüleri.....	43
Şekil 6.1. Özellik Çıkarım Yöntemlerinin Kıyaslanması	50

ÇİZELGELER DİZİNİ

Çizelge 2.1. RGB Renk Değerleri.....	9
Çizelge 3.1. GLCM Özellikleri.....	19
Çizelge 3.2. GLRLM Özellikleri	22
Çizelge 4.1. ANN Toplam Fonksiyonları	30
Çizelge 4.2. ANN Aktivasyon Fonksiyonları	31
Çizelge 5.1. Veri Seti	34
Çizelge 5.2. Laws Özellikleri.....	44
Çizelge 5.3. Renk Özellikleri	46
Çizelge 5.4. Sınıflandırıcıların Başarı ve Zaman Değerleri.....	47

1. GİRİŞ

Ülkemizdeki ormanlık alanlar 22.342.935 hektarlık alana sahiptir. Ormanlık alanlar ülke yüzölçümünün %28,6'sını kaplamaktadır [1]. Bu alan içerisinde normal kapalı orman alanı 12.704.148 hektara sahip olup toplam ormanlık alanının %56,9'unu, boşluklu kapalı orman alanı ise 9.638.787 hektar ile toplam ormanlık alanın %43,1'ini oluşturmaktadır.

Coğrafi konum olarak genelde Akdeniz iklim kuşağında yer alan Türkiye'de, ormanlarımızın büyük bir bölümü yangın tehdidi altında bulunmaktadır. Toplam ormanlık alanın %60'ını birinci ve ikinci derece yangın ihtimali olan alanlar oluşturmaktadır. Bu nedenle orman yangınları ülkemizde öncelikli sorunlar arasında yer almaktadır. Orman yangınlarının oluşmasına ve yayılmasına engel olmak için her türlü fiziki ve beşeri tedbirler alınmalıdır. Bunun için orman yangınlarıyla mücadele tekniklerinin geliştirilmesi ve güçlendirilmesi gerekmektedir. Yangın tespit süresini kısaltarak yangın zararlarını en aza indirmek ve orman yangınlarında görev alan personeli eğitmek öncelikli ve önemli faaliyetler arasında yer almaktadır.

Yangın tespit ve uyarı sistemleri, teknolojinin gelişmesi ile yaygınlaşmıştır. Yangının erken tespiti, yangının oluşturduğu maddi kayıpların azaltılması, birçok bitki ve hayvan türünün korunması açısından oldukça önemlidir. Literatürde yangın erken tespiti için yapılan birçok araştırma ve geliştirme yöntemi mevcuttur. Mevcut yöntemler temelde iki kategoriye ayrılmıştır. Bu kategorilerden ilki algılayıcı tabanlı sistemlerdir. Algılayıcı tabanlı sistemler kısa mesafelerde yangın tespiti üzerine yoğunlaşmaktadır. İkinci kategori ise hareketli veya hareketsiz görüntülerin işlenmesi yöntemine dayanır. Bu yöntem ilk kategoriye göre daha geniş alanları kontrol edebilen erken uyarı sistemlerini ele almaktadır.

Yangın ihbar sistemlerinin verimli olabilmesi için erken ve doğru uyarı verebilen bir sistem olması gerekir. Mevcut yöntemler incelendiğinde, ilk çalışmalarda yangın algılamak için detektörler kullanılmıştır. Ancak, yangın algılayıcı detektörler genelde duman, ısı, alev, buhar gibi karakteristik parametreleri algılamaya çalışırken çevresel faktörlerden etkilenmektedir. Yangın algılama da kullanılan duman detektörünün çalışması için duman ile oluşan belli parçacıkların detektör içine kadar ulaşması gerekir. Duman detektörünün mesafeye dayalı çalışma yapısı, açık ve geniş alanlarda yetersiz kalmaktadır. Detektörlerin aksine, uzun algılama mesafesine sahip, geniş alan

perspektifi sunan ve daha ucuz maliyetli görüntü işleme tabanlı yangın algılama sistemleri kullanılmaktadır. Görüntü işleme tabanlı sistemler daha avantajlı ve tercih edilebilir bir konumdadır.

Bu tez çalışmasında, ormanlık alanlarda oluşan yangınlar için erken yangın tespit sistemi önerilmiştir. Önerilen sistemde, dumanın doku ve renk özellikleri kullanılarak duman algılama işlemi gerçekleştirilmiştir.

Dumanın doku özelliklerini çıkarmak için LBP ve LAWS doku özellik çıkarım yöntemleri kullanılmıştır. Dumanın renk özelliklerini bulmak için RGB renk uzayında duman rengini tanımlayan 3 özellik kullanılmıştır. Duman görüntülerinden elde edilen doku ve renk özellikleri 3 farklı sınıflandırıcı algoritması ile sınıflandırılmış ve sınıflandırma başarıları karşılaştırılmıştır. Tasarlanan bu sistem Feiniu Yuan vd. [2] tarafından oluşturulan ve paylaşımına açık olan veri seti üzerinde test edilmiştir. Bu veri setinde 5.000 adet duman görüntüsü 17.000 adet duman olmayan görüntü olmak üzere toplam 22.000 adet görüntü bulunmaktadır. Bu görüntüler ile sistemimiz eğitilmiş ve en yüksek başarı %98,04 olarak elde edilmiştir. Aldığımız sonuçlar, bu çalışmadaki yaklaşımın, yangın erken tespiti sistemi olarak kullanabileceğini göstermektedir.

1.1 Tezin Amacı

Bu tez çalışmasının amacı; erken yangın tespit sistemi geliştirmektir. Erken yangın tespit sistemleri, yangını kontrol altına almada önemli bir rol oynamaktadır. Geliştirilen sistem, yangın dumanını tespit ederek yangına erken müdahaleyi amaçlamıştır. Bu amaç doğrultusunda dumanı tespit etmek için; dumanın renk ve doku özellikleri kullanılmıştır. Dumanın bu özellikleri mevcut sınıflandırıcılar ile eğitilerek sistem test edilmiştir.

1.2 Literatür Taraması ve Değerlendirilmesi

Yangın algılama sistemlerinde kullanılan teknolojilerden sensör teknolojisi kapalı alanlarda (ev, bina vb.) iyi sonuçlar vermektedir. Ancak açık (orman vb.) alanlarda sensör teknolojileri yetersiz kalmaktadır. Bu nedenle açık alanlarda sensörler yerine görüntü işleme yöntemleri ile yangın tespiti yapılmaktadır.

Son yıllarda yapılan duman tabanlı yangın algılama çalışmaları incelendiğinde, dumanı belirlemek için dumanın rengi, hareketi, şekli ve dokusu gibi farklı birçok özellik kullanıldığı görülmektedir.

Piccini vd. [3], parçalı nesnelere üzerinde çalışan duman algılama modülü ile arka plan çıkarma modülünü önermişlerdir. Önerdikleri yöntemde dalgacık modelinde enerji değişimi ve dumanın renk modeli kullanılmaktadır. Arka plan ve anlık görüntü arasında oluşan dalgacık alanındaki enerji miktarındaki azalma, doku düzeyinde değişimleri temsil eden dumanı algılamada bir ipucu olarak kullanılmıştır.

ByoungChul Ko vd. [4], bilgisayarlı görme ve desen tanıma teknikleri ile yangın anında dumanı algılayan bir yöntem sunmuşlardır. Öncelikle aday bölgeleri en küçük kareler farkı yöntemi kullanarak tanımlamakta ve hareketli nesnelere algılamak için parametrik olmayan duman renk modelleri oluşturulmuştur. Duman doğrulaması için, eğitim aşamasında BoF histogramını kullanarak rasgele bir orman sınıflandırıcısı oluşturulmuştur.

A. Benazza-Benyahia vd. [5], Ayırık Kosinüs Dönüşümü (DCT) katsayılarına dayalı duman alanlarının yerel fraktal özelliğini ölçen hızlı ve erken bir duman algılama yöntemi önermişlerdir. Önerilen yöntemde kameranın görüntü sıkıştırma sistemiyle ilişkilendirmek amaçlanmıştır.

Wei Ye vd. [6], video görüntü dizilerinden duman bölgesini algılamak için, Surfacelet dönüşümü ve Gizli Markov Modeli (HMM) ile yeni bir dinamik doku tanımlayıcısı önermiştir. Görüntü dizisi, piramit modeli ile çoklu ölçekte ayrıştırılmış ve sinyaller 3B yönlü filtreler kullanılarak farklı yönlere ayrılmıştır. Daha sonra, Surfacelet dönüşümünden elde edilen katsayılar için, hem Gauss karma modeli hem de ölçek süreklilik modeli ile bir 3B HMM modeli oluşturulmuştur. SVM kullanarak dumanlı ve dumansız videolar sınıflandırılmıştır.

Hongda Tian vd. [7], görüntüde ki dumanı arka plandan ayırmaya yönelik bir yaklaşım sunmuşlardır. Bir görüntünün, duman bileşeni ve arka plan resminin birleşmesiyle oluştuğunu varsaymışlardır. Birleşme parametresini ve duman tahminini

bir optimizasyon problemi olarak kabul etmişlerdir. Çalışmanın ilerleyen kısımlarında ise optimizasyon problemini çözmek için farklı yöntemler önermişlerdir.

Ali Rafiee vd. [8], sundukları yöntemde bir görüntüdeki tüm nesnelere alarak hangi nesnenin duman ve ateş olduğunu anlamak için kontrol işlemi yapmışlardır. Dumanı renk, hareketlilik ve doku bozukluğu özelliklerini kullanarak tespit işlemi gerçekleştirmişlerdir.

Jayavardhana Gubbi vd. [9], yapmış oldukları çalışmada orman yangın videolarından ve tünel yangın videolarından aldıkları görüntülerde dumanın algılanması için çalışmalar yürütmüşlerdir. Bu çalışmalarında, ayırık kosinüs dönüşümleri ve dalgacıklar kullanan bir blok tabanlı yaklaşımla dumanı karakterize etmeye çalışmışlardır.

Feiniu Yuan vd. [10], yapmış oldukları çalışmada, duman tespit doğruluğunu iyileştirmek için, her pikseldeki yüksek dereceli türevleri kodlayarak bir öznetelik çıkarma yöntemi önermişlerdir. Duman algılama da güçlü ve kompakt özellikler önermek için Yerel Üçlü Modelleri (LTP), yüksek türevli işaretleri ve çeşitli yöntemleri bir araya getirerek bir çalışma sunmuşlardır.

Zhiqiang Zhou vd. [11], dumanın renk ve hareket bilgisine dayanan bir çalışmanın aksine dumanın yerel uç bölgelerini belirlemek için Maksimum Kararlı Ekstremal Bölge (MSER) algılama yöntemini kullanmışlardır. Duman aday bölgeleri, dumanın statik görsel özellikleri kullanılarak tüm olası bölgelerden seçilmiştir. Potansiyel bir duman bölgesi bulunduktan sonra da bu bölgeyi takip eden uç bölgeler izlenerek takip işlemine devam etmişlerdir.

Sheng Luo vd. [12], mevcut görüntülerde dumanı tespit etmek için videoları yoğunlaştırmakta ve duman yörüngelerinin sağa eğik çizgi, pürüzsüz akış çizgisi, düşük frekans, sabit kaynak ve yatay-dikey oranı gibi özelliklere sahip olması üzerinden çalışmalar yürütmüşlerdir. Bu özelliklere dayanarak, karmaşık bir ortamda dahi dumanı algılayabilmektedirler.

Saylee Gharge vd. [13], yangın anında kamera alanında beliren dumanı algılayan ve dumanı algıladıktan sonra da alevi algılamaya çalışan bir yöntem önermişlerdir. Duman algılanmaya başladığında güvenlik birimlerine uyarı mesajları göndermişlerdir. Kamera alanına giren görüntüde duman ve alev algılanmaya devam ederse sistem alarm durumuna geçmektedir.

Jesny A. vd. [14], yapmış oldukları çalışmada bina gözlem kameralarından alınan videoları analiz ederek, yangın ve duman alanlarını tespit eden bir yöntem

önermişlerdir. Bu çalışma renk, hareket ve şekil gibi çok yönlü özellikler kullanılarak geliştirilmiştir. Dumanın sahip olduğu bu özellikler ayrı ayrı değerlendirilmekte ve video da tespiti yapılmaktadır.

Jean Paul D. vd. [15], yapmış oldukları çalışmada karmaşık bir kamera sahnesinde görünen dumanı tespit etmek için yöntem geliştirmişlerdir. Görüntüler ilk önce eşsizlik eşiği haritası ve yangının gerçek zamanlı farkları göz önüne alınarak bölünür. İkili görüntü işleme tekniklerini, düşük çözünürlükte eşitsizlik hesaplamaları ile bölünmüş görüntülerden gelen gürültüyü elimine etmek için kullanmışlardır. Sonuç olarak daha kesin sonuçlar elde etmişlerdir.

Turgay Çelik vd. [16], görüntü işleme ile renk modellerine dayalı duman ve alev tanımlama üzerine bir çalışma önermişlerdir. Çalışmalarında kullandıkları renk modelleri, farklı video dizileri ve görüntülerden alınan örneklerin istatistiksel analizinden faydalanarak çıkarılmıştır. Önceden yaptıkları bulanık mantık tabanlı yangın piksellerini tespit etme çalışmalarını geliştirerek duman pikselleri için yeni modeller sunmuşlardır.

B. Uğur Töreyn vd. [17], video da dumanı algılayabilmek için sabit bir kamera kullanarak çalışma yürütmüşlerdir. Mevcut görüntüde dumanı algılamak için arka planı tahmin etmişlerdir. Görüntü sahnesindeki yüksek frekanslı enerjinin azalmasını ve arka plan görüntüsünün mekânsal dalgalı dönüşümünü kullanarak izlemişlerdir. Sahnede beliren dumanın periyodik seyreden davranışlarını da HMM kullanarak analiz etmişlerdir.

Byoung Chul Ko vd. [18], video kamera kullanarak yangın dumanını algılamak için, dumanın renk bilgisini, dalgalı katsayılarını, hareket yönelimini ve yönlendirilmiş gradyanların histogramını kullanmışlardır. Daha sonra geçici-uzaysal özellikleri 100 görüntü karesinden çıkararak dumanı algılama üzerinde çalışma yürütmüşlerdir.

Chunyu Yu vd. [19], görüntü birikimi ve optik akış tekniğine dayalı gerçek zamanlı yangın alevi ve dumanını algılama için bir yöntem sunmuşlardır. Birikim görüntüleri, diferansiyel yöntem sonucunda elde edilen ön plan görüntülerinden hesaplamıştır. Alev aday bölgesini duman bölgesinden ayırmak için iki parametreye başvurmuşlardır. Duman bölgesini algılamak için hareket özelliği ayırt etme yöntemini kullanmışlardır.

