

T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YANGIN/ALEV RENK ÖZELLİKLERİ KULLANILARAK ORMAN
YANGINLARININ TESPİTİ

Buket TOPTAŞ

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ DONANIM ANABİLİM DALI

ARALIK 2017

MALATYA

Tezin Bařlıđı: Yangın/Alev Renk zellikleri Kullanılarak Orman Yangınlarının
Tespiti

Tezi Hazırlayan: Buket TOPTAŐ

Sınav Tarihi: 15.12.2017

Yukarıda adı geen tez jürimizce deđerlendirilerek Bilgisayar Mühendisliđi Ana Bilim
Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Sınav Jüri Üyeleri

Tez Danıřmanı: Do. Dr. Davut HANBAY

İnönü Üniversitesi

.....

Do. Dr. M. Fatih TALU

İnönü Üniversitesi

.....

Prof. Dr. Abdulkadir ŐENGÜR

Fırat Üniversitesi

.....

Prof. Dr. Halil İbrahim ADIGÜZEL

Enstitü Müdürü

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduğum “Yangın/Alev Renk Özellikleri Kullanılarak Orman Yangınlarının Tespiti” 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 oluştuğunu belirtir, bunu onurumla doğrularım.

Buket TOPTAŞ

ÖZET

Yüksek Lisans Tezi

YANGIN/ALEV RENK ÖZELLİKLERİ KULLANILARAK ORMAN YANGINLARININ TESPİTİ

Buket TOPTAŞ

İnönü Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Donanım Ana Bilim Dalı

46 + ix sayfa

2017

Danışman: Doç. Dr. Davut HANBAY

Orman yangınları, atmosferi olumsuz yönde etkileyen, birçok canlı türünün yaşam alanını yok eden, bitki ve hayvan türlerinin yok olmasına sebep olan bir afettir. Orman yangınları ile mücadele sürecinde, yangının erken tespit edilmesi ve ihbar sistemlerine ulaştırılması önemli bir konudur. Teknolojinin gelişmesine bağlı olarak günümüzde görüntü işleme teknikleri ile yangın/alev tespiti yapılmaktadır. Yangın/Alev tespitinde geliştirilen yöntemler de genellikle alevin statik ya da dinamik özellikleri kullanılmıştır.

Bu çalışma da, yangın görüntülerinin renk özellikleri kullanılmış ve yangın görüntüleri yeni bir renk uzayına taşınarak alevin tespit edilmesi sağlanmıştır. Elde edilen yeni renk uzayı, Yapay Arı Kolonisi (YAK) algoritması kullanılarak geliştirilmiştir. Yeni renk uzayına dönüştürülen görüntüler üzerinde Otsu eşik yöntemi kullanılmış ve ikili görüntülere dönüştürülen görüntülerden alev tespiti yapılmıştır. Alev tespit işlemi bittikten sonra, elde edilen ikili görüntüler veri seti içerisinde bulunan gerçek ikili görüntüler ile benzerlik ölçütüne tabi tutulmuş ve önerilen yöntemin başarı ölçütü hesaplanmıştır.

ANAHTAR KELİMELER: ABC, Otsu, Yangın Tespiti, Jaccard, Dice

ABSTRACT

Master Thesis

FOREST FIRE DETECTION BY USING COLOR FEATURE OF FIRE/ FLAME

Buket TOPTAŞ

Inonu University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering

46 + ix page

2017

Supervisor: Asst. Prof. Davut HANBAY

Forest fires are a disaster that affects the atmosphere in the negative way, destroying the habitat of many living species and destroying plant and animal species. In the fight against forest fires, the early detection of fire and the introduction of warning systems have a great important. Nowadays, depending on the development of the technology, image processing techniques are used in fire / flame detection. Usually, static or dynamic characteristics of fire/flame are used in developed methods for fire / flame detection.

In this study, the color features of the fire images were used and the fire images transformed to a new color space to detect the flame. The obtained new color space is developed by using the Artificial Bee Colony (ABC) algorithm. Otsu thresholding method was used on converted images in new color space. Flame detection was performed on binary images. After the flame detection process is completed, the obtained binary images are subjected to the similarity measure with the real binary images contained in the data set and the success criterion of the proposed method is calculated.

KEYWORDS: ABC, Otsu, Fire Detection, Jaccard, Dice

TEŐEKKÜR

Yüksek Lisans Tez çalışmamın gerçekleşmesinde, değerli bilgilerini benimle paylaşan her türlü yardımı ve desteęi saęlayan danışman hocam Sayın Doç. Dr. Davut Hanbay'a;

Yüksek Lisans Tez çalışmasında, akademik bilgi ve tecrübelerini esirgemeyen her zaman yol gösterici olan değerli hocam Sayın Arş. Gör. Nuh Alparslan'a;

Yüksek Lisans Tez çalışmamda, yangın hakkında piyasa ihtiyaçlarını ve yaşanan problemleri benimle paylaşan Fizik Mühendisi Murat Şamil Ünal'a;

Yüksek Lisans Tez hazırlama sürecinde, kıymetli zamanını bana her zaman ayırıp sabırla ve büyük bir ilgiyle elinden gelenin fazlasını sunan, maddi ve manevi destekleriyle beni hiçbir zaman yalnız bırakmayan değerli yol arkadaşım ve eşim Bilgisayar Mühendisi Murat Toptaş'a

Teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
ŞEKİLLER DİZİNİ.....	vi
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR.....	ix
1. GİRİŞ	1
1.1 Tezin Amacı.....	2
1.2 Literatür Taraması ve Değerlendirilmesi	3
1.2.1 Uydu Tabanlı Yangın Algılama Sistemleri.....	3
1.2.2 Optik Sensörlerle Yangın Algılama Sistemleri.....	3
1.2.3 Görüntü İşleme Tabanlı Yangın Algılama Sistemleri.....	4
1.3 Tezin Organizasyonu	6
2. TEORİK BİLGİLER.....	7
2.1 Renk Uzayları.....	7
2.1.1 RGB Renk Uzayı	7
2.1.2 HSI Renk Uzayı	8
2.1.3 YCbCr Renk Uzayı	9
2.2 OTSU Eşik Değeri Belirleme Yöntemi	10
2.3 Gamma Kontrast Ayarlaması.....	12
2.4 Doğruluk Değerlendirme Yöntemleri	13
2.4.1 Benzerlik Ölçütleri	13
2.4.2 İstatiksel Doğruluk Ölçütleri.....	14
3. OPTİMİZASYON ALGORİTMALARI	16
3.1 Yapay Arı Kolonisi Algoritması	16
3.2 Parçacık Sürü Optimizasyon Algoritması	18
4. K-MEANS KÜMELEME ALGORİTMASI	21
5. ÖNERİLEN YANGIN ALEVİ TESPİT UYGULAMASI.....	24
5.1 Kullanılan Veri Seti.....	24
5.2 Önerilen Yöntem.....	25
5.2.1 Özellik Matrisinin Oluşturulması.....	25
5.2.2 Hata Hesaplama Fonksiyonu.....	27

5.2.3	Önerilen Yapay Arı Kolonisi Algoritma Adımları	29
5.2.4	Görüntü Ön İşleme	30
5.2.5	OTSU Eşik Belirleme Yöntemi	31
5.2.6	Benzerlik Ölçütleri	32
6.	SONUÇLAR VE DEĞERLENDİRME	34
6.1	Sistemin Başarı Ölçütünün Hesaplanması	36
7.	KAYNAKLAR	43

ŞEKİLLER DİZİNİ

Şekil 2.1. RGB renk uzayı kübik gösterimi	7
Şekil 2.2. (a) RGB renk uzayı üçgeni, (b) RGB renk uzayından HSI renk uzayına dönüşüm üçgeni	8
Şekil 2.3. Yangın görüntüsünün renk uzaylarında görüntüsü. a) RGB renk uzayındaki yangın görüntüsü, b) YCbCr renk uzayındaki yangın görüntüsü, c) HSI renk uzayındaki yangın görüntüsü.	9
Şekil 2.4. Gamma kontrast ayarlanması.....	12
Şekil 2.5. Benzerlik ölçütleri için verilen örnek şema	13
Şekil 3.1. PSO hız güncelleme gösterimi.....	19
Şekil 4.1. K-means kümeleme algoritması, (a) Küme sayısının belirlenmesi, (b) Küme merkezlerinin seçilmesi, (c) Küme merkezleri ile veriler arasındaki uzaklıkların hesaplanması, (d) Yeni küme merkezlerinin belirlenmesi.....	21
Şekil 5.1. Veri seti içinden örnek görüntüler. (a)-(c)-(e) Orijinal görüntüler, (b)-(d)-(f) Gerçek ikili alev görüntüleri	24
Şekil 5.2. Önerilen Sistem Akış Şeması	26
Şekil 5.3. Alev kesiti	27
Şekil 5.4. Alev olmayan kesit	27
Şekil 5.5. (a) Veri setinde bulunan orjinal görüntüler, (b) (a)'da verilen görüntülere gamma düzeltilmesi uygulanmış görüntüler	30
Şekil 5.6. (a) Orjinal görüntüler, (b) Otsu yöntemi sonucu oluşan ikili bölütlenmiş görüntüler	31
Şekil 5.7. Jaccard ve Dice benzerlik ölçütü. (a) Orjinal yangın görüntüleri, (b) Jaccard benzerlik sonucu, (c) Dice benzerlik sonucu	32
Şekil 6.1. Jaccard ve Dice benzerlik ölçütleri. (a) RGB görüntü, (b) Gerçek ikili görüntü, (c) Bölütlenmiş ikili görüntü, (d) Jaccard benzerlik sonucu, (e) Dice benzerlik sonucu.....	35
Şekil 6.2. Renk uzayları ve benzerlik ölçüt sonucu. (a) RGB görüntü, (b) Gerçek ikili alev görüntüsü, (c) ABC ile elde edilen renk uzayı, (d) (c) Görüntüsü için Otsu yöntemi sonrası jaccard benzerlik sonucu, (e) PSO ile elde edilen renk uzayı, (f) (e) Görüntüsü için Otsu sonrası Jaccard benzerlik sonucu.....	37
Şekil 6.3. Renk uzaylarında alev ve alev olmayan piksellerin renk dağılımı. (a) RGB görüntü ve renk dağılımı, (b) ABC ile elde edilen renk uzayındaki görüntü ve renk dağılımı, (c) PSO ile elde edilen renk uzayındaki görüntü ve renk dağılımı.....	38
Şekil 6.4. Alıcı işlem karakteristiği ile ABC ve PSO sonuçlarının karşılaştırılması .	39
Şekil 6.5. Veri seti içerisinden rastgele seçilen 5 görüntü için uygulama sonuçları. (a) Orijinal görüntüler, (b) Veri seti içerisinde bölütlenmiş gerçek ikili görüntüler, (c) Denklem (6.1)'de verilen dönüşüm matrisi uygulanmış görüntü, (d) (c) sonrası Otsu	

yöntemi uygulanmış ikili görüntü, (e) Denklem (6.2)'de verilen dönüşüm matrisi uygulanmış görüntü (f) (e) sonrası Otsu yöntemi uygulanmış ikili görüntü..... 41

Şekil 6.6. Veri setinin farklı renk uzaylarında görünümü. a) RGB uzayında ki görüntü, b) İkili bölütlenmiş alev görüntüsü, c) ABC uzayındaki görüntü, d) YCbCr renk uzayındaki görüntü, e) HSI renk uzayındaki görüntü 42

ÇİZELGELER DİZİNİ

Çizelge 2.1. Otsu Algoritma Adımları	10
Çizelge 2.2. Karmaşıklık Matrisi	14
Çizelge 2.3. AUC Değer Aralığı	15
Çizelge 2.4. Doğruluk Ölçüt Formülleri	15
Çizelge 3.1. Yapay Arı Kolonisi Algoritma Adımları	17
Çizelge 3.2. Parçacık Sürü Optimizasyon Algoritması.....	20
Çizelge 4.1. K-Means Algoritma Adımları.....	22
Çizelge 5.1. Parametre ve Değerleri	33
Çizelge 6.1. Jaccard ve Dice benzerlik ölçüt sonuçları (10 görüntü için)	34
Çizelge 6.2. 500 görüntü için ortalama Jaccard ve Dice benzerlik sonucu	36
Çizelge 6.3. Veri seti üzerinde hesaplanan doğruluk ölçüt hesaplama sonuçları	40

SİMGELER VE KISALTMALAR

YAK	Artificial Bee Colony (Yapay Arı Kolonisi)
AUC	Area Under Curve (Eğri altında kalan alan)
CFDB	Coursican Fire Database
Dsim	Dice Benzerlik Ölçüt Değeri
FNR	False Negative Rate (Yanlış Negatif Oran)
FPR	False Positive Rate (Yanlış Pozitif Oran)
HSI	Hue Saturation Intensity (Renk Özü Doygunluk Yoğunluk)
ISDN	Integrated Services Digital Network (Birleşik Sayısal Ağ Hizmetleri)
Jsim	Jaccard Benzerlik Ölçüt Değeri
KM	Karmaşıklık Matrisi (Confusion Matrix)
PSO	Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
RGB	Red Gren Blue (Kırmızı Yeşil Mavi)
ROC	Receiver Operating Characteristic (Alıcı işlem Karakteristiği)
SVM	Support Vector Machine (Destek Vektör Makineleri)
TP	True Positive (Doğru Pozitif)
TN	True Negative (Doğru Negatif)
TPR	True Positive Rate (Doğru Positive Oran)
TNR	True Negative Rate (Doğru Negatif Oran)
W	Dönüşüm Matrisi
X	Özellik Matrisi
Y	Dönüştürülmüş Özellik Matrisi
YCbCr	Parlaklık Mavi Krominans kırmızı krominans
γ	Gamma

1. GİRİŞ

Toplum yaşamını, bitki ve hayvan türlerinin varlığını tehdit eden çeşitli afetler vardır. Afet türleri içerisinde en etkili tehditlerden biri de yangındır. Yangın, ekonomik kayıplara sebep olur. Küresel ısınma ve yerel hava durumunu olumsuz yönde etkiler. Ayrıca, ormanlık arazilerde meydana gelirse birçok canlı türünü yok edebilir [1].

Ormanlar, dünyada var olan en değerli alanlardır. Ormanların yok olması, küresel ısınma problemini arttıracak ve dünya da yaşam kalitesini düşürecektir. Ekolojik dengeyi korumak ve ormanların varlığını tehdit eden unsurları azaltmak için bazı tedbirler alınmıştır. Alınan tedbirler içerisinde en etkilisi, yangın risk bölgelerini izleyerek yangını başlangıç evrelerinde belirlemek ve yangına erken müdahale etmektir. Erken yangın algılama üzerine geçmişten günümüze birçok sistem geliştirilmiştir. Tercih edilen erken yangın algılama sistemlerinde aranan özellikler, güvenilirlik, hızlı çalışma ve ucuz maliyet olmuştur.

Kamera teknolojisinin gelişmesi ile birlikte birçok alanda görüntü işleme tabanlı uyarı sistemleri oluşturulmuştur. Yangın tespit sistemleri de görüntü işleme teknikleri kullanarak uyarı oluşturan sistemler arasındadır. Görüntü işleme tekniklerinin avantajı geniş mesafeleri algılayabilmesi, ucuz maliyetli olması ve güvenilir bir sistem olmasıdır.

Bu tez çalışmasında, ormanlık alanlarda ki yangın görüntülerini kullanarak alev tespit eden bir sistem önerilmiştir. Önerilen sistemde, yeni bir renk uzayı tasarlanmış ve yeni renk uzayındaki alev görüntülerine bölütleme işlemi uygulanmıştır.

Önerilen yeni renk uzayı, bir özellik matrisi ile dönüşüm matrisinin doğrusal çarpımı ile oluşturulmaktadır. İlk aşamada, veri setindeki görüntüler üzerinden alev ve alev olmayan kesitler alınmıştır. Daha sonra bu kesitlerin piksel renk değerleri bir özellik matrisinde birleştirilmiştir. Elde edilen özellik matrisi rastgele üretilen bir dönüşüm matrisi ile doğrusal çarpıma tabi tutulmuş ve yeni renk uzayındaki görüntü elde edilmiştir. Elde edilen yeni renk uzayı YAK algoritmasında uygunluk değerinin hesaplanması için K-means algoritmasına gönderilmiştir. YAK algoritmasında dönüşüm matrisinin değerleri uygunluk fonksiyonunun hata değerine göre güncellenmiştir. YAK algoritması sonucunda güncellenmiş dönüşüm matrisi elde edilmiştir. İkinci aşamada başlangıç görüntüleri tekrar kullanılmıştır. Bu görüntülere

dönüşüm matrisi uygulanmadan önce görüntü iyileştirme yapılmıştır. İyileştirilmiş görüntüler yeni renk uzayına dönüştürülmüş ve bu görüntülerden alev bölgesinin çıkarılması için Otsu algoritması kullanılmıştır. Son olarak elde edilen bölütlenmiş ikili görüntüler veri seti içerisindeki gerçek ikili alev görüntüleri ile Jaccard ve Dice benzerlik ölçütü kullanılarak karşılaştırılmıştır. Tasarlan bu sistem T.Toulouse [2] ve arkadaşları tarafından oluşturulan ve paylaşımına açık olan COURSICAN FIRE DATABASE (CFDB) isimli veri seti üzerinde test edilmiştir. Bu veri seti toplam 500 adet orman yangın görüntüsünden oluşmaktadır. Her görüntü için gerçek ikili (siyah beyaz) alev görüntüleri de bulunmaktadır.