B. Uğur Töreyn vd. [20], video tabanlı duman algılama üzerinde çalışma yürütmüşlerdir. Bu çalışmada görüntü alınan kameranın sabit bir kamera olduğu

varsayılmaktadır. Görüntü alınan kameranın görüntü sahnesi içerisinde arka plan tahmini yapılmıştır. Daha sonra sahnede ki yüksek frekans azalması ile mevcut arka planın mekânsal dalgacık yöntemi ile izlenmiştir. Dumanın sınırlarında meydana gelen periyodik davranışları ve dışbukeyliği de analiz eden bir çalışma sunmuşlardır.

B. Toptaş [21], renk özellikleri kullanmıştır. Yangın görüntülerindeki alevi yeni bir renk uzayına taşıyarak tespit etmeye çalışmıştır. Yeni renk uzayı, Yapay Arı Kolonisi algoritması kullanılarak geliştirilmiştir. Alev tespit işlemi yaptıktan sonra ikili görüntüler veri seti içerisinde bulunan gerçek ikili görüntüler ile benzerlik ölçütüne tabi tutulmuş ve önerilen yöntemin başarı ölçütü hesaplanmıştır.

Qi-xing Zhang vd. [22], geleneksel metotlardan kaçmak için R-CNN kullanmışlardır. Dumanı tespit etmek için sentetik duman görüntüler kullanmışlardır. Bu çalışmada gerçek duman görüntülerinden arka planları çıkarılır ve bu arka planlara sentetik duman görüntüler eklenmiştir. Bu görüntülerde dumanın hareket karakteristiği ve dumanın renk eşik değeri tespit edilmiştir. Bu çalışma küçük dumanlara karşı duyarsızdır.

1.3 Tezin Organizasyonu

Bölüm 1’de, orman yangınları, orman yangınlarında duman faktörü ele alınmıştır. Ayrıca literatürde yapılan erken yangın tespit sistemlerine değinilmiştir. Son olarak tezin amacından bahsedilmiştir.

Bölüm 2’de, tez çalışmasında kullanılan yöntemler hakkında teorik bilgiler verilmiştir.

Bölüm 3’de, doku özellik çıkarım yöntemlerinden bahsedilmiştir. Doku özellik çıkarım yöntemleri 5 ana başlık altında incelenmiştir. Bunlar sırası ile Yerel İkili Örüntüler (LBP), Yerel Üçlü Örüntüler (LTP), Law’s Doku Enerji Değerleri (LAWS), Gri Seviye Eş Oluşum Matrisi (GLCM) ve Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)’dir.

Bölüm 4’de, sınıflandırıcılar başlığı altında 3 farklı sınıflandırıcı incelenmiştir. Bunlar Destek Vektör Makinaları (SVM), Yapay Sinir Ağları (ANN) ve k-En Yakın Komşu (KNN) algoritmalarıdır.

Bölüm 5’de, önerilen duman algılama yönteminden bahsedilmiştir. Veri seti hakkında bilgiler verilmiştir.

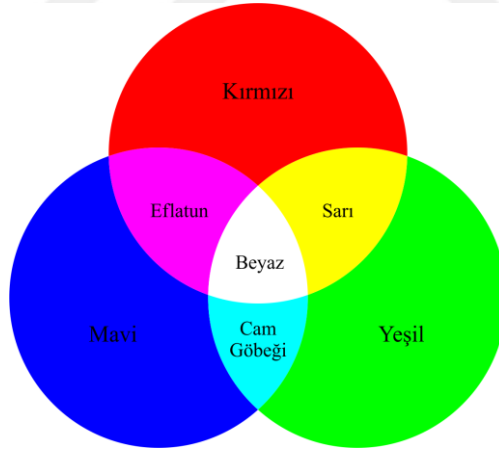
Bölüm 6’da, önerilen yöntemin veri seti üzerinde uygulaması görsel ve istatistiksel sonuçlarla gösterilmiştir.



2. TEORİK BİLGİLER

2.1 RGB Renk Uzayı

Kırmızı, Yeşil ve Mavi olmak üzere 3 ana renkten oluşmaktadır. Bu 3 ana renk dalga boylarının çeşitli oranlarda alınmasıyla diğer bütün renkleri elde edilen bir renk uzayıdır. Bu üç renge ait her dalga boyunun %100 oranında karıştırılması ile beyaz renk elde edilir. Bu üç renge ait her dalga boyunun %0 oranında karıştırılması ile siyah renk elde edilir. Üç ana renk farklı oranlarda karıştırılarak ara renkler elde edilebilir. RGB modeli bilgisayar ekranları veya katodik televizyon tüpleri gibi, doğrudan emilimle çalışan cihazlarda kullanılır. Ayrıca alt yapı materyali rengin elde edilmesinde belirleyici faktördür. Öyle ki alt yapının değişmesiyle renk de değişecek, dolayısıyla televizyon, tarayıcı veya bir monitör üçlemesinde aynı renk elde edilemeyecektir. Dolayısıyla bu renk uzayı üç ana rengi kullanıp, diğer ana renkleri göz ardı ettiğinden %100 fonksiyonel bir yapıya sahip değildir. RGB renk uzayı çok yaygın kullanılmaktadır. Şekil 2.1’de RGB renk uzayındaki renklerin oluşumuna ait bir görsel verilmiştir.



Şekil 2.1. RGB Renk Uzayı

RGB görüntüler dijital ortamda ifade edilirken üç boyutlu bir matrisle ifade edilmektedir. Matrisin satır ve sütunları görüntü boyutunu verirken, üçüncü boyutta ise renk kanalı bilgisi tutulmaktadır. Bu renk kanalları Kırmızı, Yeşil ve Mavi renklerinin değerlerini temsil etmekte olup 8 bit ile ifade edilmektedir. 8×3 hesaplaması ile 1 renk değeri 24 bit ile temsil edilmiş olur. Bir renk 2^n bit ile ifade

edildiğinden 8 bitlik üç boyutlu renk kanalı $(2^8)^3$ hesaplaması ile 16.777.216 sayısal değeri kadar renk oluşturabilir.

RGB renk uzayında bütün renkler teorik olarak bir küpün içerisinde veya üzerinde yer alır. Küpün köşegen noktalarında gri tonlar birikir. RGB renk uzayında 3 kanaldan gelen renk değerleri ile bütün renkler elde edilebilir. Çizelge 2.1’de RGB renk uzayında bulunan üç renk kanalına ait renk değerlerinin birleşmesi ile oluşan renkler gösterilmiştir.

Çizelge 2.1. RGB Renk Değerleri

	Siyah	Kırmızı	Yeşil	Mavi	Sarı	Eflatun	Cam Göbeği	Beyaz
R	0	255	0	0	255	255	0	255
G	0	0	255	0	255	0	255	255
B	0	0	0	255	0	255	255	255

Çizelge 2.1’e göre RGB renk uzayında siyah renk bütün renk kanallarının sıfır (0) değer aldığı durumda oluşur. Beyaz renk ise bütün renk kanallarının iki yüz elli beş (255) değerini aldığı durumda oluşur.

3. DOKU ÖZELLİK ÇIKARIM YÖNTEMLERİ

3.1 Yerel İkili Örüntüler (LBP)

Yerel İkili Örüntüler (LBP) Ojala tarafından önerilen yerel komşuluk değerlerine dayalı bir öznelik çıkarma yöntemidir [23]. LBP, küçük ölçekli görüntü dokusunu vurgulamak ve görüntüler arasındaki benzerlikleri ön plana çıkarmak için kullanılır. Teorik olarak, bir görüntüde her piksel değerinin gri seviyesini göz önünde bulundurarak, her bir piksel değerini 8 bitlik bir ikili kodla değiştirir. Denklem (3.1)'de bir pikselin LBP değerinin hesaplanması gösterilmiştir [24].

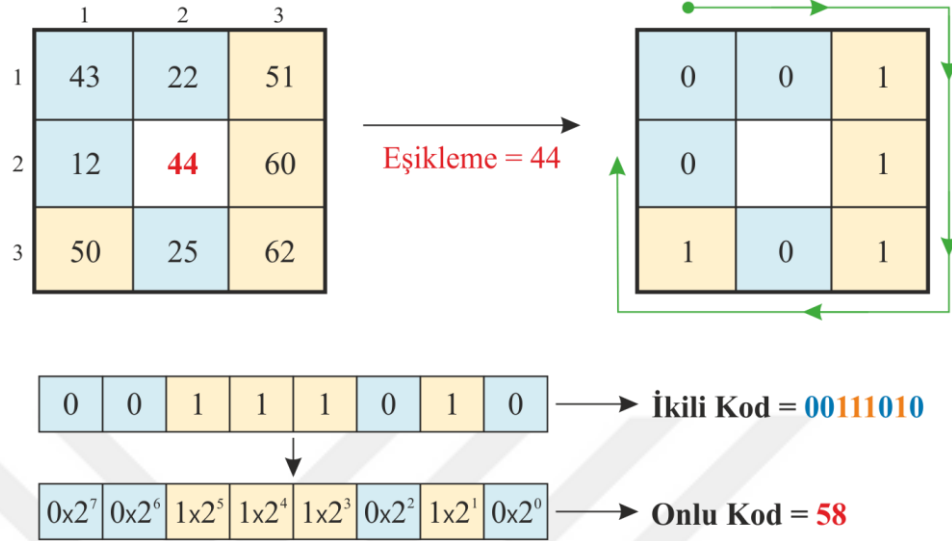
$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (3.1)$$

Denklem (3.1)'deki g_c parametresi orta piksel değerini, R parametresi seçilen yarıçap değerini ve P parametresi komşu piksellerin sayısını temsil etmektedir. LBP'de genellikle, küçük ölçekli görüntü dokusunu modellemek için g_c merkezli, yarıçapı bir ($R=1$) olan, 3×3 'lük bir pencere ve komşu piksel sayısı sekiz ($P=8$) olan bir yapı kullanılır. Yöntem, merkez piksel (g_c) ile komşu piksellerinin (P) arasındaki farkın hesaplanmasından oluşur. Merkez pikselin (g_c) sol üst tarafındaki pikselle başlanarak saat yönünde ilerletilir. Her komşu piksel değerinden merkez piksel (g_c) değeri çıkarılır ve Denklem (3.1)'de gösterildiği gibi bir piksel değerinin LBP sonucuna karşılık gelen onluk değeri elde edilir. Burada, g_p parametresi komşu piksel değerlerini temsil eder. Denkleminde ifade edilen s parametresi bir fonksiyon olup matematiksel ifadesi Denklem (3.2)'de verilmiştir.

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (3.2)$$

Denklem (3.2)'deki $s(x)$ fonksiyonunda ifade edildiği gibi komşu pikselden merkez pikselin çıkarılması sonucu 0 veya 0'dan büyük ise $s(x)$ değeri bir (1) olur. Diğer tüm durumlar da ise değer sıfır (0) olur.

Yarıçapı bir ($R=1$) ve dairesel komşuluğu sekiz ($P=8$) olarak alınan bir görüntü matrisine ait LBP matrisinin elde edilmesi Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Bir Matrisin LBP Sonucu

Şekil 3.1’de verilen 3x3’lük görüntü kesitine ait matris de orta değer (g_c), ikinci satır ve sütundaki (2,2) değere karşılık gelen 44 değeridir. 44 değeri tüm komşu pikselleri ile kıyaslanacaktır. Bu kıyaslama işlemi, birinci satır ve birinci sütundaki (1,1) piksel değerinden başlanarak saat yönünde gerçekleşmektedir. Kıyaslama işleminde, ilgili komşu piksel değeri orta değerinden çıkarılır. Çıkarma işlemi sonunda çıkan değer sıfırdan (0) küçük ise LBP matrisinde ilgili komşunun değeri sıfır (0) olarak değiştirilecektir. Şekil 3.1’de verilen 3x3’lük matris de birinci satır ve sütundaki değer 43 değeridir ve bu değer 44 orta değerinden çıkarıldığında sonuç sıfırdan (0) küçük olduğu için LBP matrisinde birinci satır ve sütundaki (1,1) değere sıfır yazılmıştır.

Kıyaslama işleminde, ilgili komşu piksel değeri 44 orta değerinden çıkarılır. Çıkarma işlemi sonunda çıkan değer sıfıra (0) eşit ve sıfırdan büyük ise LBP matrisinde ilgili komşunun değeri bir (1) olarak değiştirilecektir. Şekil 3.1’de verilen 3x3’lük matris de üçüncü satır ve sütundaki (3,3) değer 62 değeridir ve bu değer 44 orta değerinden çıkarıldığında sonuç sıfırdan (0) büyük olduğu için LBP matrisinde üçüncü satır ve sütundaki değere bir (1) yazılmıştır.

İkinci satır ve sütunda (2,2) bulunan 44 değeri, tüm komşuları ile aynı şekilde kıyaslanarak LBP matrisi oluşturulmaktadır. LBP matrisi oluşturulduktan sonra, 44 orta değeri için sekiz (8) bitlik ikili LBP kodu hesaplanır. Bu hesaplama işlemi, yeni matrisin birinci satır ve sütundaki değerinden başlanarak saat yönünde ki tüm değerlerin ardı ardına eklenmesiyle elde edilir. Şekil 3.1’de verilen 44 orta değeri için sekiz bitlik ikili LBP kodu 000111010 olarak hesaplanmıştır. Daha sonra, elde edilen sekiz (8) bitlik LBP kodu on tabanına dönüştürülerek 58 değeri elde edilmiştir. Elde edilen bu değer, ilgili matrisin LBP değeridir.

Elde edilen LBP değerlerinin hepsi doku tanımlamada kullanılan değerler değildir. Doku tanımlamada kullanılan LBP değerleri, sıfırdan bire (0-1) ya da birden sıfıra (1-0) geçiş sayısı sıfır (0), bir (1) veya iki (2) olan örüntülerden seçilmektedir. Bu örüntülere düzgün dağılımlı örüntüler denir. Örneğin; 00000000 ve 11111111 örüntülerinde geçiş sıfır (0) olduğu için düzgün dağılımlıdır. Sekiz bitlik 00001111 örüntüsünde dördüncü bitten beşinci bite geçişte birden sıfıra (1-0) sadece bir (1) geçiş mevcuttur, sekiz bitlik 11000000 örüntüsünde ise altıncı bitten yedinci bite sıfırdan bire (0-1) bir geçiş sağlanmış olup geçiş değerleri birdir. Sekiz bitlik 01111100 örüntüsü için ikinci bitten üçüncü bite sıfırdan bire (0-1) ve yedinci bitten sekizinci bite birden sıfıra (1-0) bir geçiş sağlanmış olup toplam geçiş değeri ikidir. Fakat iki (2) geçiş değerinden daha büyük geçiş değerine sahip örüntüler düzgün dağılımlı değildir. Örneğin, sekiz bitlik 11101100 örüntüsünde ikinci bitten üçüncü bite (0-1) geçişi, dördüncü bitten beşinci bite (1-0) geçişi ve beşinci bitten altıncı bite (0-1) geçişi olmak üzere toplamda üç geçiş vardır ve bu örüntü düzgün dağılımlı değildir. Literatür de LBP tabanlı doku analizleri incelendiğinde, araştırılan doku bölgelerinin %90 oranında düzgün dağılımlı bölgelerden oluştuğu görülmüştür.

Denklem (3.3)’de LBP histogramının hesaplanması matematiksel olarak ifade edilmiştir.

$$H_i = \sum_{x,y} I\{f_1(x, y) = i\}, i = 0, 1, \dots, n-1, \quad (3.3)$$

$$I\{A\} = \begin{cases} 1, & A \text{ doğru ise} \\ 0, & A \text{ yanlış ise} \end{cases}$$

Burada, n parametresi LBP operatörü tarafından üretilen farklı etiket sayısıdır. Bu etiket sayısı sekiz (8) bitlik gri ölçekli görüntülerde 256 değerine sahiptir. i

parametresi, 0 ile $n-1$ arası değişen değerlerdir. f parametresi x 'inci satır ve y 'inci sütün pikselindeki değeri temsil etmektedir. i parametresi f fonksiyon değerinin sahip olduğu frekans değeridir. A parametresi ise f fonksiyon değeri ile i 'inci değerin eşitlik durumunu inceler. Elde edilen H histogram parametresi görüntü üzerindeki tüm kenarları, benekleri ve düz alanlar gibi mikro-örüntülere ait bilgileri taşımaktadır.

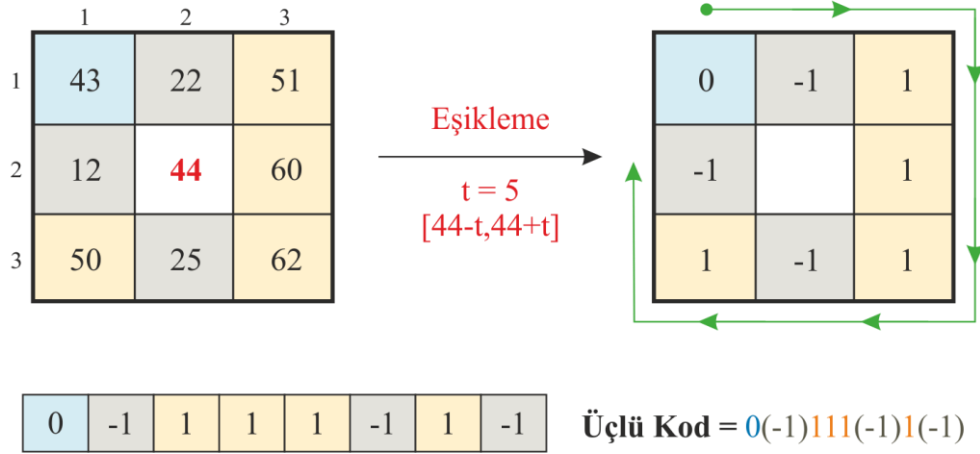
3.2 Yerel Üçlü Örüntüler (LTP)

Yerel Üçlü Örüntüler (LTP) görüntülerdeki dokuyu modellemek için kullanılan bir yöntemdir. Yakın zamanda Suruliandi ve Ramar tarafından LBP'ye [23] ek olarak sunulmuştur [25] LTP yönteminde, eşikleme için 3 değer kullanılmaktadır. Bu üç değer, merkez pikselle kıyaslanan komşu piksel arasındaki ilişkiye göre belirlenir. Bu değerler 0,1 ve -1 değerleridir. Denklem (3.4)'de bir görüntü kesitine ait LTP matrisinin elde edilmesi matematiksel olarak ifade edilmiştir.

$$LTP_{P,R,t} = \sum_{i=0}^{P-1} s(p_i - p_c) \times 3^i, s(x) = \begin{cases} 1 & x \geq t \\ 0 & |x| < t \\ -1 & x \leq -t \end{cases} \quad (3.4)$$

Denklem (3.4)'de bir görüntü kesitine LTP uygulanmıştır. Burada, p_i parametresi görüntü matrisindeki komşu pikselleri, p_c parametresi ise aynı matrisin merkez pikselini temsil etmektedir. P parametresi, komşu sayısını temsil etmektedir. i parametresi 0'dan $P-1$ değerleri arasında değişen komşu pikselleri temsil etmektedir. t parametresi tolerans değerini, x parametresi ise, merkez piksel değerinden ilgili komşu piksel değerinin farkını temsil etmektedir. Eğer x parametresi, t parametresinden büyük ve eşit ise $s(x)$ kıyaslama fonksiyonu 1 değerini, mutlak değerce küçükse $s(x)$ kıyaslama fonksiyonu 0 değerini almaktadır. Ancak, x parametresi t parametresinin negatif haline eşit veya küçükse $s(x)$ kıyaslama fonksiyonu -1 değerini almaktadır.

Şekil 3.2'de, 3×3 'lük bir görüntü kesitine ait matris için LTP matrisinin oluşturulması gösterilmiştir. Bu şekil için en fazla bir komşuluk uzaklığına bakılmış yani yarıçap bir kabul edilmiş ($R=1$) ve sekiz komşu ($P=8$) ile kıyaslama yapılmıştır.




Şekil 3.2. Bir Matrisin LTP değerinin bulunması

Şekil 3.2’de verilen ilk matris de merkez değeri ikinci satır ve ikinci sütundaki (2,2) değere karşılık gelen 44 değeridir. Merkez değeri, birinci satır ve birinci sütundaki (1,1) komşu değerinden başlanarak saat yönünde sekiz komşusu ile kıyaslanır. Şekil 3.2’de verilen matris için tolerans değeri beş ($t=5$) olarak seçilmiştir. Tolerans değeri, LTP’de kıyaslama aralığını genişletmek için kullanılmaktadır. Birinci satır ve birinci sütundaki (1,1) 43 değerinden merkez piksel değeri çıkarılarak ($43-44$) x değeri elde edilir. Elde edilen x değeri tolerans (t) değeri ile kıyaslanır. Kıyaslama işleminde ($-1 < 5$) x değeri tolerans değerinden mutlak değerce küçük olduğu için LTP matrisinde ilgili komşunun değeri sıfır (0) olarak belirlenir.

Birinci satır ve ikinci sütundaki (1,2) 22 değerinden merkez piksel değeri çıkarılarak ($22-44$) x değeri elde edilir. Elde edilen x değeri tolerans (t) değeri ile kıyaslanır. Kıyaslama işleminde ($-22 < -5$) x değeri eksi tolerans ($-t$) değerinden küçük veya eşit şartını sağladığı için LTP matrisinde ilgili komşunun değeri eksi bir (-1) olarak belirlenir. Birinci satır ve üçüncü sütundaki (1,3) 51 değerinden merkez piksel değeri çıkarılarak ($51 - 44$) x değeri elde edilir. Elde edilen x değeri tolerans (t) değeri ile kıyaslanır. Kıyaslama işleminde ($7 > 5$) x değeri tolerans değerinden büyük veya eşit olma şartını sağladığı için LTP matrisinde ilgili komşunun değeri bir (1) olarak belirlenir. Diğer komşular içinde kıyaslama işlemi aynı şekilde yapılmaktadır. Sekiz komşu piksel ile merkez piksel değerinin kıyaslama sonucunda 0(-1)111(-1)1(-1) örüntüsü elde edilmiştir.

Elde edilen 0(-1)111(-1)1(-1) örüntüsü pozitif ve negatif matrisler olarak iki parçaya ayrılmış ve Şekil 3.3’de gösterilmiştir.



Şekil 3.3. LTP Matrisinin Pozitif ve Negatif Matrisleri

Şekil 3.3’de verilen 0(-1)111(-1)1(-1) LTP örüntüsü için pozitif örüntü 00111010 olarak elde edilmiştir. Pozitif örüntü elde edilirken LTP örüntüsündeki negatif değerler (-1), sıfır (0) olarak değiştirilmiştir. 0(-1)111(-1)1(-1) LTP örüntüsü için negatif örüntü ise 01000101 olarak elde edilmiştir. Negatif örüntü elde edilirken LTP örüntüsündeki negatif değerler (-1) bir (1) olarak, pozitif değerler (+1) ise sıfır (0) olarak değiştirilmiştir. Oluşturulan negatif ve pozitif örüntüler LBP görüntüleridir. LBP betimleyicileri, ayrı histogram ve benzerlik ölçümleri için 2 kanaldan hesaplanmakta, hesaplama sonunda bunlar birleştirilmektedir. LTP görüntüleri pozitif ve negatif matrisler olarak iki ayrı LBP görüntüsüne dönüştürülmüştür.

3.3 Law’s Doku Enerji Değerleri (LAWS)

Law’s Doku Enerji Değerleri (LAWS) doku analizi için kullanılan bir yöntemdir. Bir görüntüde bazı karakteristik özelliklerin (miktar, kenar, nokta, salınım ve damla) ortaya çıkarılması için küçük evrişim maskeleri kullanılabilir. Law’s doku özellikleri doku türlerini anlamak için yerel maskeleri kullanır. Bu yöntem Law tarafından [26] sabit büyüklükteki bir pencere içerisinde ki değişimi ölçen doku enerji

yaklaşımı olarak geliştirilmiştir. Doku enerjisini hesaplamak için dört adet 5x5 boyutunda konvolüsyon maske seti kullanılmıştır. Denklem (3.5)'de kullanılan dört konvolüsyon maskesi verilmiştir.

$$\begin{aligned}
 L5 &= \begin{bmatrix} 1 & 4 & 6 & 4 & 1 \end{bmatrix} \\
 E5 &= \begin{bmatrix} -1 & -2 & 0 & 2 & 1 \end{bmatrix} \\
 S5 &= \begin{bmatrix} -1 & 0 & 2 & 0 & -1 \end{bmatrix} \\
 R5 &= \begin{bmatrix} 1 & -4 & 6 & -4 & 1 \end{bmatrix}
 \end{aligned} \tag{3.5}$$

Burada, L5 maskesi gri seviye yoğunlukları, E5 maskesi kenarları, S5 maskesi lekeleri ve R5 maskesi ise dalgalanmaları algılayabilmek için oluşturulmuştur.

Denklem (3.5)'de verilen vektörler kendisi ve diğerleri ile çarpılarak 16 adet iki boyutlu konvolüsyon maskeleri oluşturulur. Oluşturulan bu maskeler Denklem (3.6)'da verilmiştir.

$$\begin{aligned}
 &L5L5 \quad L5E5 \quad L5S5 \quad L5R5 \\
 &E5L5 \quad E5E5 \quad E5S5 \quad E5R5 \\
 &S5L5 \quad S5E5 \quad S5S5 \quad S5R5 \\
 &R5L5 \quad R5E5 \quad R5S5 \quad R5R5
 \end{aligned} \tag{3.6}$$

Denklem (3.6)'da verilen iki boyutlu konvolüsyon maskelerinden *L5E5* konvolüsyon maskesinin oluşturulması Denklem (3.7)'de verilmiştir. Diğer maskelerde benzer şekilde oluşturulmaktadır.

$$L5E5 = \begin{bmatrix} 1 \\ 4 \\ 6 \\ 4 \\ 1 \end{bmatrix} \times \begin{bmatrix} -1 & -2 & 0 & 2 & 1 \end{bmatrix} = \begin{bmatrix} -1 & -2 & 0 & 2 & 1 \\ -4 & -8 & 0 & 8 & 4 \\ -6 & -12 & 0 & 12 & 6 \\ -4 & -8 & 0 & 8 & 4 \\ -1 & -2 & 0 & 2 & 1 \end{bmatrix} \tag{3.7}$$

Denklem (3.6)'da verilen 16 adet konvolüsyon maskelerinden simetrik olan maskeler tek bir maske kabul edilerek toplam 10 adet maske elde edilir. Elde edilen maskeler Denklem (3.8)'de verilmiştir. Bu maskeler içerisinde *L5L5* maskesi,

görüntünün yoğunluk değerini değiştirdiği için hesaplamalarda kullanılmaz. Bu durumda maske sayısı 9 olarak alınır.

$$\begin{array}{lll}
 L5E5 / E5L5 & E5S5 / S5E5 & S5S5 \\
 L5S5 / S5L5 & E5R5 / R5E5 & E5E5 \\
 L5R5 / R5L5 & E5S5 / S5R5 & R5R5
 \end{array} \quad (3.8)$$


Oluşturulan 9 adet maske kullanılarak 100x100 boyutunda gri ölçekli bir görüntüden 9 adet 100x100 boyutunda maskelenmiş görüntüler elde edilir.

3.4 Gri Seviye Eş Oluşum Matrisi (GLCM)

Gri Seviye Eş Oluşum Matrisi (GLCM) ilk defa Haralick vd. tarafından önerilen bir doku analiz yöntemidir [27]. Bu yöntem görüntünün ikinci derece istatistiksel olasılıklarını kullanarak doku analizleri yapmaktadır. GLCM hesaplanırken yön (θ) ve komşuluk (d) bilgisi kullanılır. θ bilgisi için $0^\circ, 45^\circ, 90^\circ$ ve 135° değerleri kullanılırken, d bilgisi için genelde 1 veya 2 değerleri kullanılmaktadır. GLCM oluşturulurken görüntüye ait her pikselin gri ton değeri Denklem (3.9)'da verildiği gibi hesaplanır.

$$P(i, j) = \frac{P(i, j, d, \theta)}{\sum_{i=1} \sum_{j=1} P(i, j, d, \theta)} \quad (3.9)$$

Burada, (i, j) pikselin frekans değeri, d komşuluk bilgisi ve θ yön bilgisidir. Şekil 3.4'de GLCM'ye ait θ bilgisini gösteren bir şekil verilmiştir.



Şekil 3.4. GLCM Yön Bilgisi

Şekil 3.4’de 4x4’lük görüntü kesiti için gri ton dağılımı oluşturulmuştur. Şekil 3.4’de oluşturulan gri ton dağılımı kullanılarak 0° açı bilgisine ve bir komşuluk bilgisine (d=1) sahip GLCM matrisi Şekil 3.5’de gösterilmiştir. GLCM matrisi oluşturulurken, orijinal matrisin içerisindeki en büyük değer GLCM matrisinin boyutu olarak belirlenir. Daha sonra orijinal matrisin içindeki değerlerin açı ve komşuluk bilgisine göre geçişleri kontrol edilir. Geçişlerin tekrar sayısı GLCM matrisinde geçiş yapılan satır ve sütun bilgisine yazılarak ilgili matrisin GLCM matrisi oluşturulur.