1.1 Tezin Amacı

Bu tez çalışmasının amacı; görüntü işleme tabanlı bir orman yangın tespit sistemi geliştirmektir. Geliştirilen bu sistem de alev renk özellikleri kullanılarak alevin farklı bir renk uzayına taşınması amaçlanmıştır. Bu amaçla alev renk özellikleri kullanılarak oluşturulan ve YAK optimizasyon algoritması kullanılarak modellenen yeni bir renk uzayı tasarlanmıştır.

Yangın görüntülerinde alev tespit edilirken genelde alevin statik özelliklerinden faydalanılır. Renk bilgisi, alev görüntülerinde incelenen en popüler statik özelliklerden biridir. Literatürde alevin renk bilgisini kullanarak geliştirilen birçok renk uzayı tabanlı sistem mevcuttur. Bu sistemler genelde karmaşık yapıda olup klasik renk uzayları ile sınırlıdır. Yapılan çalışmada ise, klasik renk uzaylarını kullanmak yerine yangın görüntüleri üzerinde çalışan ve YAK algoritması ile modellenen yeni bir renk uzayı tasarlanmıştır. Önerilen çalışma, kolay uygulanabilen özgün bir yapıya sahiptir.

1.2 Literatür Taraması ve Değerlendirilmesi

Yangın algılama sistemleri incelendiğinde, tüm sistemlerin ortak amacı yangına zamanında müdahale edebilmek için erken uyarı oluşturmak, ucuz maliyet sağlamak ve güvenilir olmaktır. Teknolojinin gelişimine bağlı olarak geçmişten bugüne kadar birçok yangın tespit sistemi önerilmiştir.

1.2.1 Uydu Tabanlı Yangın Algılama Sistemleri

1998 yılında gelişmiş yüksek çözünürlüklü ve 1999 yılında başlatılan orta çözünürlüklü [3] uydu tabanlı sistemler yangını algılamak için kullanılmıştır. Ne yazık ki, bu uydular dünya üzerindeki tüm bölgelerin görüntülerini yalnızca iki günde bir sağlayabilmiştir. Uydu tabanlı bu sistemlerin hava şartlarından etkilenmesi ve tespit etme sürelerindeki gecikmelerden dolayı kullanışlı bir sistem olarak görülmemiştir.

1.2.2 Optik Sensörlerle Yangın Algılama Sistemleri

Sensör teknolojisinin gelişmesi ile birlikte optik sensörler yangın algılama alanında yerini almaya başlamıştır. FireWatch [4] sistemi 10 ile 40 km arasında yer alan yangınları tespit eden optik sensörlü bir sistemdir. Bu sistemde sensör bir bulut ya da duman sütunu algıladığında 64 bitlik ISDN (Bütünleştirilmiş Sayısal Ağ Hizmetleri) aracılığıyla orman yangın kontrol merkezlerine bilgileri aktarmaktadır. Ancak gelen bilgileri yorumlayamadığı için kullanışlı bir sistem değildir. Sensör teknolojisinin ağ teknolojisi ile birleşmesi ile yangın algılama üzerinde wireless sensörlerle de çalışmalar yürütülmüştür [5-6]. Bu sistemlerde ise sınırlı hafıza sorunu vardır. Ayrıca, güç kaynağına sahip wireless sensör ağlarına görüntüler yavaş bir şekilde yüklendiği için görüntü transferinde problemler yaşanmıştır.

1.2.3 Görüntü İşleme Tabanlı Yangın Algılama Sistemleri

Günümüzde, teknolojinin gelişmesine bağlı olarak zaman içerisinde kamera teknolojisi de gelişmiştir. Kamera teknolojisinin gelişmesi ile görüntü işleme alanında yapılan uygulamalar artmıştır. Bu uygulamaların kullanıcı kolaylığı sağlaması ve ucuz maliyetli olmasından dolayı yangın algılama sistemlerinde görüntü işleme tabanlı uygulamalar geliştirilmiştir. Görüntü tabanlı uygulamaların en önemli avantajı, görüntüyü geniş çaplı olarak algılaması ve görüntü sahnesi içerisinde görülen bir yangını anında ihbar sistemlerine aktarabilmesi olmuştur.

Sensör teknolojisinin, açık alanlarda oluşan yangınlarda yetersiz kalması ile görüntü işleme teknikleri ile yangın algılama üzerine çalışmalar da artmıştır. Görüntü işleme tekniklerine dayalı yangın algılama sistemlerinde yöntemlerin çoğu renk [7–10], hareket [11-14], doku [15-18] ve titreşim frekansı [19-21] gibi alev veya dumanın statik ya da dinamik özelliklerini kullanmaktadır. Yapılan çalışmalarından bazıları şöyledir:

Norsyahirah Izzati binti Zaidi vd.[8], RGB ve YCbCr renk uzaylarına dayalı yangın algılama üzerinde bir çalışma yürütmüşlerdir.

I.Khan vd. [9], yangın görüntüsünün renk analizine dayanan bir alev tespit yöntemi önermişlerdir. Önerilen yöntemde, yangın alanını tespit etmek için görüntü HSI renk uzayına çevrilmiş ve daha sonra renk maskesi oluşturularak alev bölgesi algılanmıştır.

Punam vd. [11], görüntü işleme tekniklerini kullanarak yaptıkları çalışma da video verilerinde yangını tespit etmek için renk algılama, hareket algılama ve alan dağılımı yaklaşımlarının birleşimini kullanmışlardır. Önerilen algoritma da öncelikle video karelerindeki istenen renk bölgeleri bulunmuş ve daha sonra videoda herhangi bir hareketin bulunduğu bölge belirlenmiş ve son adımda çerçevenin piksel alanı hesaplanmıştır.

B. Uğur Töreyn vd. [12], dalgacık dönüşümü kullanarak sıkıştırılmış videolarda, hareketli nesne algılayabilen bir çalışma yapmışlardır. İşlem yaptıkları resme ait dalgacık dönüşüm katsayıları, arka plana ait katsayılar ile kıyaslayarak hareketli nesne algılama işlemini gerçekleştirmişlerdir.

B.Uğur Töreyn vd. [13], sıradan bir kamera tarafından üretilen video verilerini işleyerek, yangını/alevi gerçek zamanlı olarak algılayan bir yöntem geliştirmişlerdir. Geliştirilen yöntemde, video verilerinde hareket ve renk ipuçlarına ek olarak, alev ve alev titreşimi dalgacık uzayında tespit edilmiştir.

Sándor Fazekas ve Dmitry Chetverikov [18], optik akış özelliklerini kullanarak dinamik doku sınıflandırma üzerinde çalışma yürütmüşlerdir. Bu yaklaşım da yerel görüntü bozulmalarını ve bunların optik akışla olan ilişkisi analiz edilmiştir. Sonra da kapsamlı bir dinamik doku sınıflandırma çalışması ile sonuçlar sunulmuştur.

Juan Chen vd. [20], Gauss karma modelini kullanarak arka plan çıkarımı yapmışlardır. Arka plan çıkarımı ile tespit edilen hareketli cisimler alev renk filtreleme algoritması kullanılarak aday ve aday dışı alev bölgelerine ayrılmıştır. Alev titreşim tanımlama algoritması ile de gerçek alevlerin video görüntülerindeki ateş benzeri cisimlerden ayırt edilmesi sağlanmıştır.

B.Toptas ve D.Hanbay [22], HSI renk uzayında renk maskesi oluşturarak video görüntülerinde alev bölgesinin tespitini gerçekleştirmişlerdir.

Rui Chui vd. [23], yangın algılama sistemlerinde alevi tespit etmek için yanlış alarmları en aza indirgeyen güvenilir bir sistem yapmayı amaçlamışlardır. Önerdikleri sistemde, dinamik özellikler, doku özellikleri ve kontur özelliklerini temel alarak yeni bir yaklaşım sunmuşlardır.

Lopes vd. [24] Kanada'da meydana gelen yangınlara ait veri setini kullanarak orman yangınlarının doku görselleştirmesi ve bilgisayarla modellenmesi üzerine bir çalışma gerçekleştirmişlerdir.

1.3 Tezin Organizasyonu

Tezin birinci bölümünde, yangın kavramı, yangının ormanlar üzerindeki etkisi ve literatürde yapılan yangın tespit sistemleri anlatılmıştır. Ayrıca tezin amacı anlatılmış ve tez çalışmasının seçilme sebebi ve önerilen yaklaşımdan bahsedilmiştir.

Bölüm 2'de, tez çalışmasında kullanılan yöntemler hakkında teorik bilgiler verilmiştir. İlk olarak renk uzayları hakkında bilgiler verilmiş ve RGB, HSI ve YCbCr klasik renk uzayları anlatılmıştır. İkinci olarak, gri seviye görüntüleri ikili görüntüye çeviren Otsu algoritmasından bahsedilmiştir. Üçüncü olarak, kontrast ayarlama yöntemlerinden biri olan gamma düzeltmesinden bahsedilmiştir. Son olarak ise tez çalışmasının başarısını ölçmek için kullanılan benzerlik ölçütleri ve doğruluk ölçütlerinden bahsedilmiştir.

Bölüm 3'de, optimizasyon yöntemlerinden bahsedilmiştir. YAK ve PSO optimizasyon algoritmalarının yapıları verilmiş ve çalışma prensipleri anlatılmıştır.

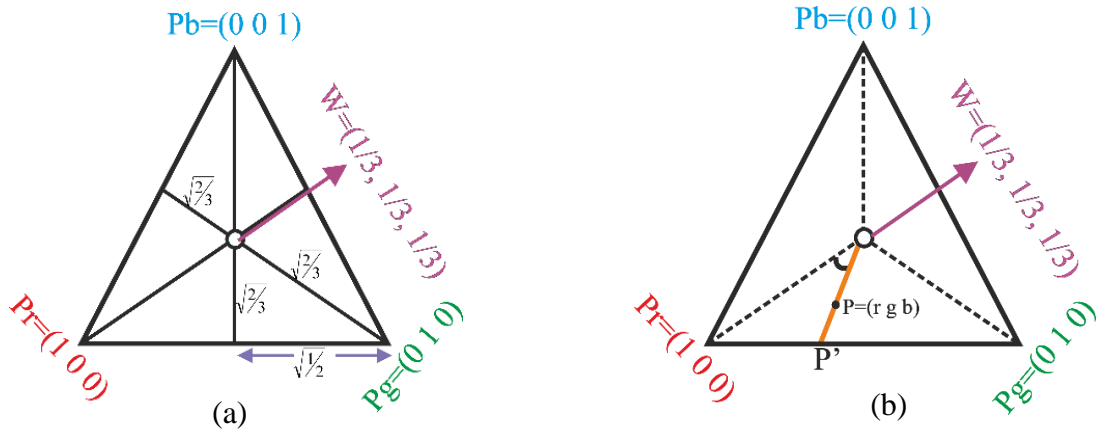
Bölüm 4'de, kümeleme yöntemlerinden biri olan K-means kümeleme yönteminden bahsedilmiştir.

Bölüm 5'de, önerilen yangın alev tespit sisteminden bahsedilmiş ve kullanılan veri seti açıklanmıştır.

Bölüm 6'da, önerilen sistemin veri seti üzerinde uygulanması görsel ve istatistiksel sonuçlarla gösterilmiştir. Sistemin diğer sistemlerle kıyaslanması yapılmıştır. Doğruluk ölçüt hesaplaması yapılmıştır. Ayrıca yeni renk uzayının diğer klasik renk uzayları ile arasındaki farklılıklar görsel sonuçlar ile ifade edilmiştir.

2.1.2 HSI Renk Uzayı

Renk Özü (Hue), Doygunluk (Saturation) ve Yoğunluk (Intensity) parametrelerinin birleşiminden oluşmuştur. Renk Özü, rengin baskın dalga boyu hakkında bilgi vermektedir. Doygunluk, rengin kendi skalasında ne kadar doygun olduğu hakkında bilgi verir. Eğer doygunluk değeri yüksek ise renkler canlı, düşük ise renkler gri tonlarına daha yakın görünür. Yoğunluk ise ışık miktarı hakkında bilgi verir. Şekil 2.2’de RGB renk uzayı üçgeni ve bu üçgen kullanılarak HSI renk uzayına dönüşüm üçgeni gösterilmiştir.



Şekil 2.2. (a) RGB renk uzayı üçgeni, (b) RGB renk uzayından HSI renk uzayına dönüşüm üçgeni

HSI renk uzayını oluşturan renk özü (H), doygunluk değeri (S) ve yoğunluk değerinin (I) değer aralıkları şöyledir:

$$0^\circ \leq H \leq 360^\circ, \quad 0 \leq S \leq 100, \quad 0 \leq I \leq 255$$

RGB görüntünün HSI renk modeline dönüşümü Denklem (2.2-2.5) ile ifade edilmiştir [25].

$$I = \frac{1}{3}(r + g + b) \quad (2.2)$$

Burada verilen r , g ve b parametreleri Denklem (2.1) ile hesaplanan değerlerdir.

$$S = 1 - \frac{3}{r + g + b} [\min(r, g, b)] \quad (2.3)$$

$$H = \begin{cases} \theta & ,if \ b \leq g, \\ 360 - \theta & ,if \ b > g \end{cases} \quad (2.4)$$

$$\theta = \cos^{-1} \left\{ \frac{0.5[(r-g) + (r-b)]}{\left[(r-g)^2 + (r-b)(g-b) \right]^{1/2}} \right\} \quad (2.5)$$

Denklem (2.2 – 2.5) arasında ifade edilen denklemlerde tüm renk değerleri [0,1] aralığında normalize edilmiş değerlerdir.


2.1.3 YCbCr Renk Uzayı

Renklilik ve parlaklık bilgisini birbirinden ayıran bir renk uzayıdır. Parlaklık bilgisi, görüntüde bulunan ışığın miktarını vermektedir. Renklilik bilgisi ise, görüntüdeki renklerin renk özü oranlarının miktarı hakkında bilgi vermektedir.

RGB renk uzayından YCbCr renk uzayına dönüşüm Denklem (2.6) ile sağlanır[26].

$$\begin{bmatrix} \overline{Y} \\ \overline{Cb} \\ \overline{Cr} \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.169 & -0.331 & 0.500 \\ 0.500 & -0.419 & -0.081 \end{bmatrix} \begin{bmatrix} \overline{R} \\ \overline{G} \\ \overline{B} \end{bmatrix} \quad (2.6)$$

RGB, YCbCr ve HSI renk uzaylarına ait yangın görüntüleri Şekil 2.3'de verilmiştir.



Şekil 2.3. Yangın görüntüsünün renk uzaylarında görüntüsü. a) RGB renk uzayındaki yangın görüntüsü, b) YCbCr renk uzayındaki yangın görüntüsü, c) HSI renk uzayındaki yangın görüntüsü.

2.2 OTSU Eşik Değeri Belirleme Yöntemi

İlk kez ismini aldığı Otsu tarafından önerilmiştir. Gri seviye görüntüleri, ikili görüntüye dönüştürürken kullanılacak en uygun eşik değerinin hesaplanmasını sağlar.

Otsu yönteminin algoritma adımları Çizelge 2.1’de verilmiştir.

Çizelge 2.1. Otsu Algoritma Adımları

1:	Girdi Parametreleri
2:	Gri Seviye Görüntü.
3:	Yöntem
4:	Önce Gri Seviye Resim Okunur.
5:	Resmin Histogramı Hesaplanır.
6:	Döngü
7:	T olarak adlandırılan bir eşik değeri seçilir.
8:	Görüntünün arka plan varyansı hesaplanır.
9:	Görüntünün ön plan varyansı hesaplanır.
10:	İkili Sınıf içindeki varyanslar hesaplanır.
11:	Bitir (Tüm eşik değerleri bitene kadar)
12:	Sınıf içindeki varyans değerini minimum yapan T değeri eşik değeri olur.
13:	İkili Görüntü = Gri seviye görüntü > T

Çizelge 2.1’de verilen adımların açıklaması şu şekildedir[27].

Algoritma ilk olarak, gri görüntünün okunması ve Histogram değerinin hesaplanması ile başlar. Histogram hesabı ile renklerin görüntü üzerinde var olma sayısı belirlenmiş olur.

Algoritmanın yedinci adımında, T olarak adlandırılan bir eşik değeri belirlenir.