1	5	4	5
2	3	1	3
4	1	2	5
1	5	2	3

(a)

	1	2	3	4	5
1	0	1	1	0	2
2	0	0	2	0	1
3	1	0	0	0	0
4	1	0	0	0	1
5	0	1	0	1	0

(b)

Şekil 3.5. GLCM Matrisinin Hesaplanması

Şekil 3.5’de (a) matrisi 4x4’lük bir görüntü kesitine ait bir matrisi temsil etmektedir. (b) matrisi ise (a) matrisinin GLCM matrisini temsil etmektedir. Şekil 3.5’de verilen (a) matrisindeki en büyük değer beş olduğu için (b) matrisi 5x5 boyutunda oluşturulmuştur. Daha sonra bu örnek için 0° açı ve bir komşuluk değeri (d=1) kullanılmıştır. Matriste 1 değerinin ardından gelen 5 değerinin iki kez geldiği gözlemlenmiştir. Dolayısıyla (b) matrisinde birinci satır ve beşinci sütun (1,5) değeri 2 olmuştur. GLCM matrisinde tekrar sayısı yoksa ilgili pikselin değeri 0 olarak alınmıştır. (a) matrisinde 1’den 1’e bir geçiş olmadığı için (b) matrisinde birinci satır ve sütun (1,1) değeri 0 olarak belirlenmiştir.

Görüntüye ait GLCM oluşturulduktan sonra bu matris üzerinden özellikler çıkarılır. Bu özellikler ilgili dokunun karakteristiğini temsil eder. Dokunun karakteristik özellikleri, zıtlık, varyans, entropi, homojenlik, ikinci moment ve enerji

bilgisini içeren parametrelerdir. Bu tez çalışmasında, GLCM üzerinden elde edilen doku özellikleri Çizelge 3.1’de verilmiş ve bu özelliklerin matematiksel ifadeleri gösterilmiştir.

Çizelge 3.1. GLCM Özellikleri

DOKUSAL ÖZELLİKLER	MATEMATİKSEL İFADELER
Zıtlık	$\sum_{i,j=0}^{PS} P_{i,j} i - j $
Enerji	$\sum_{i,j}^{PS} P_{i,j}^2$
Entropi	$\sum_{i,j=0}^{PS} P_{i,j} (-\ln P_{i,j})$
Homojen	$\sum_{i,j=0}^{PS} \frac{P_{i,j}}{1 + (i - j)^2}$
Varyans Farkları	$P_x - P_y$ 'nin varyansı
Entropi Farkları	$-\sum_{i=0}^{PS} P_{x-y}(i) \cdot \log\{P_{x-y}(i)\}$
Korelasyon Ölçümü 1	$\frac{EXY - EXY1}{\max\{EX, EY\}}$ $EXY = -\sum_{i,j=0}^{PS} P_{i,j} \log_2 P(i, j)$ $EXY1 = \sum_{i,j=0}^{PS} P_{i,j} \log_2 \{P_x(i)P_y(j)\}$
Korelasyon Ölçümü 2	$\sqrt{1 - \exp[-2.0(EXY2 - EXY)]}$ $EXY2 = -\sum_{i,j=0}^{PS} P_x(i) \cdot P_y(j) \log_2 \{P_x(i)P_y(j)\}$

Çizelge 3.1’de verilen GLCM matrisi elde edildikten sonra çıkarılan özelliklerin kısa açıklaması şöyledir:

Zıtlık: Zıtlık derecesinde, GLCM olasılıklarının çarpıldığı ağırlıklar diyagonalden doğrusal olarak artmaktadır.

Enerji: GLCM oluşumunda elemanların karelerinin toplamını verir. Dokulardaki bozuklukları algılar. Gri seviye görüntü dağılımları düzgün ise enerji değeri yüksek çıkar.

Entropi: Görüntünün karmaşıklığını ölçen istatistiksel bir özelliktir. Enerji özelliği ile ters orantılıdır. Eş oluşum matrisinin elemanları küçük olduğunda entropi değeri yüksek olur.

Homojen: Eş oluşum matris elemanlarının diyagonale yakınlığını ölçer.

Korelasyon Ölçümü: Görüntüdeki gri tonlu doğrusallık ilişkisinin bir ölçütüdür.

3.5 Gri Seviye Koşu Uzunluğu Matrisi (GLRLM)

Gri Seviye Koşu Uzunluğu Matrisi (GLRLM), farklı uzunlukların gri seviye sayılarının hesaplanmasına dayanır [27]. Bir gri seviye uzunluğu, aynı gri seviye değerine sahip doğrusal bir komşu görüntü noktalar dizisidir. Gri seviye, dizi uzunluğu içindeki görüntü noktalarının sayısıdır. GLRLM, iki boyutlu bir matris olup doku özellik çıkarımında kullanılmaktadır. Çalışma uzunluğu, aynı yönde aynı gri yoğunluklu piksellere sahip komşuların frekansıdır. Genelde piksel yoğunluğu yüksek dokular küçük koşma eğilimi gösterirken, piksel kalitesi düşük dokular daha uzun koşmalar içermektedir. GLRLM ile görüntünün uzun veya kısa uzunluklarda yüksek veya düşük yoğunluklu gri tonlamaları olup olmadığı belirlenebilmektedir. Şekil 3.6'da 4x4 lük bir görüntü matrisi için GLRLM yapısının oluşturulması gösterilmiştir. GLRLM yapısı oluşturulurken, orijinal matrisin boyutu koşu uzunluğunun maksimum sınır değerini vermektedir. Orijinal matris içindeki her değer içinde gri seviyeler belirlenmektedir.

	1	2	3	4
1	2	2	3	3
2	4	3	1	1
3	1	3	3	3
4	2	3	3	4

(a)

Gri Seviye	Koşu Uzunluğu			
	1	2	3	4
1	1	1	0	0
2	1	1	0	0
3	1	2	1	0
4	2	0	0	0

(b)

Şekil 3.6. GLRLM Matrisinin Hesaplanması

Şekil 3.6’da (a) matrisi 4x4 boyutunda olup bir görüntü kesitine ait matrisi temsil etmektedir. Şekil 3.6’da (b) matrisi ise, (a) matrisine ait GLRLM matrisini temsil etmektedir. Bu örnekte gösterildiği gibi bir pikselin gri yoğunluk değeri incelenen yöndeki ($0^\circ, 90^\circ, 135^\circ, 180^\circ$ gibi) uzunluk bilgisi ile hesaplanmaktadır. (a) matrisi içindeki en büyük değer dört (4) olduğu için gri seviye değeri 1 ile 4 arası değerler için incelenmiştir. Matris boyutu 4x4 olduğu için maksimum koşu uzunluğu dört olabilmektedir. Yani bir değer art arda en fazla dört defa gelebilir.

Şekil 3.6’da (a) matrisi incelendiğinde art arda üç defa üç gelme durumu üçüncü satır ikinci sütun, üçüncü satır üçüncü sütun ve üçüncü satır dördüncü sütun ((3,2),(3,3),(3,4)) piksellerinde görülmüştür. Dolayısıyla 3 gri seviye değeri için koşu uzunluğu bir kez 3 olmuştur. Art arda iki (2) değerinin gelmesi sadece birinci satır birinci sütun ve birinci satır ikinci sütunda ((1,1),(1,2)) gerçekleştiği için 2 gri seviye değeri için koşu uzunluğu bir kez 2 olmuştur. (a) matrisindeki tüm değerler aynı şekilde incelenerek GLRLM oluşumu gerçekleştirilir. GLRM oluşumu gerçekleştirildikten sonra, bu oluşum üzerinden bazı özelliklere ulaşılır. Bu özellikler, Çizelge 3.2’de verilmiştir.

Çizelge 3.2. GLRLM Özellikleri

DOKUSAL ÖZELLİKLER	MATEMATİKSEL İFADELER
Kısa Koşu Vurgusu	$SRE = \sum_{i=1}^{N_g} \sum_{j=1}^{L_r} \frac{p(i, j)}{j^2}$
Uzun Koşu Vurgusu	$LRE = \sum_{i=1}^{N_g} \sum_{j=1}^{L_r} j^2 p(i, j)$
Gri Seviye Düzensizliği	$GLN = \sum_{i=1}^{N_g} \left(\sum_{j=1}^{L_r} p(i, j) \right)^2$
Koşu Uzunluk Düzensizliği	$RLN = \sum_{j=1}^{L_r} \left(\sum_{i=1}^{N_g} p(i, j) \right)^2$
Koşu Yüzdesi	$RP = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{L_r} p(i, j)}{\sum_{j=1}^{L_r} j \sum_{i=1}^{N_g} p(i, j)}$
Düşük Gri Seviye Koşu Vurgusu	$LGRE = \sum_{i=1}^{N_g} \sum_{j=1}^{L_r} \frac{p(i, j)}{i^2}$
Yüksek Gri Seviye Koşu Vurgusu	$HGRE = \sum_{i=1}^{N_g} \sum_{j=1}^{L_r} i^2 p(i, j)$

4. SINIFLANDIRICILAR

4.1 Destek Vektör Makinaları (SVM)

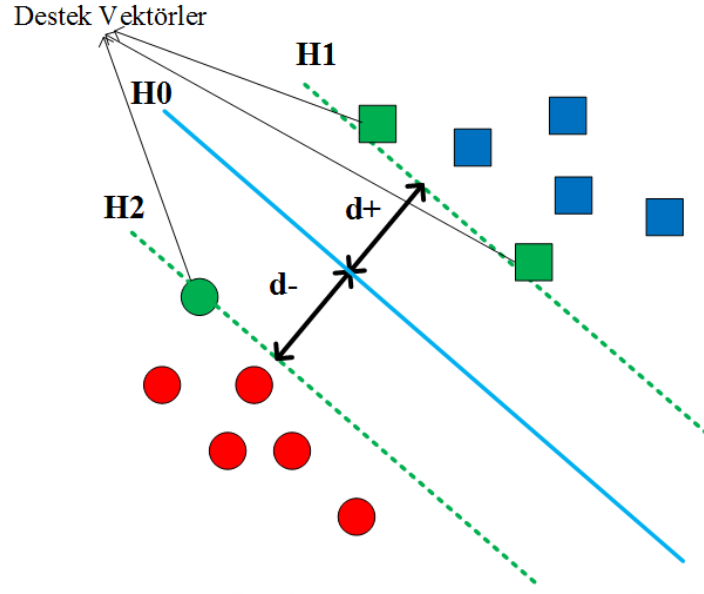
SVM, ilk olarak 1995 yılında Vapnik tarafından [28] sınıflandırma problemlerinin çözümü için geliştirilmiştir. SVM, yapısal risk minimizasyonu ilkesine dayanan bir istatistiksel öğrenme teorisi yöntemidir [29]. Yapısal risk minimizasyonu, gerçek risk ile ampirik risk arasındaki farkı kontrol etmek için kullanılan bir yöntemdir.

SVM temelde iki boyutlu ve çok boyutlu sınıflandırma problemleri için çözümler geliştirmektedir. SVM'ler, iki sınıflı veriye ait nokta kümesini ayıran en iyi hiper düzlemi bulmaya çalışmaktadır. SVM, en iyi hiper düzlemi bulmaya çalışırken her iki sınıfa da en uzak olan hiper düzlemi seçmektedir. Hiper düzleme en yakın noktalar destek vektörleri olarak adlandırılır.

SVM'de eğitim ve test verileri ile işlemler yapılır. Eğitim verileri, en iyi hiper düzlemi aramada kullanılır. Test verileri ise sınırın hangi tarafında kalmışsa o sınıfa dâhil edilerek sınıflandırma işlemi yapılır. İki boyutlu problemlere çözüm sunan SVM'ler, doğrusal ayrılabilen veriler ve doğrusal olarak ayrılamayan veriler için sınıflandırma yapmaktadır.

4.1.1 Doğrusal Ayrılan Veriler

Doğrusal olarak ayrılabilen veriler genellikle $y_i \in \{-1,+1\}$ ile ifade edilen sınıflardan birine ait olan x_i verileridir. Burada $i = 1, \dots, N$ kümesine aittir ve $x_i \in R^n$ 'dir. N boyutunda, (x_i, y_i) ikililerinden oluşan bir S eğitim kümesi verildiğinde, Şekil 4.1 de gösterildiği gibi farklı sınıflar birbirinden ayrılır.



Şekil 4.1. Doğrusal SVM Gösterimi

Şekil 4.1’de H1 ve H2 kesikli çizgiler sınıfları ayıran hiper düzlemleri temsil ederken, H0 çizgisi her iki sınıftan da maksimum uzaklıktaki en iyi hiper düzlemi göstermektedir. Doğrusal olarak ayrılabilen iki sınıflı verileri sınıflandıran birden fazla hiper düzlem bulunabilmektedir. Ancak, SVM bu en iyi hiper düzlemi bulmak için iki sınıfın verilerine en uzak noktalardan geçen doğruyu seçmektedir. Şekil 4.1’de H1 ve H2 hiper düzlemleri üzerinde bulunan yeşil küme verileri destek vektörleri temsil etmektedir. Destek vektörleri, H1 ve H2 ayırma düzlemi üzerinde etkisi en büyük ve düzleme en yakın olan noktalardır. En iyi hiper düzleme olan uzaklık ölçütü pozitif noktaya olan en kısa mesafe olarak $d+$ parametresi ile negatif noktaya olan en kısa mesafe olarak $d-$ parametresi ile temsil edilmektedir.

H0, H1 ve H2 çizgileri için ayırıcı doğrunun matematiksel ifadesi Denklem (4.1)’de ifade edilmiştir.

$$\begin{aligned}
 \text{H1 düzlemi} : w \cdot x_i + b &= +1 \\
 \text{H2 düzlemi} : w \cdot x_i + b &= -1 \\
 \text{H0 düzlemi} : w \cdot x_i + b &= 0
 \end{aligned}
 \tag{4.1}$$

Burada, w parametresi hiper düzlemin ağırlık vektörü olarak, b parametresi ise sabit olarak tanımlanmıştır.

Denklem (4.1)'de verilen ifadeler Denklem (4.2)'ye dönüştürülebilir.

$$y(w.x_i + b) \geq 1, \forall i \in [1, n] \quad (4.2)$$

Bir eğitim örneğinin hiper düzleme olan uzaklığı Denklem (4.3)'de ifade edilmiştir.

$$d(w, b; x_i) = \frac{|w.x_i + b|}{\|w\|} \quad (4.3)$$

Denklem (4.4)'de, Denklem (4.2) için kısıtlarına tabi olan ρ sınır değeri verilmiştir.

$$\begin{aligned} \rho(w, b) &= \min_{x^i, y^i = -1} d(w, b; x^i) + \min_{x^i, y^i = 1} d(w, b; x^i) \\ &= \min_{x^i, y^i = -1} \frac{|\langle w, x^i \rangle + b|}{\|w\|} + \min_{x^i, y^i = 1} \frac{|\langle w, x^i \rangle + b|}{\|w\|} \\ &= \frac{1}{\|w\|} \left(\min_{x^i, y^i = -1} |\langle w, x^i \rangle + b| + \min_{x^i, y^i = 1} |\langle w, x^i \rangle + b| \right) \\ &= \frac{2}{\|w\|} \end{aligned} \quad (4.4)$$

Burada, $\|w\|$ parametresi ağırlık vektörü olan w vektörünün normunu temsil etmektedir. Bu durumda, hiper düzlemin sınırının maksimuma çıkarılması için $\|w\|$ parametresinin minimuma getirilmesi gerekir [29]. En iyi hiper düzlemin belirlenmesi için ise, Denklem (4.5)'de ifade edilen optimizasyon probleminin çözümü gereklidir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (4.5)$$

Bu optimizasyon problemi Lagrange denklemi kullanılarak çözülebilmektedir. Lagrange çarpanları minimize etme problemini, dual problemlere dönüştürerek

problemin çözümünü kolaylaştırmaktadır. Lagrange çözümü Denklem (4.6)'da verildiği gibidir [29].

$$Lp = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N a_i [y_i (w \cdot x_i + b)] + \sum_{i=1}^N a_i \quad (4.6)$$

Burada, a parametresi a_1, \dots, a_N arasında ki negatif olmayan bir Lagrange çarpanıdır. Lp ise Lagrange çözümünün fonksiyonudur. Lagrange fonksiyonu w ve b parametrelerine göre kısmi türevi alınır. Bu kısmi türev sonuçları Lp fonksiyonunda tekrar yerine konulursa Denklem (4.7)'de verilen ifade elde edilmiş olur.

$$\begin{aligned} \text{Max} L_D = L_D(w, a, b) &= \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (x_i x_j) + \sum_{i=1}^N a_i \\ \text{s.t.} \quad \sum_{i=1}^N a_i y_i &= 0 \quad \text{ve} \quad \forall a_i \end{aligned} \quad (4.7)$$

Burada, amaç a_i değerlerini bulmaktır. En iyi hiper düzlem, pozitif değerler alan Lagrange çarpanları ile belirlenir. Sonuçta en iyi hiper düzleme bağlı sınıflandırıcı Denklem (4.8)'de ifade edildiği gibi bulunur.

$$f(x) = \sum a_i y_i x_i^T x + b \quad (4.8)$$

Burada, $f(x) = 1$ ise pozitif olarak, diğer durumlarda negatif olarak sınıflandırıyor.

4.1.2 Doğrusal Ayrılamayan Veriler


Doğrusal ayrılmayan veri kümeleri, doğrusal olarak ayrılabilen yüksek boyutlu bir özellik uzayına taşınarak en iyi hiper düzlemin bulunması sağlanır. Yüksek boyutlu özellik uzayının elde edilmesi pozitif bir yapay değişkenin (ξ_i) tanımlanması ile çözüme kavuşur. Bu değişken hata sınıflandırmayı derecelendirmektedir. Doğrusal ayırım yapamayan verilerin optimizasyon problemi Denklem (4.9)'da ifade edilmiştir.

$$\min \left[\frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \xi_i \right] \quad (4.9)$$

$$\text{Öyle ki: } y_i(w_i^T x_i + b) \geq 1 - \zeta_i \quad \zeta_i > 0, \quad i = 1, \dots, r$$

Burada, C parametresi pozitif değerler içeren ve Lagrange çarpanının alabileceği en üst sınır değerini gösteren bir düzenleme parametresidir. Kullanıcı tarafından belirlenmekte ve eğitim kümesini minimize ederken uzaklığı maksimum etme arasındaki eşiği belirlemektedir [30].

Şekil 4.2’de doğrusal ayrılmayan veri noktaları için pozitif yapay değişkenin (ξ_i) eklenmesi gösterilmiştir.




Şekil 4.2. Doğrusal Ayrılmayan SVM

4.2 Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları (ANN), insan beyninin çalışma prensibini örnek alarak oluşturulmuş bir veri işleme yöntemidir. ANN’yi diğer veri işleme yöntemlerinden farklı kılan en önemli özelliklerden biri programlama yerine örneklerle öğrenme yöntemini izlemesidir. Bu özellik sayesinde diğer programların sahip olduğu çoğu olumsuzluk ANN’de yoktur.

ANN sınıflandırma, örüntü tanımlama, gruplama, tahminleme ve optimizasyon problemlerinin çözümünde kullanılan birden çok girdi alabilen ve birden çok çıktı üretebilen matematiksel bir yapay zeka yöntemidir. İlk sinirsel model McCulloch ve Pitts tarafından 1943 yılında önerilmiştir [31]. 1957 yılında Frank Rosenblatt ilk perceptron üreterek ilk yapay sinir ağını geliştirmiştir. 1982 yılında James Anderson vd. ANN uygulamalarını robot bilimine uyarlamışlardır. ANN'ler doğrusal olmayan problemlerin çözümü için yaygın kullanılmaktadır.


ANN modeli genel bilgisayar mimarisi olan işlem / bellek soyutlaması yerine insan sinir sisteminin iletim modelini ve insan beyninin paralel hesaplama yeteneğini model alır. Biyolojik sistemlerde temel işlem birimi sinir hücresidir ve nöron olarak isimlendirilir. İnsan sinir sisteminde yaklaşık 100 milyar nöron bulunmaktadır. Sinir hücrelerinin bir kısmı veri toplamak, bir kısmı alınan veriyi iletmek, bir kısmı da ulaşan bu verileri işlemek üzere özelleşmiştir. Dolayısıyla ANN'nin çalışma prensibi ile insan beyninin çalışma prensibi arasında ortak yönler görülmektedir. Şekil 4.3'de bir sinir hücre görüntüsü verilmiştir.



Şekil 4.3. Sinir Hücresi

Genel olarak yapay sinir ağları girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktılardan oluşmaktadır. Şekil 4.4'de bir ANN yapısı gösterilmiştir. ANN'de amaç ağırlık değerlerini optimal hale ulaştırmaktır. Bu sebeple, ağırlık değerleri giriş değerleri ile çarpılarak tahmini bir çıkış değerleri bulunur. Bu tahmini çıkış değerleri toplanarak toplam fonksiyonu elde edilir. Daha sonra toplam fonksiyonundan elde edilen değer bir aktivasyon fonksiyonuna gönderilir. Aktive edilmiş sonuç gerçek çıkış değerinden çıkarılarak tahmini bir hata bulunmuş olur. Eğer hata, önceden belirlenen eşik hata değerinden küçük yada eşitse

ağırlıklar optimal hale getirilmiştir. Eğer hata önceden belirlenen eşik hata değerinden büyük ise hata değeri ağırlıklara etki eder ve ağırlıklar güncellenir. Daha sonra yeni ağırlıklar, girdiler ile çarpılarak aynı işlemler tekrar edilir. ANN’de ağırlıklar optimal hale ulaşana kadar tüm işlem tekrar eder.



Şekil 4.4. ANN Yapısı

Şekil 4.4’de x_i girişleri, y çıkışı, f aktivasyon fonksiyonunu ve w_i ağırlıkları ifade eder. Girişler dış kaynaklardan veya diğer işlemci elemanlardan gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıkları da farklıdır. Giriş değerlerinin her biri uygun ağırlık değerleri ile çarpılmaktadır ($x_i \cdot w_i$). Toplam fonksiyonunda çarpım sonuçları toplanarak çıkış elde edilmektedir. (Σ). Toplam fonksiyonu sonucunda üretilen çıkış değeri aktivasyon fonksiyonuna gönderilir (f). Aktivasyon fonksiyonu sonucunda tahmini sonuç hesaplanır. Tahmini çıkış değeri gerçek çıkış değerinden çıkarılarak hata değeri hesaplanır.

Toplam Fonksiyonun en çok kullanılan formülleri Çizelge 4.1’de gösterilmiştir. Toplam fonksiyonu genel olarak ağırlıklar ile çarpılarak toplanmasını sağlamaktadır.

Çizelge 4.1. ANN Toplam Fonksiyonları

Toplam Fonksiyonu	Formülleri
Toplam	$\Sigma(Xi*Wi)$
Çarpım	$\Pi(Xi*Wi)$
Maksimum	$\text{Max}((Xi*Wi)$
Minimum	$\text{Min}((Xi*Wi)$

Çizelge 4.1’de toplam fonksiyonu için kullanılan formüller gösterilmiştir. Toplam fonksiyonu için önerilen bir seçim yöntemi yoktur. Toplam fonksiyonu daha çok deneme yanılma yöntemi ile seçilir. Toplam Fonksiyonu için genel olarak çarpımların toplamı yöntemi kullanılmaktadır.

Aktivasyon fonksiyonu, ANN içinde girdilere karşı üretilen çıktıları belirler. Aktivasyon fonksiyonunun seçiminde genellikle verilerin değer aralıkları etkili olmaktadır. Bu nedenle aktivasyon fonksiyonunun yanlış seçimi ağıın başarısını düşürür. Yanlış aktivasyon fonksiyonu ile oluşan ağ, sınıflandırmada kullanıldığında sınıflandırma başarısını düşürür. En fazla kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur. Sigmoid fonksiyonu için verilerin normalizasyon ile normalleştirilmesi sağlanır. Doğrusal problemlerin çözümünde doğrusal aktivasyon fonksiyonu kullanılmaktadır. Çizelge 4.2’de ANN’de kullanılan aktivasyon fonksiyonları verilmiştir.

Çizelge 4.2. ANN Aktivasyon Fonksiyonları

Aktivasyon Fonksiyonları	Formülleri
Sigmoid <i>logsig (x)</i>	$f(x) = \frac{1}{1 + e^{-x}}$
Lineer <i>lin (x)</i>	$f(x) = x$
Tanjant Hiperbolik <i>tansig (x)</i>	$f(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$
Doyun Fonksiyonu <i>sat (x)</i>	$f(x) = \begin{cases} +1 & x \geq 1 \\ x & -1 < x < 1 \\ -1 & x \leq -1 \end{cases}$
Keskin Sınırlayıcı <i>signum (x)</i>	$f(x) = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases}$

Aktivasyon fonksiyonu toplam fonksiyonundan çıkan değerleri gerçek değerler ile kıyaslayabilmek için uygun bir forma dönüştürür. Aktivasyon fonksiyon türlerinden en çok kullanılan sigmoid fonksiyonudur.

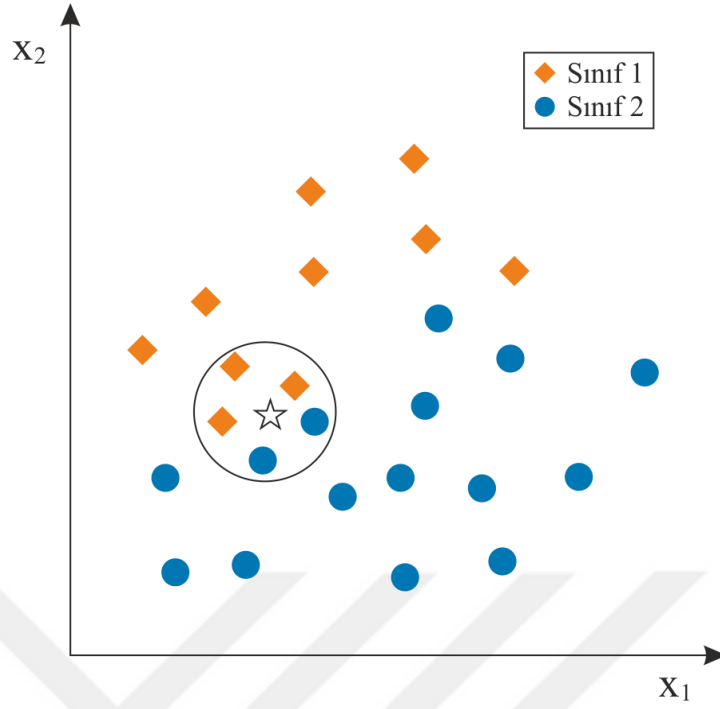
Aktivasyon fonksiyonunun ürettiği tahmini sonuç ve gerçek sonuç değeri karşılaştırılarak bir hata bulunur. Bu hata değerine göre ağırlıklar güncellenir. Hata payı eşik değeri ve eşik değerinin altına düşünceye kadar bu işlem tekrarlanır. Burada ağın maliyetini en iyi belirleyen ölçüt iterasyon sayısıdır. Eğer iterasyon sayısı fazla olursa başarılı sonuçlar elde edilebilir. Ancak ağın eğitime süresi artacaktır. Giriş verileri toplam fonksiyonundan geçtikten sonra tekrar gizli katmandan geçirilir ve ağırlıkların optimal haline ulaşması sağlanır.

4.3 K-En Yakın Komşu (KNN)

K-En Yakın Komşu (KNN) yöntemi mesafeye dayalı olarak sınıflandırma yapan bir algoritmadır. Bu yöntem, hangi sınıfa ait olduğu bilinmeyen örnek veriye sınıf etiketi vermeyi amaçlar [32]. Bunun için eğitim kümesindeki örneklerin bu örnek veriye olan uzaklık ölçütü hesaplanır. Bu örnek veriye en kısa mesafe de olan veriler seçilerek bu verilerin sınıf bilgisi yeni örnek veriye aktarılır. K-en yakın komşu ifadesinde “k” karakteri, en yakın kaç komşuya bakılması gerektiğini ifade eder. Sınıf etiketinin çoğunluk seçimiyle belirlenmesinden dolayı “k” değeri genellikle 3, 5 veya 7 gibi tek sayıda seçilmektedir. KNN algoritmasında komşular arasındaki uzaklık ölçütünü hesaplamak için en popüler yöntem Öklid uzaklık yöntemidir. Öklid uzaklık ölçütünden sonra en çok Manhattan, Minkowski uzaklık ölçütleri kullanılmaktadır. KNN ile iki veri arasındaki mesafeyi hesaplamak için, Denklem (4.10)’da Öklid denklemi, Manhattan denklemi ve Minkowski denklemleri sırası ile d_1 , d_2 ve d_3 olarak gösterilmiştir.

$$\begin{aligned}d_1 &= \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \\d_2 &= \sqrt{\sum_{i=1}^k |x_i - y_i|} \\d_3 &= \sqrt{\sum_{i=1}^k |x_i - y_i|^q}\end{aligned}\tag{4.10}$$

Şekil 4.5’de KNN sınıflandırıcısı için komşuluk değeri beş ($k = 5$) olarak seçilen bir örnek görsel olarak sunulmuştur.