Algoritmanın sekizinci ve dokuzuncu adımında, görüntünün ön ve arka piksellerine ait varyanslar hesaplanır. Varyans hesabı ön ve arka pikseller için sırasıyla Denklem (2.7) ve Denklem (2.8)’ de verildiği gibi ifade edilir.

$$\sigma_f^2(t) = \sum_{i=0}^t p_i \cdot (i - u_f(t))^2 / \omega_f \quad (2.7)$$

$$\sigma_b^2(t) = \sum_{i=t+1}^{L-1} p_i \cdot (i - u_b(t))^2 / \omega_b \quad (2.8)$$

Burada t değeri mevcut piksel sayısını L değeri ise toplam piksel sayısını vermektedir. u_f ve u_b ifadesi ise iki sınıf için ortalama yoğunluk gri seviye değerleridir. Ön ve arka piksel sınıfları için sırası ile Denklem (2.9) ve Denklem (2.10)'da verildiği gibi ifade edilir.

$$u_f(t) = \sum_{i=0}^t i.p_i / \omega_f(t) \quad (2.9)$$

$$u_b(t) = \sum_{i=t+1}^{L-1} i.p_i / \omega_b(t) \quad (2.10)$$

Burada ifade edilen $\omega_f(t)$ ve $\omega_b(t)$ ifadesi iki sınıf için olasılık yoğunluk değerlerini vermektedir. Ön ve arka piksel sınıfları için sırası ile Denklem (2.11) ve Denklem (2.12) verildiği gibi ifade edilir.

$$\omega_f(t) = \sum_{i=0}^t p_i \quad (2.11)$$

$$\omega_b(t) = \sum_{i=t+1}^{L-1} p_i \quad (2.12)$$

Burada ifade edilen p_i değeri ise i 'inci gri seviyenin olasılık dağılımını vermektedir. AxB Boyutunda bir görüntü olduğunu varsayarsak Denklem (2.13)'de verildiği gibi ifade edilir.

$$p_i = \frac{f_i}{AxB} \quad (2.13)$$

Burada f_i , AxB boyutundaki imge için i 'inci gri seviye frekansını göstermektedir.

Algoritmanın onuncu adımında, sınıf içi varyans hesabı yapılır. Daha sonra tüm sınıflar arasındaki varyans değerini maksimize eden ve sınıf içi varyans değerini minimize eden T değerlerine bakılır. Sınıflar arası varyans hesabı, sınıf içi varyans hesabına göre daha az işlem yükü getirdiği için sınıflar arası varyans değerini maksimize eden değere bakılabilir. Sınıflar arası varyans değeri Denklem (2.14) ile hesaplanır[27].

$$\sigma^2_{out}(t) = \omega_f(t).[u_f(t) - u_T]^2 + \omega_b(t).[u_b(t) - u_T]^2 \quad (2.14)$$

Burada u_T değeri, görüntüye ait ortalama gri seviye değerini temsil etmektedir. Denklem (2.15)'de verildiği gibi ifade edilmektedir.

$$u_T = \sum_{i=0}^{L-1} i.p_i \quad (2.15)$$

Burada T değeri, sınıflar arası varyans değerini maksimum yapan eşik değeridir. Denklem (2.16)'de verildiği gibi ifade edilmektedir.

$$t = \text{ArgMax}_{0 < t < L-1} \sigma^2_{out}(t) \quad (2.16)$$


Algoritmanın on ikinci adımında, tüm eşik değerleri içerisinde sınıf içi varyans değerini minimum yapan değer eşik değeri olarak seçilir.

Algoritmanın on üçüncü adımında, gri görüntü içindeki piksel renk değerleri seçilen eşik değerinden büyükse 1 küçükse 0 yapılarak ikili görüntüler oluşturulur.

2.3 Gamma Kontrast Ayarlaması

Görüntü üzerinde görüntüye ait özelliklerin birçoğu belirgin değildir. Görüntüye ait özelliklerin belirgin hale gelmesi için görüntü iyileştirme teknikleri kullanılmalıdır. Bu teknikler, görüntü üzerinde gürültü azalmak, piksellerin renk dağılımını ayarlamak ve görüntü netleştirmek gibi işlemlerdir. Görüntü iyileştirme işlemleri kullanılan sistemin performans artışına sebep olabilir.

Görüntülerin kontrast ayarlanmasında, orijinal görüntüde bulunan her pikselin yoğunluk değeri kontrast ayarı yapılabilmesi için bir transfer fonksiyonuna dönüştürülür. Kontrast ayarlaması ile görüntü iyileştirme de en yaygın kullanılan transfer fonksiyonu gamma kontrastının ayarlanmasıdır. Gamma kontrastının ayarlanması üç boyutlu renk uzayında her renk kanalı için ayrı ayrı hesaplanıp kullanılabilir. Ayrıca iki boyutlu gri görüntülerde de kullanılabilir. Gamma kontrastının ayarlanması Şekil 2.4'de gösterilmiştir.



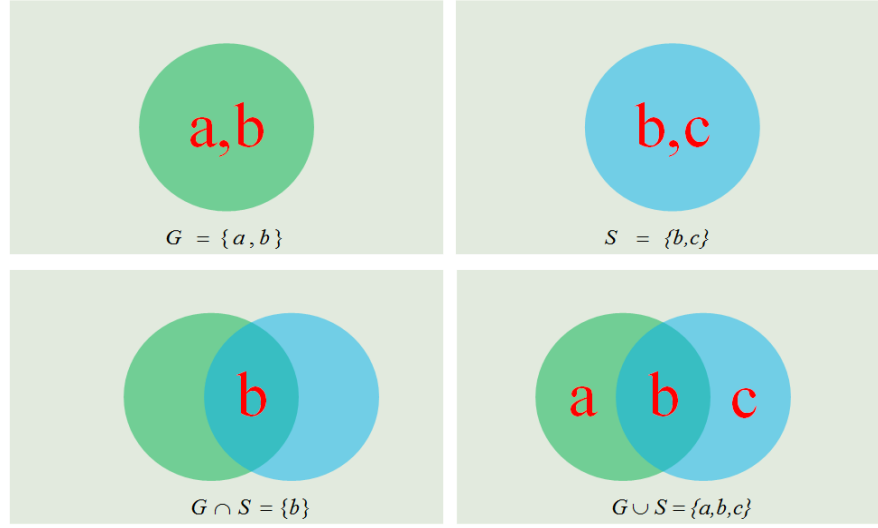
Şekil 2.4. Gamma kontrast ayarlanması

Şekil 2.4'de verilen low_in ve high_in değerleri kontrast için düşük ve yüksek gri tonlama yoğunluk değerlerini vermektedir.

2.4 Doğruluk Değerlendirme Yöntemleri

2.4.1 Benzerlik Ölçütleri

İki ikili görüntünün birbirine ne kadar benzediğini ölçmek için benzerlik ölçüt yöntemleri kullanılabilir. Öklid, Kosinüs, Jaccard, Dice, Hamman gibi birçok benzerlik ölçüt yöntemi mevcuttur. Şekil 2.5'te Jaccard ve Dice benzerlik ölçütlerini ifade edebilmek için kullanılan örnek şablonlar verilmiştir.



Şekil 2.5. Benzerlik ölçütleri için verilen örnek şema

$G = \{a,b\}$ ve $S = \{b,c\}$ olmak üzere, G ifadesi bölütlenmiş gerçek ikili görüntüyü (ground truth), S ifadesi ise önerilen algoritma sonucu bölütlenmiş ikili görüntüyü (segmented image) temsil etmektedir. Jaccard ve Dice benzerlik ölçütü hesaplaması şu şekildedir[28]:

Jaccard Benzerlik Ölçütü: Jaccard indeksi veya Jaccard benzerlik ölçütü Denklem (2.17) de verildiği gibi hesaplanmaktadır.

$$Jsim = \frac{|G \cap S|}{|G \cup S|} = \frac{b}{a+b+c} \quad (2.17)$$

Burada $Jsim$ parametresi, Jaccard benzerlik indeksini vermektedir ve $[0 \ 1]$ aralığında bir değer alır. Görüntü tamamen benziyor ise $Jsim$ parametresi 1 değerini alır. Görüntüler arasında hiçbir benzerlik yok ise $Jsim$ parametresi 0 değerini almaktadır.

Dice Benzerlik Ölçütü: Denklem (2.18)'de verildiği gibi hesaplanmaktadır.

$$Dsim = \frac{2 \cdot |G \cap S|}{|G| + |S|} = \frac{2 \cdot (b)}{|a+b| + |b+c|} \quad (2.18)$$

Burada *Dsim* parametresi, Dice benzerlik indeksini vermektedir. *Dsim* parametresi [0 1] aralığında bir değer alır. Görüntü tamamen benziyor ise *Dsim* parametresi 1 değerini alır. Görüntüler arasında hiçbir benzerlik yok ise *Dsim* parametresi 0 değerini alır.

2.4.2 İstatiksel Doğruluk Ölçütleri

Bir sistem de sınıflandırma başarısı, doğruluk hesaplaması, hassasiyet, özgünlük, iki sınıf arasındaki başarı oranı gibi istatistiksel bilgilere ihtiyaç duyulabilir. Karmaşıklık Matrisi (KM), tasarlanan sistemin doğruluk ölçütlerinin kolayca ifade edilmesini mümkün kılmaktadır. KM matrisi Çizelge 2.2'de gösterildiği gibi dört tür elemana sahiptir. Bu elemanların, doğru pozitif (True Positive, TP), yanlış pozitif (False Positive, FP), yanlış negatif (False Negative, FN) ve doğru negatif (True Negative, TN) şeklinde tanımlanır.