Şekil 4.5. KNN Gösterimi

KNN sınıflandırıcısı kısaca verilen test örneği için en yakın beş komşuyu tespit eder ve test örneği en fazla tekrar eden sınıfa dâhil edilir. Şekil 4.5’de KNN sınıflandırıcısını anlatan bir grafik verilmiştir. Şekil 4.5’de (☆) işareti test örneğini temsil etmektedir, (◆) işareti Sınıf1’i ve (●) işareti Sınıf2’yi temsil etmektedir. Test verisi diğer bütün örnek veriler ile kıyaslanarak en yakın 5 komşusu seçilmiştir.

Seçilen en yakın 5 komşunun 3 tanesi (◆) Sınıf1’e ait kalan 2 tanesi ise (●) Sınıf2’ye aittir. Bu nedenle test örneği (◆) Sınıf1’e dâhil edilir. k sayısının tek sayı olarak seçiminin rastgele olmadığına dikkat edilmelidir. İki sınıflı problemler için k parametresi genelde tek sayı olarak seçilir. Çok sınıflı problemler için k parametresi potansiyel bağları engellemek amacıyla sınıf sayısına bölünemeyen bir sayı seçilir.

5. ÖNERİLEN ERKEN DUMAN ALGILAMA SİSTEMİ

5.1 Veri Seti

Erken Duman Algılama Sistemine ait test işlemlerinin gerçekleştirilmesi için duman ve duman olmayan görüntüler gerekmektedir. Sistemin diğer sistemlerle kıyaslanabilir olması ve sistem başarısının ölçülebilmesi için ortak bir veri setine ihtiyaç duyulmaktadır. Önerilen bu sistem, Feiniu Yuan [2] tarafından oluşturulan ve paylaşımına açık olarak sunulan veri seti üzerinde test edilmiştir. Bu veri setine ait gerekli bilgiler Çizelge 5.1’de verilmiştir.

Çizelge 5.1. Veri Seti

	Oran	Duman Görüntüleri	Duman Olmayan Görüntüler	Toplam Görüntü Sayısı
Eğitim	%10	500	1.700	2.200
Test	%90	4.500	15.300	19.800
TOPLAM	%100	5.000	17.000	22.000


Bu veri setinde Çizelge 5.1’de görüldüğü gibi 5.000 adet duman görüntüsü 17.000 adet duman olmayan görüntü olmak üzere toplam 22.000 adet görüntü bulunmaktadır.

Önerilen bu sistem de, duman ve duman olmayan görüntülerin 2.200 adeti yani toplam görüntü sayısının %10’una karşılık gelen görüntüler eğitim işlemi için kullanılmıştır. Duman ve duman olmayan görüntülerden alınan 19.800 görüntü yani toplam görüntülerin %90’ına karşılık gelen görüntüler ise test verisi olarak ayrılmıştır.

Veri setinde içerisinden seçilen ve farklı görünümde bulunan duman görüntüleri için 16 adet örnek Şekil 5.1’de verilmiştir. Şekil 5.2’de ise veri seti içinde bulunan ancak içerisinden duman içermeyen farklı 16 adet örnek verilmiştir.



Şekil 5.1. Veri Seti Örnek Duman Görüntüleri

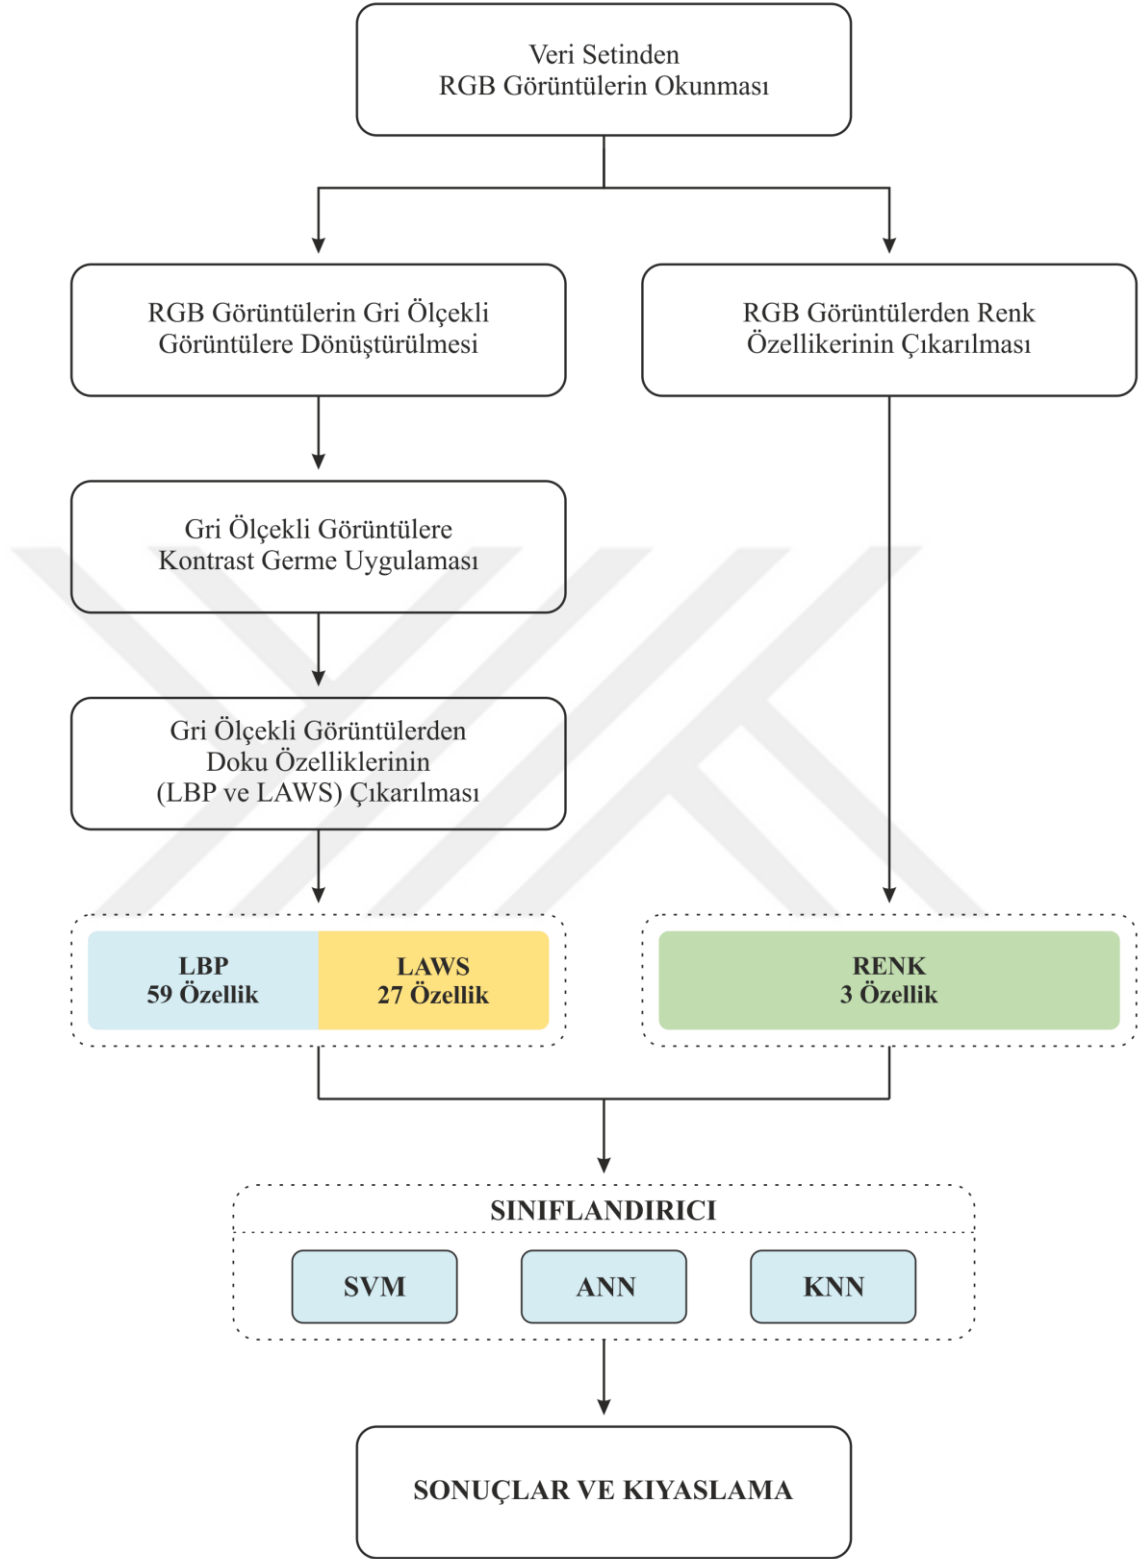


Şekil 5.2. Veri Seti Örnek Duman Olmayan Görüntüler

5.2 Önerilen Yöntem

Bu tez çalışmasında, Fenni Yuan vd. [2] tarafından RGB renk uzayında oluşturulan veri seti kullanılmıştır. Bu veri seti içindeki görüntüler üzerinde duman tespit işlemi yapılmıştır. Veri setindeki RGB görüntüler duman ve duman olmayan görüntülerden oluşmaktadır. Önerilen sistemde, öncelikle RGB görüntüler gri ölçekli görüntüye dönüştürülmüştür. Gri ölçekli bu görüntüler üzerine görüntü ön işleme uygulanmış ve görüntü kalitesi artırılmıştır. Daha sonra, bu görüntüler üzerinde doku özneliklerinin çıkarılması sağlanmıştır. Doku öznelik çıkarma aşamasında LBP ve LAWS algoritmaları kullanılmıştır. LBP algoritması ile 59, LAWS algoritması ile 27 öznelik çıkarılmış olup toplam 86 öznelik elde edilmiştir.

Veri setindeki orijinal RGB görüntüler tekrar alınarak bu görüntülere ait renk özellikleri çıkarılmıştır. Renk özellik çıkarma işleminde RGB renk uzayına ait R, G ve B kanallarında alınan değerler kullanılmıştır. Bu görüntüler üzerinde toplam 3 renk özelliği elde edilmiştir. İşlemler sonucunda duman ve duman olmayan her görüntü için elde edilen toplam 89 özellik sınıflandırıcıya gönderilmiştir. Sınıflandırma aşamasında SVM, ANN ve KNN sınıflandırıcıları kullanılmış olup sistemin başarısı test edilmiştir. Önerilen yönteme ait akış şeması Şekil 5.3'de verilmiştir.



Şekil 5.3. Akış Şeması


5.2.1 RGB Renk Uzayından Gri Ölçekli Renk Uzayına Dönüşüm

Veri setinde ki duman ve duman olmayan görüntüler üzerinde doku analizi işlemi için LBP ve LAWS yöntemleri kullanılmaktadır. Her iki yöntemde gri ölçekli görüntüler üzerinde çalışan yöntemlerdir. Ancak kullanılan veri seti içindeki görüntüler RGB renk uzayındadır. Bu görüntüler üzerinde doku analizi yapabilmek için görüntülerin RGB renk uzayından gri ölçekli görüntülere dönüştürülmesi gerekmektedir.

RGB renk uzayından gri ölçekli renk uzayına dönüşüm işlemi için genel olarak kullanılan matematiksel ifade Denklem (5.1)'de verilmiştir [33].

$$R*0.299 + G*0.587 + B*0.114 \quad (5.1)$$

Bu tez çalışmasında, görüntüyü RGB renk uzayından gri ölçekli hale dönüştürürken mevcut yöntemlerin dışında yeni bir yaklaşım sunulmaktadır. Yapılan çalışma ve deneylerde, RGB renk uzayındaki duman görüntülerine ait renk piksel değerlerinin R, G ve B kanallarından gelen renk değerleri birbirine yakın değerler olduğu gözlemlenmiştir. Şekil 5.4'de farklı duman görüntülerinden alınan görüntülere ait duman renginin RGB renk uzayındaki renk değerleri gösterilmiştir.



Şekil 5.4. Orjinal Görüntülerde RGB Renk Değerleri

Şekil 5.4’de gösterildiği gibi duman renginin RGB renk uzayında R, G, B renk değerleri birbirine çok yakındır. Bu nedenle RGB renk uzayından gri ölçekli renk uzayına dönüşümde Denklem (5.1) de verilen matematiksel ifade yerine R, G, B renk kanallarının eşit bir şekilde gri ölçekli değerine katkı yapabilmesi için Denklem (5.2)’de verilen matematiksel ifade kullanılmıştır [33].


$$R*0,333 + G*0,333 + B*0,333 \quad (5.2)$$

Denklem (5.2)’de ifade edilen R,G,B, renk kanallarının çarpanları eşittir. Bu eşit çarpan değeri renk kanallarını gri ölçekli renk uzayına dönüştürürken her bir renk kanalı için eşit katkı verecektir. Duman görüntüleri üzerine uygulanan bu eşit çarpan sayesinde, RGB renk uzayından gri ölçekli renk uzayına geçildiğinde duman renginin daha belirgin olduğu gözlemlenmiştir. RGB renk uzayından gri ölçekli renk uzayına

dönüşümde Denklem (5.1)'de verilen genel ifade yerine Denklem (5.2)'de verilen ifade kullanıldığında sistemin başarısı artmıştır.

5.2.2 Kontrast Germe

Veri setinden bulunan görüntüler gri ölçekli görüntülere çevrildikten sonra bu görüntüler üzerinde görüntü ön işleme uygulanmıştır. Görüntü ön işleme yöntemlerinden kontrast germe işlemi gri ölçekli görüntüler üzerinde uygulanmıştır. Eğer bir görüntüde kontrast belirli bir aralıkta sıkışık ise aranan bilgi tekdüze konsatrasyona sahip alan içerisinde kaybolabilir. Bu işlemde amaç, görüntünün kontrastını düzenleyerek görüntü içindeki tüm detayların fark edilebilirliğinin artırılmasını sağlamaktır. Şekil 5.5'de kontrast germe işlemi uygulanmış görüntüler verilmiştir.



Şekil 5.5. Ön İşleme a) Orjinal Görüntü b) Ön İşleme Yapılmış Görüntüler

Şekil 5.5.a'da gri ölçekli görüntüye dönüştürülmüş imgeler, Şekil 5.5.b'de ise (a) görüntüleri üzerine uygulana kontrast germe işlemi sonunda oluşan görüntüler verilmiştir. Kontrast germe işlemi sonucunda dumanın yoğun olduğu bölgeler daha çok belirginleşmiş ve daha parlak gözükmeye beyaz renk aralığına yaklaşmıştır. Dumanın az veya hiç olmadığı yerler ise daha karanlık gözükmüş ve siyah renk aralığına yaklaşmıştır.

5.2.3 Özellik Çıkarımı

Görüntüdeki bir nesnenin özelliği, onu diğer nesnelere ayırabilen ve karakteristiği hakkında bilgi veren unsur ya da unsurlar bütünüdür. Özellik çıkarımı ile görüntü fazla bilgilerden arındırılır ve karakteristiğini ifade eden özellikler ile temsil edilmesi sağlanır. Özellik çıkarma işleminden sonra görüntüye ait tüm özellikler içerisinden görüntünün karakteristiğini temsil eden özelliklerin seçilmesi amaçlanır. Aslında bu işlem bir tür boyut azaltma işlemidir. Görüntüyü yüksek ve detaylı bilgilerden arındırarak daha karakterize özelliklerle çalışma sağlanmaktadır. Böylelikle, çalışma yapısı daha anlaşılabilir ve daha verimli sonuçlar doğurabilmektedir.

Bu tez çalışmasında, veri setinde bulunan duman ve duman olmayan görüntüler üzerinde doku ve renk özelliklerinin çıkarılması amaçlanmıştır. Doku özellikleri, görüntüye has geniş bir yüzeysel çeşitliliğe sahip olan, anlamlı küçük parçaların tekrar etmesi ile oluşan görsel bir özelliktir. Doku özellik çıkarım işleminde LBP ve LAWS yöntemleri kullanılmış olup sırası ile bu işlemlerden 59 ve 27 adet özellik çıkarılmıştır. Toplamda duman ve duman olmayan görüntüye ait doku özellik çıkarım işleminden 86 adet özellik elde edilmiştir. Görüntünün en temel özelliklerinden biri olan renk özelliği, nesnelere doğal yapısı hakkında bilgi sunan ve görüntü özelliklerinin değerlendirilmesinde en yaygın kullanılan özelliktir. Bu çalışmada, renk özellik çıkarım işleminde RGB renk uzayı kullanılmış ve toplamda görüntüye ait 3 renk özelliği çıkarılmıştır. Şekil 5.6'da toplam 89 özelliğin elde edildiği yöntemler görsel olarak sunulmuştur.



Şekil 5.6. Özellik Sayıları

Şekil 5.7’de veri seti içinde bulunan 4 farklı duman ve 4 farklı duman içermeyen görüntü olmak üzere toplam sekiz adet farklı görüntü örnekleri verilmiştir.




Şekil 5.7. Veri Setinden Örnek Görüntüler

5.2.3.1 Doku Özellik Çıkarımı

Doku özellik çıkarım işlemi, önerilen sistemde kullanılan ilk özellik çıkarım yöntemidir. Doku özellikleri nesnelere hakkında anlamlı bilgileri içerir. Bu nedenle, nesnelere ayırt edilmesi açısından göz önünde bulundurulması gereken özelliklerdir. Bu çalışmada, doku analizinde birçok açıdan güçlü ve popüler olan LBP ve LAWS yöntemleri kullanılmıştır.

LBP Yöntemi ile Özellik Çıkarımı: LBP yöntemi kullanılarak görüntünün histogram değerleri bulunmuştur. Histogram dijital ortama aktarılan bir görüntünün her renk değerinden kaç adet olduğunu gösteren bir grafikdir. Bu grafik sayesinde, resmin parlaklığı ve renk yoğunluğu hakkında çeşitli bilgilere ulaşılabilir.

LBP yönteminin görüntüler üzerinde uygulanmasıyla histogram değerleri bulunur. Bulunan histogram değerlerine ait matematiksel ifade üçüncü bölümde sunulan Denklem (3.3)'de bahsedilmiştir. LBP yöntemi ile görüntüye ait histogram değerlerinin elde edilmesinde düzgün dağılım ve düzgün olmayan dağılım değerler olduğu görülmüştür. Düzgün dağılım değerler toplam 58 adet olup bu düzgün dağılım değerleri Şekil 5.8'de gösterilmiştir. Düzgün olmayan dağılım değer sayısı ise 198'dir. Bu düzgün olmayan dağılım değerleri toplanarak bir özellik olarak kabul edilmiştir. Bu nedenle LBP yönteminden toplam 59 (58+1) özellik çıkarılmıştır.



Şekil 5.8. LBP Düzgün Örüntüleri

LAWS Yöntemi ile Özellik Çıkarımı: Doku analiz işleminde LAWS yöntemi kullanılarak görüntüden toplam 27 özellik çıkarılmıştır. Bir görüntü üzerinde dokuz (9) maske kullanılmış ve görüntüye ait 9 LAWS enerji sonucu elde edilmiştir. Yani, 100x100 boyutunda gri ölçekli bir görüntünün olduğunu varsayarsak bu görüntünün 100x100 boyutunda 9 adet LAWS maskelenmiş görüntüsü oluşacaktır.

LAWS yöntemi sonucu oluşan 9 adet maskelenmiş görüntüden özellikler çıkarılmıştır. Her maskelenmiş görüntü için 3 özellik çıkarılmış olup toplamda 27 özellik elde edilmiştir. Her maskelenmiş görüntünün 3 özelliği için maskelenmiş görüntünün ortalama, varyans ve entropi değerleri bulunmuştur. Çizelge 5.2’de LAWS’dan elde edilen sonuçlara ait sayısal değerler çizelge halinde sunulmuştur.

Çizelge 5.2. Laws Özellikleri

	Görüntüler							
	1	2	3	4	5	6	7	8
1	93,35	80,24	74,50	88,71	86,91	96,28	118,60	99,57
2	28,30	27,94	37,50	31,79	60,01	79,01	15,54	34,20
3	7,52	8,23	11,11	9,39	16,62	26,56	1,94	5,69
4	2,21	2,49	3,48	2,88	5,90	9,50	0,98	1,97
5	8,32	8,29	8,63	8,69	11,09	17,93	8,08	8,26
6	50,56	51,13	60,86	55,73	67,15	78,93	16,62	49,96
7	29,81	31,75	40,92	34,14	49,89	68,91	4,57	17,41
8	6,19	6,46	8,16	7,45	15,63	30,24	3,89	6,81
9	3,10	3,25	3,70	3,60	6,64	11,95	2,59	3,23
10	2770,32	3416,33	3602,97	3055,72	3244,68	2843,71	650,86	2228,02
11	1095,66	1166,08	1640,56	1425,64	2678,53	3135,41	629,26	1701,24
12	101,69	177,95	241,79	196,90	388,14	719,92	14,00	87,24
13	15,46	31,34	70,76	44,59	138,18	241,98	46,79	52,49
14	152,23	167,31	191,89	191,08	313,81	834,44	168,40	175,35
15	2412,46	2431,87	2946,49	2750,06	3040,33	3213,86	1015,67	2545,60
16	2381,49	2768,77	4153,10	3313,57	5515,06	8223,65	92,42	1154,38
17	115,75	151,54	161,83	166,66	377,24	1041,23	35,42	155,26
18	19,16	30,35	37,12	39,48	91,65	233,50	21,27	31,53
19	0,70	0,87	0,93	0,78	0,83	0,74	0,05	0,53
20	0,82	0,81	0,82	0,82	0,82	0,81	0,83	0,81

21	0,78	0,88	0,86	0,88	0,82	0,78	0,89	0,86
22	1,00	1,00	1,00	1,00	1,00	1,00	0,97	0,99
23	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
24	0,86	0,84	0,87	0,86	0,84	0,83	0,88	0,77
25	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
26	0,84	0,83	0,84	0,84	0,82	0,82	0,86	0,84
27	0,90	0,91	0,90	0,91	0,89	0,87	0,92	0,91

Çizelge 5.2, yirmi yedi satır ve sekiz sütundan (27x8) oluşmaktadır. Sütun numaraları Şekil 5.7’de numaralandırılmış sekiz görüntüyü temsil etmektedir. Satırlar ise bu sekiz görüntü üzerine uygulanan LAWS yöntemine ait özellikleri temsil etmektedir. Birinci ve dokuzuncu satır (1-9) arasındaki değerler, maskelenmiş görüntülerin ortalamalarını, onuncu ve on sekizinci (10-18) satır arasındaki değerler ise görüntüye ait varyans değerlerini göstermektedir. Son yedi satırda ise (19-27) maskelenmiş görüntüye ait entropi bilgisini göstermektedir.

5.2.3.2 Renk Özellik Çıkarımı

Renk özellik çıkarım işlemi, önerilen sistemde kullanılan ikinci özellik çıkarım yöntemidir. Renk, görüntü algılama işlemlerinde en yaygın kullanılan görsel bir özelliktir. Bu çalışmada kullanılan veri setinde bulunan duman ve duman olmayan görüntüler RGB renk uzayındadır. RGB renk uzayındaki bu görüntüler üzerinden renk kanallarına göre analiz işlemi yapılmıştır. Amaç, dumanı tespit etmek olduğu için dumanı görüntüde bulan diğer nesnelere ayırabilen matematiksel bir ifade kullanılmıştır. Bu matematiksel ifade Denklem (5.3)’de gösterilmiş olup bu ifade sayesinde görüntüye ait 3 renk özelliği çıkarılmıştır.

$$|R - G|, |R - B|, |G - B| \quad (5.3)$$

Denklem (5.3) ile elde edilen 3 adet renk özelliği Şekil 5.7’de verilen sekiz görüntü üzerinde uygulanmış ve bu uygulamanın sayısal değerleri Çizelge 5.3’de gösterilmiştir.

Çizelge 5.3. Renk Özellikleri

Özellikler	Görüntüler							
	1	2	3	4	5	6	7	8
R – G	19,20	0,06	0,39	2,73	5,15	5,81	25,19	6,44
R – B	28,89	15,75	3,06	4,22	11,62	7,65	65,44	44,77
G – B	9,70	15,81	3,45	6,95	16,78	1,84	40,25	38,32

Çizelge 5.3 sekiz sütun ve üç satırdan (3x8) oluşmaktadır. Sütun numaraları Şekil 5.7’de numaralandırılmış sekiz görüntüyü temsil etmektedir. Birinci satır kırmızı renk kanalından yeşil renk kanalının çıkarılmasını, ikinci satır kırmızı renk kanalından mavi renk kanalının çıkarılmasını ve son satır ise yeşil renk kanalından mavi renk kanalının çıkarılması ile elde edilen özellikleri temsil etmektedir.

5.2.4 Sınıflandırma

Sınıflandırma, görüntüden elde edilen farklı özellikleri kullanarak sistemin erişim etkinliğini iyileştirmeyi amaçlar. Görüntü analiz sistemlerinin son aşamasında görüntülerden elde edilen özelliklerin sınıflandırılması sağlanır. Aslında, hangi sınıfta olduğu daha önceden bilinen bir miktar veri bir eğitim sürecinden geçirilir. Daha sonra, bilinmeyen örüntünün hangi sınıfta olacağını belirlenmesi için bir karar mekanizması oluşturulur. Bu tez çalışmasında duman ve duman olmayan görüntülerden elde edilen 89 özellik sınıflandırılmıştır. Sınıflandırma aşamasında, SVM, ANN ve KNN sınıflandırıcıları kullanılmış olup sistemin başarısı test edilmiştir. Sınıflandırma aşamasında kullanılan tüm yöntemlerin ortak amacı, örüntülerin özellik uzaylarına göre en yakın sınıflara en az hata ile dâhil edilmesidir.

Veri setimize SVM uygularken çekirdek fonksiyonu olarak radyan tabanlı fonksiyonu (Radial Basis Function) kullanılmıştır.

Veri setimize ANN uygularken, gizli katman sayısı özellik sayısının yarısı kadar alınmıştır. ANN toplam fonksiyonu için 4. bölüm altında Çizelge 4.1’de gösterilen çarpımların toplamı (Toplam) fonksiyonu kullanılmıştır. Aktivasyon fonksiyonu için ise 4. bölüm altında Çizelge 4.2’de gösterilen sigmoid fonksiyonu kullanılmıştır.

Veri setimize KNN uygularken k komşuluk değeri 5 olarak alınmıştır. KNN’de değerler arasındaki uzaklık değerini hesaplamak için 4. bölüm başlığı altında bulunan Denklem (4.10)’da verilen Öklid fonksiyonu kullanılmıştır.

Belirlenen değerler ile SVM, ANN ve KNN sınıflandırıcılarına gönderilen özelliklerin sınıflandırmalarına ait sayısal sonuçlar ve çalışma süreleri Çizelge 5.4’de gösterilmiştir. Önerilen sistemin, Matlab ortamında Intel i7 4500u işlemciye sahip bir makinede koşturulmasıyla sonuçlar elde edilmiştir.

Çizelge 5.4. Sınıflandırıcıların Başarı ve Zaman Değerleri

	SVM		ANN		KNN	
	%	t (sn.)	%	t (sn.)	%	t (sn.)
GLCM (8 Özellik)	90,20	0,30	89,60	0,52	89,10	0,11
GLRLM (7 Özellik)	91,55	0,25	92,23	0,48	90,29	0,10
LAWS (27 Özellik)	94,03	0,13	93,77	0,65	92,42	0,35
LBP (59 Özellik)	94,95	0,18	94,62	0,84	93,14	0,71
LTP (118 Özellik)	94,92	0,33	94,42	1,16	93,67	1,29
LTP (59 Özellik)	94,42	0,17	94,23	0,67	93,21	0,62
LBP + LAWS + RENK (89 Özellik)	98,12	0,27	97,98	1,12	95,95	0,92

Çizelge 5.4, yedi satır ve altı sütundan oluşmaktadır (7x6). Sütun değerleri sınıflandırıcıya ait başarı ve çalışma sürelerini, satır değerleri ise kullanılan özellik çıkarım yöntemlerini vermektedir. Çizelge 5.4 incelendiğinde, en iyi sınıflandırma başarısını LBP, LAWS ve RENK özellik çıkarım yöntemleri ile elde edilen 89 özellik ile %98,12 oranında SVM sınıflandırıcısı vermiştir. SVM sınıflandırıcı bu hibrit yaklaşım için hem en hızlı hem de en yüksek başarıya sonuca ulaşmıştır.