Çizelge 2.2. Karmaşıklık Matrisi

Beklenen Gerçek Değerler			
Tahmini Değerler			
			Doğru
	Doğru		True Positive (TP)
Yanlış		False Positive (FP)	True Negative (TN)

Karmaşıklık matrisi kullanılarak sistemin diğer sistemlerle başarı oranının kıyaslanması Alıcı İşlem Karakteristiği (ROC) kullanılarak değerlendirilebilir. ROC eğrisi, KM ile elde edilen duyarlılık değerinin (TPR), yanlış pozitif orana (1-TNR) karşı kıyaslanması ile elde edilmektedir. Her iki eksenin noktaları birleştirilerek ROC eğrisi oluşturulur. ROC eğrisinin altında kalan alan (AUC), da sistemin başarı ölçütünün hesaplanmasında kullanılabilen bir doğruluk ölçütüdür. AUC değeri 0 ile 1 arasında bir değer alır. Çizelge 2.3'de AUC değer aralıklarına göre sonuçların yorumlanması verilmiştir.

Çizelge 2.3. AUC Değer Aralığı

.90-1.00	Mükemmel
.80-.90	İyi
.70-.80	Orta
.60-.70	Zayıf
.50-.60	Başarısız

Doğruluk ölçüt hesabı için kullanılan bazı parametreler Çizelge 2.4’de ifade edildiği gibidir.

Çizelge 2.4. Doğruluk Ölçüt Formülleri

Duyarlılık (sensitivity,recall) TPR (True Pozitive Rate)	$\frac{TP}{TP + FN}$
Özgünlük (specificity) TNR(True Negative Rate)	$\frac{TN}{FP + TN}$
FNR (False Negative Rate)	$1 - TPR$
FPR (False Pozitive Rate)	$1 - TNR$
F-Score	$\frac{2TP}{2TP + FP + FN}$

3. OPTİMİZASYON ALGORİTMALARI

Optimizasyon, bir sistemde var olan parametrelerin uygun değerlerde kullanılması ile karar verme sürecinin hızlandırılması ve bu parametrelere bağlı olan mevcut çözümler içerisinde en iyi çözümü seçme işlemidir. Bazı problemlerde istenen işlem, parametre değerlerinin en üst ya da en az değerde olması olabilir (minimum maliyet, maksimum kar, minimum hata gibi).

Optimizasyon algoritmaları klasik optimizasyon algoritmaları ve sezgisel optimizasyon algoritmaları olmak üzere iki ana başlıkta incelenmektedir. Klasik optimizasyon algoritmaları, sürekli yada diferansiyel fonksiyonların optimum çözümünü yada maksimum ve minimum değerlerini bulmada yararlıdır. Klasik optimizasyon algoritmaları, yalnızca karmaşık olmayan problemlerde kullanılabilir. Sezgisel optimizasyon algoritmaları ise, çözüm uzayında kesin çözüme yakınsayan ve yaklaşık en iyi çözümü sunan algoritmalarlardır. Sezgisel algoritmalar problemleri çözmenin genel bir yolu olarak düşünülür ve genelde doğadan etkilenerek oluşturulmuştur. Doğa esintili algoritmalar genelde toplu halde hareket eden canlı türlerin davranışlarının analizi sonucu oluşmuştur. Örneğin, yapay arı koloni algoritması, parçacık sürü optimizasyon algoritması, karınca koloni algoritması, ateş böceği algoritması ve balık sürü optimizasyon algoritması doğadan esinlenen algoritmalar bazılarısıdır. Son zamanlarda en popüler olan sürü tabanlı algoritmalar YAK algoritması ve PSO algoritması doğadan esinlenilerek oluşturulan algoritmalar olup bu tez çalışmasında kullanılmıştır.

3.1 Yapay Arı Kolonisi Algoritması

YAK algoritması Karaboga[29] tarafından optimizasyon problemlerini çözmek için geliştirilmiştir. YAK algoritması arıların besin araması, işçi arıların danslarla besinin yerini diğer arılara aktarması ve besin kaynakları tükendiğinde arıların yeni besin kaynağını araması davranışından esinlenilerek tasarlanmış bir algoritmadır. YAK algoritmasında işçi, gözcü ve kâşif olarak adlandırılan üç tip arı vardır. Bu üç arının optimizasyon problemindeki görevleri aşağıda açıklanmıştır.

İşçi Arı Evresi: Komşuluk ilişkilerine dayanarak yiyecek kaynağı aramak ve gözcü arılarla bu bilgileri paylaşmaktan sorumludur. Burada yiyecek kaynağı çözüm olarak adlandırılır. Yiyecek kaynağındaki nektar miktarı ise amaç fonksiyonun

değerini temsil eder. Her işçi arı kovandan ayrıldığında rastgele yönlere ve uzaklıklara gider. Bu evrede yapılan önemli kabullerden biri işçi arıların sayısının toplam yiyecek kaynağı sayısına eşit olmasıdır.

Gözcü Arı Evresi: İşçi arıları kovan içerisinde beklerler ve işçi arıların danslarını izleyerek en iyi yiyecek kaynağını seçerler. Bu evrede yapılan önemli kabullerden biri gözcü arıların sayısının işçi arıların sayısına eşit olmasıdır.

Kâşif Arı Evresi: Kâşif arılar rastgele yeni kaynaklar bulmak için görevlendirilir. Kâşif arıların devreye girmesi için yiyecek kaynakları tükenmiş veya yiyecek kaynakları kötülemeye başlamıştır.

YAK algoritması Çizelge 3.1’de verildiği gibi ifade edilebilir.

Çizelge 3.1. Yapay Arı Kolonisi Algoritma Adımları

1:	Başlangıç evresi
2:	Döngü
3:	İşçi arı evresi
4:	Gözcü arı için olasılıklar hesaplanır
5:	Gözcü arı evresi
6:	Şart (Yiyecek kaynağı kötüleşiyorsa) Kâşif arı evresi
7:	Şimdiye kadar ki en iyi çözümün hafızada tut
8:	Bitir (maksimum döngü sayısı)

Çizelge 3.1’de verilen adımları şu şekilde açıklayabiliriz:

Başlangıç evresinde, Denklem (3.1)’de verilen eşitlikteki gibi rastgele yiyecek kaynağı üretilir.

$$x_{i,j} = x_j^{\min} + rand(0,1)(x_j^{\max} - x_j^{\min}) \quad (3.1)$$

Burada $i = 1, 2, \dots, SN$, $j = 1, 2, \dots, D$ ve SN yiyecek kaynak sayısı ve D ise optimize edilecek parametre sayısıdır. x_j^{\max} , j ’inci parametre için üst sınırı, x_j^{\min} ise j ’inci parametre için alt sınırı ifade eder.

İşçi arı evresinde, Denklem (3.2)’de verilen eşitlikteki gibi yiyecek kaynakları güncellenir.

$$v_{i,j} = x_{i,j} + \varphi(x_{i,j} - x_{k,j}) \quad (3.2)$$

Burada $j \in [1, D]$ aralığında rastgele üretilen bir tamsayıyı temsil eder. φ değeri $[-1, 1]$ aralığında rastgele değer alan bir sayıdır. Mevcut kaynağın j 'inci parametresi ile komşu çözümün j 'inci parametresinin farkları alınarak φ sayısı ile ağırlıklandırılır. $x_{i,j}$ ve $x_{k,j}$ arasındaki farkın azalması çözümlerin birbirine benzer olduğunu göstermektedir.

Gözcü arı evresinde, gözcü arı işçi arının kovanda yaptığı danstan bilgilere ulaşır. Ulaştığı bilgilerden faydalanarak yiyecek kaynaklarının nektar miktarları ile orantılı olasılıksal bir bölge seçer. Olasılıksal bölge seçme işleminde genel olarak Denklem (3.3)'de ifade edilen eşitlik kullanılır.

$$p_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (3.3)$$

Burada $fitness_i$, i 'inci kaynağın kalitesini, SN görevli arı sayısını göstermektedir. p_i değeri $[0, 1]$ aralığında üretilen rastgele sayıdan büyükse gözcü arılarda işçi arılar gibi Denklem (3.2)'de ifade edilen eşitliği kullanarak yiyecek kaynaklarını günceller.

Kâşif arı evresinde, Denklem (3.1) de ifade edildiği gibi yeni kaynaklar üretilir.

3.2 Parçacık Sürü Optimizasyon Algoritması

Parçacık Sürü Optimizasyonu (PSO), temel sezgisel algoritmalardan biridir. PSO algoritmasında parçacıklar problem için bir çözümü temsil eder. Parçacıkların bir araya gelmesi ile popülasyon oluşur. PSO algoritması rastgele üretilen parçacıklarla başlatılır ve parçacıklar güncellenir. Bir parçacık güncellenirken hızına bağlı olarak pozisyonunu güncellemeye çalışır. Denklem (3.4)'de hıza bağlı olarak pozisyon güncelleme işlemi ifade edilmiştir[30].

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1} \quad (3.4)$$

Burada, v_{ij} parametresi hızı ifade etmektedir, x_{ij}^t parametresi ise t 'inci zamanda bulunan ij 'inci parçacığın pozisyonunu göstermektedir. Parçacık güncelleme işlemi küresel en iyi (gbest-PSO) ve yerel en iyi (lbest-PSO) yaklaşımları kullanılarak

güncellenir. Yerel en iyiler içerisinde küresel en iyi değerler seçilir. Denklem (3.5)'de hız güncelleme işlemi ifade edilmiştir.

$$v_{ij}^{t+1} = \omega \times v_{ij}^t + c_1 r_{1j}^t [P_{best,i}^t - x_{ij}^t] + c_2 r_{2j}^t [G_{best} - x_{ij}^t] \quad (3.5)$$


Burada, v_{ij}^t parametresi t 'inci zamanda $j = 1, \dots, n$ boyutunda i 'inci parçacığın hızını vermektedir. $x_{ij}(t)$ parametresi t 'inci zamanda j boyutunda i 'inci parçacığın pozisyonunu vermektedir. c_1 ve c_2 parametreleri pozitif ivme sabitleridir ve dengeyi korumak için gereklidir. c_1 parametresi yerel en iyi değerine (P_{best}) ve c_2 parametresi ise küresel en iyi değerine (G_{best}) çekilmeleri kontrol eder. r_{1j}^t ve r_{2j}^t parametreleri t 'inci zamanda $[0,1]$ arasında tek düze dağılımdan üretilmiş rastgele sayılardır. ω parametresi ise parçacığın hız artışlarının değişimlerini kontrol eder. Yani, parçacığın bir önceki hız artışının yeni hız değerine etkisini kontrol altına alır ve küresel arama ve yerel arama arasındaki dengeyi kurmada rol oynar. $\omega = 0$ ise hız kavramı yok olur ve parçacık eski hız bilgisinden yararlanamadığı için herhangi bir yöne hareket eder. ω parametresi Denklem (3.6)'da verilen eşitlik ile hesaplanır.

$$\omega^t = (\omega_{baslangic} - \omega_{bitis})(t_{max} - t) / t_{max} + \omega_{bitis} \quad (3.6)$$

Burada $\omega_{baslangic}$ parametresi, ω vektörü için başlangıç değerini vermektedir ve ω_{bitis} parametresi ise ω vektörü için son değeri vermektedir. t döngü sayısını t_{max} ise maksimum döngü sayısını vermektedir.

Şekil 3.1'de PSO algoritmasının Denklem (3.4) ve Denklem (3.5) 'de ifade edilen hesaplamalara dayalı arama mekanizması gösterilmektedir.

PSO algoritmasının adımları Çizelge 3.2'de verildiği gibi ifade edilmiştir.



Şekil 3.1. PSO hız güncelleme gösterimi

Çizelge 3.2. Parçacık Sürü Optimizasyon Algoritması


-
- 1: PSO için başlangıç parametrelerini başlat.
 - 2: PSO için başlangıç popülasyonu oluştur.
 - 3: **Döngü**
 - 4: Oluşan her parçacık için uygunluk değerini belirle.
 - 5: **Şart** (Oluşan uygunluk değeri yerel en iyiden daha iyi ise)
 - 6: P_{best} değerine uygunluk değerini ata.
 - 7: Tüm parçacıklar için P_{best} değerinin en iyi değerini G_{best} olarak ayarla.
 - 8: Parçacıkların hızlarını (v_{ij}) güncelle.
 - 9: Parçacıkların pozisyonlarını (x_{ij}) güncelle .
 - 10: **Bitir** (Sonlandırma şartı sağlanana kadar)
-

4. K-MEANS KÜMELEME ALGORİTMASI

Kümeleme, bir veri kümesindeki bilgileri belirli yakınlık kriterine dayanarak gruplara ayırma işlemidir. Kümeleme algoritmaları çalışma alanlarına göre farklı yöntemlere ayrılmıştır. Bu yöntemler temel de hiyerarşik ve hiyerarşik olmayan (bölümlemeli) kümeleme yöntemleri olmak üzere ikiye ayrılır.

Bölümlemeli kümeleme yöntemleri, k giriş parametresini alarak n tane nesneyi k tane kümeye bölen kümeleme yöntemini oluşturur. Bu algoritmaya ait yöntemlerin temelini küme içi benzerlik yüksek, kümeler arası benzerlik az ilkesi oluşturur. Bölümlemeli kümeleme algoritmaları K-Means, K-Medoids ve Bulanık C-Means yöntemleridir[31]. Bölümlemeli kümeleme yöntemleri içerisinde K-Means yöntemi uygulanabilirliği kolay ve hızlı çalıştığı için bu tez çalışmasında tercih edilmiştir.

K-means, popüler bölümlemeli kümeleme algoritmalarından biridir. Kullanımı basit ve etkin olduğunu için birçok alanda tercih edilmiştir. K-means yöntemi her verinin sadece bir kümeye atanmasına izin vermektedir. Şekil 4.1 'de K-means kümeleme yöntemini ifade eden bir görsel verilmiştir. Çizelge 4.1'de ise K-means algoritma adımları ifade edilmiştir.



Şekil 4.1. K-means kümeleme algoritması, (a) Küme sayısının belirlenmesi, (b) Küme merkezlerinin seçilmesi, (c) Küme merkezleri ile veriler arasındaki uzaklıkların hesaplanması, (d) Yeni küme merkezlerinin belirlenmesi

Çizelge 4.1. K-Means Algoritma Adımları

1:	Girdi Parametreleri
2:	k adet kümeye ait küme merkezi
3:	$X = \{x_1, x_2, \dots, x_n\}$ n adet nesne içeren veri seti.
4:	Yöntem
5:	X veri setinden rastgele k adet veriyi başlangıç küme merkezi olarak seçilir.
6:	Veri noktaları ile küme merkezleri arasındaki uzaklıklar hesaplanır.
7:	Her bir veri benzerlik ölçütüne göre kendine en yakın kümeye atanır.
8:	Her bir küme için küme merkezleri yeniden hesaplanır.
9:	Küme merkezleri değişmeyene kadar 5-9 arası adımlar tekrar edilir.

Çizelge 4.1’de verilen algoritma adımlarını şu şekilde ifade edebiliriz:

Algoritmanın ilk üç adımında, girdi parametrelerinden bahsedilmiştir.

Algoritmanın dördüncü ve dokuzuncu adımı arasında, algoritma işleyişi anlatılmıştır.

Algoritmanın beşinci adımında, k adet verinin küme merkezi olarak seçilme işlemi yapılmıştır.

Algoritmanın altıncı adımında, verilerin buldukları küme merkez noktalarına olan uzaklıkları hesaplanmıştır. En popüler uzaklık ölçüt yöntemlerinden biri olan Öklid uzaklık yöntemi Denklem (4.1)’de verildiği gibi hesaplanmaktadır. Algoritma, karesel hata fonksiyonunu azaltan k adet veri merkezini belirlemeye çalışmaktadır.

Algoritmanın yedinci adımında, her bir veri kendine en yakın kümeye atanır.

$$e_i^2 = \sum_{i=1}^{n_k} (x_{i,k} - m_k)^2 \quad (4.1)$$

Burada verilen m_k değeri, k’ıncı küme merkezinin ortalama vektörü olarak Denklem (4.2)’de verildiği gibi ifade edilir.

$$m_k = \frac{1}{n_k} \sum_{i=1}^{n_k} x_{i,k} \quad (4.2)$$

k adet küme için toplam-kare hata ise Denklem (4.3)’de verildiği gibi ifade edilir.

$$E_k^2 = \sum_{k=1}^k e_k^2 \quad (4.3)$$

Algoritmanın sekizinci adımında, her bir küme için küme merkezleri yeniden hesaplanır.

Algoritmanın dokuzuncu adımında, küme merkezlerinin yeri değişmişse 5-9 arası adımlar tekrar edilir. Küme merkezlerinin yeri sabit ise algoritma sonlandırılır.