Çizelge 5.4’den anlaşılacağı gibi özellik çıkarım aşamasında GLCM, GLRLM ve LTP yöntemleri de denenmiştir. Ancak bu yöntemlerin sonuca ulaşmada başarı

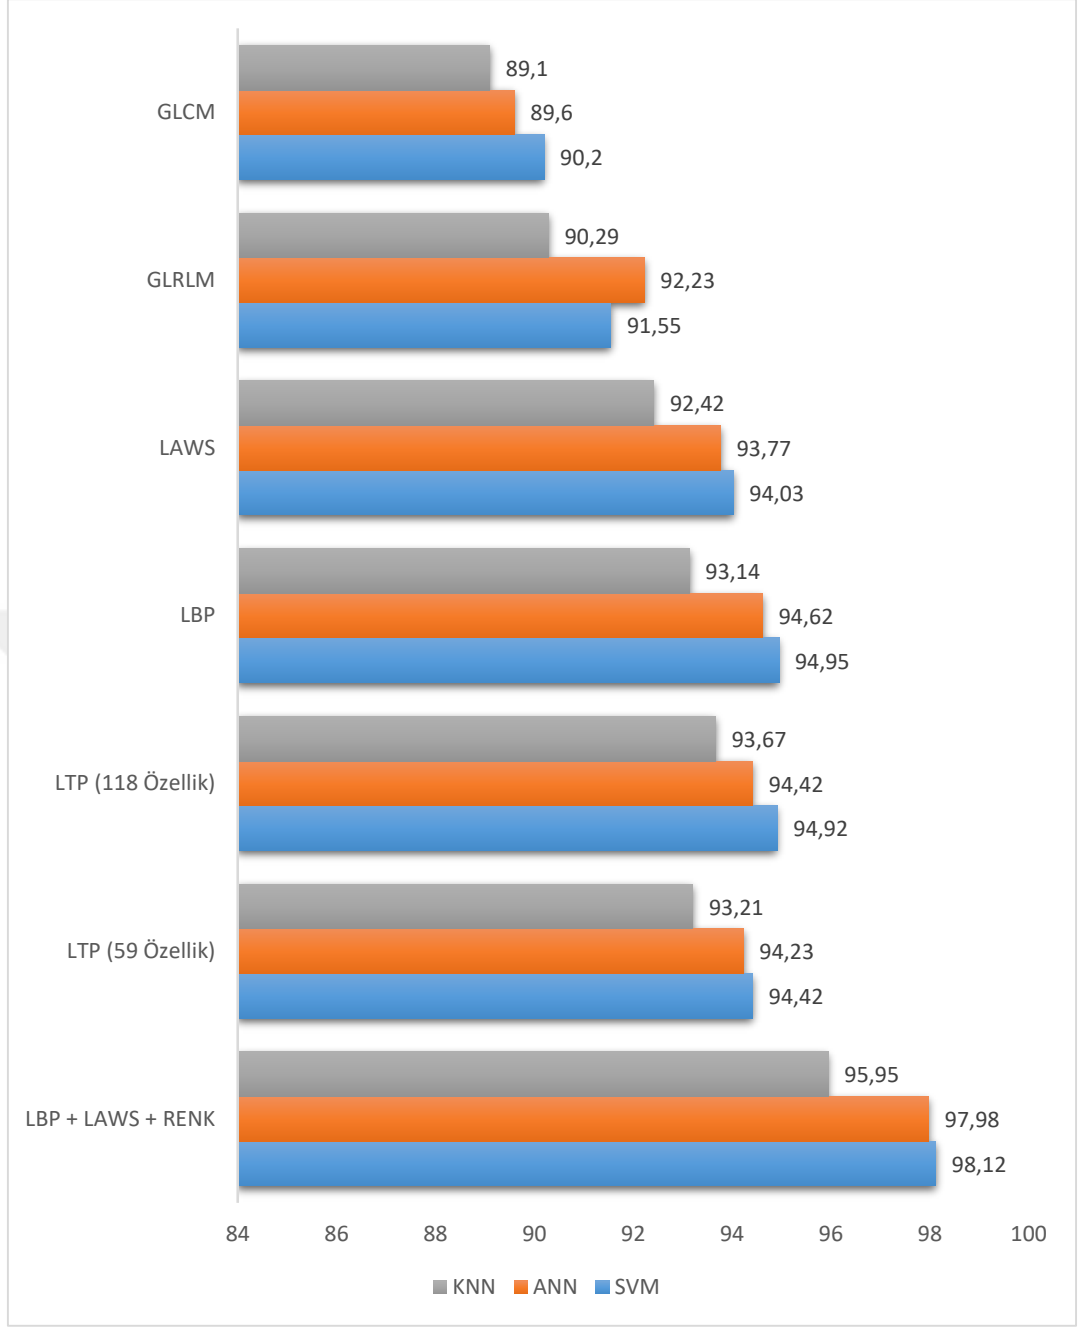
oranları az olduđu için önerilen sistemde tercih edilmemiştir. Çizelge 5.4’de en düşük başarı oranı GLCM yöntemi kullanılarak elde edilen verilerin KNN ile sınıflandırılmasından elde edilmiş olup başarı yüzdesi %89,10 olarak kaydedilmiştir. Çalışma süresi olarak incelendiğinde en kötü sonucu LTP yönteminde KNN sınıflandırıcında alınmış olup çalışma hızı 1,29 saniye olarak kaydedilirken, en iyi çalışma süresini GLRLM yönteminde KNN sınıflandırıcında olup çalışma hızı 0,10 saniye olarak kaydedilmiştir.



6. SONUÇLAR VE DEĞERLENDİRME

Önerilen yöntemde 5.000 adet duman ve 17.000 adet duman olmayan görüntü alınarak 22.000 adet görüntü üzerinden doku ve renk özellikleri çıkarılmıştır. Renk özellik yönteminde RGB renk uzayı kullanılmış ve doku özellik yönteminde LBP ve LAWS yöntemleri kullanılarak toplam 89 özellik çıkarılmıştır. Sonuçta, 22000x89 boyutunda bir veri kümesi elde edilmiştir. Bu veri kümesi, SVM, ANN ve KNN sınıflandırıcıları kullanılarak sınıflandırılmış ve sistem başarısı test edilmiştir. Test sonuçları beşinci bölümde verilen Çizelge 5.4'te gösterilmiştir.

Önerilen yöntemin başarısının GLCM, GLRLM ve LTP doku özellik çıkarım yöntemleri ile kıyaslanması yapılmıştır. Ancak bu yöntemlerin, önerilen sistemden daha düşük başarılar verdiği tespit edilmiş ve Şekil 6.1'de başarı kıyaslamaları grafiksel olarak gösterilmiştir.



Şekil 6.1. Özellik Çıkarım Yöntemlerinin Kıyaslanması

Şekil 6.1’de görüldüğü gibi bizim önerdiğimiz sistem, literatürde bulunan diğer sistemlerden daha iyi sonuç vermiştir.

7. KAYNAKLAR

- [1] Anonim. (2017). <https://www.ogm.gov.tr/ekutuphane/FaaliyetRaporu> (on-line access on 18 November 2018).
- [2] S. Wu, F. Yuan, Y. Yang, Z. Fang, and Y. Fang, *Real-time image smoke detection using staircase searching-based dual threshold AdaBoost and dynamic analysis*, **IET Image Process.**, 9:10 (2015) 849–856.
- [3] P. Piccinini, S. Calderara, and R. Cucchiara, *Reliable smoke detection system in the domains of image energy and color*, **Proc. - Int. Conf. Image Process. ICIP**, (2008) 1376–1379.
- [4] B. Ko, J. Park, and J. Y. Nam, *Spatiotemporal bag-of-features for early wildfire smoke detection*, **Image Vis. Comput.**, 31:10 (2013) 786–795.
- [5] A. Benazza-Benyahia, N. Hamouda, F. Tlili, and S. Ouerghi, *Early smoke detection in forest areas from DCT based compressed video*, **Eur. Signal Process. Conf.**, (2012) 2752–2756.
- [6] W. Ye, J. Zhao, S. Wang, Y. Wang, D. Zhang, and Z. Yuan, *Dynamic texture based smoke detection using Surfacelet transform and HMT model*, **Fire Safety Journal**, 73:91 (2015) 101.
- [7] H. Tian, W. Li, L. Wang, and P. Ogunbona, *Smoke detection in video: An image separation approach*, **Int. J. Comput. Vis.**, 106:2 (2014) 192–209.
- [8] A. Rafiee, R. Dianat, M. Jamshidi, R. Tavakoli, and S. Abbaspour, *Fire and smoke detection using wavelet analysis and disorder characteristics*, **ICCRD 2011 - 2011 3rd Int. Conf. Comput. Res. Dev.**, 3 (2011) 262–265.
- [9] J. Gubbi, S. Marusic, and M. Palaniswami, *Smoke detection in video using wavelets and support vector machines*, **Fire Safety Journal**, 44:8 (2009) 1110–1115.
- [10] F. Yuan, J. Shi, X. Xia, Y. Fang, Z. Fang, and T. Mei, *High-order local ternary patterns with locality preserving projection for smoke detection and image classification*, **Information Sciences**, 372 (2016) 225–240.
- [11] Z. Zhou, Y. Shi, Z. Gao, and S. Li, *Wildfire smoke detection based on local extremal region segmentation and surveillance*, **Fire Safety Journal**, 85 (2016) 50–58.
- [12] S. Luo, C. Yan, K. Wu, and J. Zheng, *Smoke detection based on condensed image*, **Fire Safety Journal**, 75 (2015) 23–35.

- [13] O. Ghorı, A. Stadler, S. Wilk, and W. Effelsberg, *Video Based Ambient Smoke Detection By Detecting Directional Contrast Decrease*, **International Scholarly and Scientific Research & Innovation**, 10:9 (2016) 1646-1651.
- [14] J. Antony, *Real Time Fire and Smoke Detection using Multi- Expert System for Video-Surveillance Applications*, **International Journal for Innovative Research in Science & Technology**, 3:04 (2016) 203–212.
- [15] J. P. Dukuzumuremyi, B. Zou, and D. Hanyurwimfura, *A Novel Algorithm for Fire/Smoke Detection based on Computer Vision*, **International Journal of Hybrid Information Technology**, 7:3 (2014) 143–154.
- [16] H. D. T. Çelik, H. Özkaramanl, *Fire and smoke detection without sensors: image processing based approach*, **15th European Signal Processing Conference**, 3:7 (2007) 1794–1798.
- [17] B. U. Töreyn, Y. Dedeođlu, and A. E. Çetin, *Contour Based Smoke Detection in Video Using Wavelets*, **14th European Signal Processing Conference**, (2006)
- [18] J. Park, B. Ko, J. Y. Nam, and S. Kwak, *Wildfire smoke detection using spatiotemporal bag-of-features of smoke*, **Proc. IEEE Work. Appl. Comput. Vis.**, (2013) 200–205.
- [19] C. Yu, Z. Mei, and X. Zhang, *A real-time video fire flame and smoke detection algorithm*, **Procedia Eng.**, 62 (2013) 891–898.
- [20] B. U. Töreyn, Y. Dedeoglu and A. E. Çetin, *Wavelet Based Real-time Smoke Detection in Video*, **Proc. Eur. Signal Process. Conf.**, (2005) 4.
- [21] B. Toptaş, *Yangın/Alev Renk Özellikleri Kullanılarak Orman Yangınlarının Tespiti*, Yüksek Lisans Tezi, İnönü Üniversitesi Türkiye, 2017.
- [22] Q. X. Zhang, G. H. Lin, Y. M. Zhang, G. Xu, and J. J. Wang, *Wildland Forest Fire Smoke Detection Based on Faster R-CNN using Synthetic Smoke Images*, **Procedia Eng.**, 211 (2018) 441–446.
- [23] T. Ojala, M. Pietikäinen, and D. Harwood, *A comparative study of texture measures with classification based on featured distributions*, **Pattern Recognition.**, 29:1 (1996) 51–59.
- [24] F. Yuan, *Rotation and scale invariant local binary pattern based on high order directional derivatives for texture classification*, **Digit. Signal Process.**, 26 (2014) 142–152.

- [25] A. Suruliandi and K. Ramar, *Local texture patterns -A univariate texture model for classification of images*, **Proc. 2008 16th Int. Conf. Adv. Comput. Commun.**, (2008) 32–39.
- [26] R. Shenbagavalli and K. Ramar *Classification of Soil Textures Based on Laws Features Extracted from Preprocessing Images on Sequential and Random Windows*, **Bonfring Int. J. Adv. Image Process.**, 1:1 (2011) 15–18.
- [27] R. M. Haralick, K. Shanmugam, and I. Dinstein, *Textural Features for Images Classification*, **Transaction on Systems**, 3:6 (1973) 610–621.
- [28] C. Cortes and V. Vapnik, *Support Vector Networks*, **Machine Learning**, 20:3 (1995) 273-297.
- [29] S. R. Gunn, *Support Vector Machines for Classification and Regression*, **Image Speech Intell. Syst. Tech. Rep.**, 14 (1998) 230–67.
- [30] S. Haykin, *Neural Networks and Learning Machines*. 2008.
- [31] A. Abraham, “Artificial Neural Networks,” **Faceb. AI Res.**, 2015.
- [32] S. B. Imandoust and M. Bolandraftar, *Application of K-Nearest Neighbor (KNN) Approach for Predicting Economic Events: Theoretical Background*, **Int. J. Eng. Res. Appl.**, 3:5 (2013) 605–610.
- [33] A. Güneş, H. Kalkan, and E. Durmuş, “Optimizing the color-to-grayscale conversion for image classification,” **Signal, Image Video Process.**, 10:5 (2016) 853–860.

ÖZGEÇMİŞ

Adı Soyadı: Murat TOPTAŞ

Doğum Yeri ve Tarihi: Malatya - 1991

Adres: Mehmetçik Mahallesi 7003. Sokak No:1/C Karaköprü / Şanlıurfa

E-Posta: murattoptas@harran.edu.tr

Lisans: İnönü Üniversitesi Bilgisayar Mühendisliği Bölümü (2010-2014)

TEZ AŞAMASINDA ÇIKARILAN YAYINLAR;

M.Toptaş, D.Hanbay, “Videoda Doku ve Renk Analizi Kullanılarak Duman Tespiti”, *International Artificial Intelligence And Data Processing Symposium (IDAP)*, 2017.

B.Toptaş, **M.Toptaş**, A.Ari, D.Hanbay, “Alev Görüntülerinde Genetik Algoritma ile Özellik Seçimi”, *International Conference on Multidisciplinary, Science, Engineering and Technology (IMESET)*, 2017