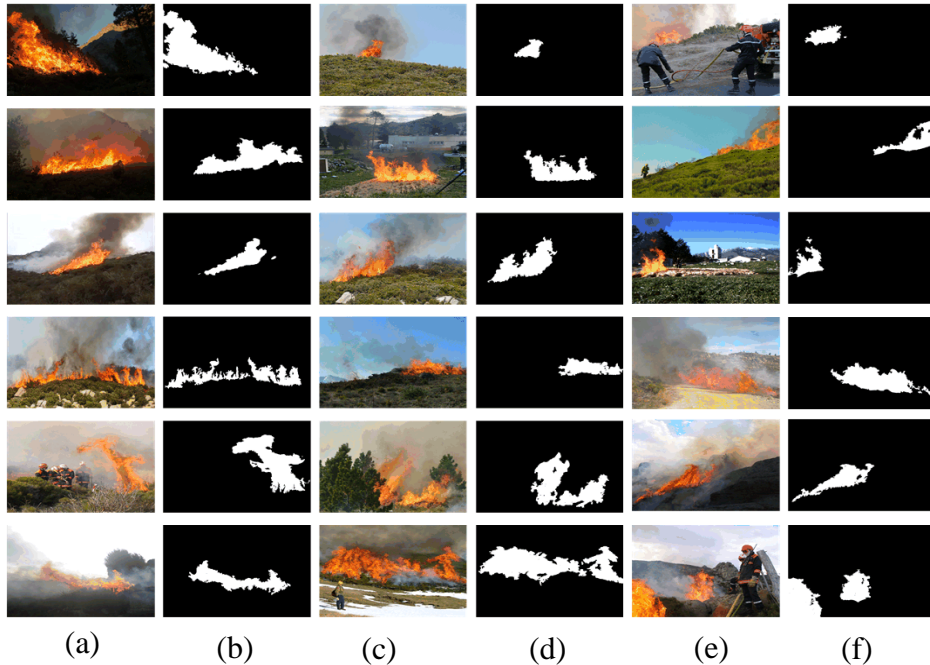
K-means kümeleme algoritmasının amacı, verilen k değeri için E_k^2 değerini minimize eden k kümelerini bulmaktır.

5. ÖNERİLEN YANGIN ALEVİ TESPİT UYGULAMASI

5.1 Kullanılan Veri Seti

Yangın alevi tespit sistemlerinin denenmesi için farklı görüntülerden oluşan veri setlerine ihtiyaç duyulmaktadır. Ortak bir veri setinin varlığı farklı uygulamaların değerlendirilmesi için oldukça önemlidir. İnternet ortamında farklı görüntülerden alınan veriler bir araya getirilerek veri seti oluşturulabilir. Veri seti oluştururken elde edilen görüntülerin ışık yoğunluğu, çekim kalitesi ve gürültü düzeyi gibi bazı etmenler veri setinin kullanılabilirliğini etkileyebilir.

Yapılan çalışmada, paylaşımına açık olan ve orman yangın görüntülerinden oluşan bir veri seti kullanılmıştır. Kullanılan veri seti T.Toulouse [2] ve arkadaşları tarafından oluşturulan ve paylaşımına açık olan COURSICAN FIRE DATABASE (CFDB) isimli veri setidir. Bu veri seti toplam 500 adet orman yangın görüntüsünün bir araya getirilmesi ile oluşturulmuştur. Veri setinde bulunan her görüntüye ait alev bölgeleri ikili görüntüler (binary image) halinde verilmiştir. Bu ikili alev görüntüleri ile önerilen yangın tespit uygulaması sonucu elde edilen ikili alev görüntülerinin karşılaştırılması yapılmıştır. Şekil 5.1’de veri seti içerisinde bulunan örnek görüntüler verilmiştir.



Şekil 5.1. Veri seti içinden örnek görüntüler. (a)-(c)-(e) Orijinal görüntüler, (b)-(d)-(f) Gerçek ikili alev görüntüleri

5.2 Önerilen Yöntem


Bu tez çalışmasında, alev ve alev olmayan kesitlerden elde edilen özellik matrisi ile doğrusal çarpım yapan bir dönüşüm matrisi kullanılarak yeni renk uzayı tasarlanmıştır. Dönüşüm matrisinin ilk değerleri rastgele üretilmiş ve optimum ağırlıkların bulunması için YAK algoritması kullanılmıştır. YAK algoritmasında maliyet fonksiyonu hesaplanmadan önce Denklem (5.1)'de ifade edilen eşitlik kullanılarak Y değeri elde edilmiştir.

$$Y = X \times W \quad (5.1)$$


Burada W dönüşüm matrisini, X ise RGB uzayındaki özellik matrisini temsil etmektedir. W dönüşüm matrisi 3×3 boyutunda bir matristir. Bu boyutta belirlenmesinin amacı dönüşüm yapılacak görüntünün boyutunu korumak içindir. Y matrisi Denklem (5.1) de verilen eşitliğe göre elde edildikten sonra, güncellenmiş yiyecek kaynağı için maliyet hesaplaması yapılmıştır. Maliyet hesabı için Y matrisi Maliyet fonksiyonuna gönderilir. Maliyet fonksiyonunun hata değerini hesaplamak için K-means kümeleme algoritması kullanılır. Şekil 5.2'de önerilen sistemin akış diyagramı verilmiştir.

5.2.1 Özellik Matrisinin Oluşturulması


Önerilen yangın tespit sisteminde, alev ve alev olmayan görüntü verilerinden oluşan özellik matrisine ihtiyaç duyulmaktadır. Özellik matrisini oluşturabilmek için veri setindeki yangın görüntülerinden kesitler alınmıştır. Veri setinden rastgele seçilen görüntüler üzerinde 100 adet yangın ve yangın olmayan kesitler alınmıştır. Farklı görüntülerden kesitler alınmasının sebebi tasarlanan yeni renk uzayının renk farklılıklarını daha iyi algılayabilmesi içindir. Seçilen yangın ve yangın olmayan kesitler $25 \times 25 \times 3$ boyutundadır. Bu boyutta seçilmesinin özel bir sebebi bulunmamaktadır. 25×25 boyutunda kesit almak daha kolay olduğu için kesitler bu boyutta seçilmiştir. Şekil 5.3 ve 5.4 'de sırası ile alev ve alev olmayan kesitlerden alınan görüntüler verilmiştir. Yangın görüntülerinden alınan bu kesitlerin piksel renk değerleri özellik matrisinde birleştirilmiştir. Özellik matrisinin ilk yarısı alev kesitlerinden (625×3) ve ikinci yarısı alev olmayan kesitlerden (625×3) alınan piksel renk değerleri ile oluşturulmuştur. Sonuçta 1250×3 boyutunda bir matris elde edilmiştir.



Şekil 5.2. Önerilen Sistem Akış Şeması



Şekil 5.3. Alev kesiti



Şekil 5.4. Alev olmayan kesit

5.2.2 Hata Hesaplama Fonksiyonu

YAK algoritmasında pozisyon değeri olarak hesaplanan W değerinden sonra, Denklem (5.1) kullanılarak Y değeri hesaplanır. Y değeri K-means kümeleme algoritmasına gönderilir. Burada amaç Y matrisinin ilk yarısını oluşturan alev kesitlerinin ve ikinci yarısını oluşturan alev olmayan kesitlerin kümelenmesinde ne kadar hata yapıldığını bulmaktır. Yani Y matrisinin ilk ve ikinci yarısında kümeleme yapılırken piksel renk değerlerinde ne kadar hata yapıldığı hesaplanmıştır. Başka bir deyişle, elde edilen yeni renk uzayında (Y) herhangi bir pozisyon değişikliği olup olmadığını ölçmek için k-means algoritması kullanılmıştır.

Dönüştürülmüş özellik matrisi (Y)'nin üç kanalı için ayrı ayrı K-means algoritması işletilir. K-means algoritmasında veri noktaları ile küme merkezleri

arasındaki uzaklık hesaplanırken Denklem (5.2)'de ifade edilen Öklid uzaklığı kullanılmıştır.

$$Dist = \sqrt{\sum_{i=1}^m (Y - c_{ik})^2} \quad (5.2)$$

Burada, c_{ik} i 'inci kümenin merkezini ifade etmektedir. Y değeri ise dönüştürülmüş özellik matrisini ifade etmektedir.

Her renk kanalı için Denklem (5.3) ve (5.4) de ifade edildiği gibi e_1 ve e_2 hata değerleri hesaplanmıştır.

$$e_1 = \sum_{i=1}^{k=625} e_i \quad (5.3)$$

$$e_2 = \sum_{i=626}^{k=1250} e_i \quad (5.4)$$

e_1 değeri dönüştürülmüş özellik matrisin ilk yarısında ve e_2 değeri dönüştürülmüş özellik matrisinin ikinci yarısında yanlış sınıflandırılmış piksel sayısını temsil etmektedir.

Üç kanal için ayrı ayrı hesaplanan e_1 ve e_2 değerleri Denklem (5.5) de verildiği gibi toplanır.

$$E = \sum_{i=1}^3 e_{1i} + e_{2i} \quad (5.5)$$

Burada E değeri, yanlış sınıflandırılmış toplam piksellerin sayısıdır. e_{1i} i . kanal için dönüştürülmüş özellik matrisinin ilk yarısındaki yanlış sınıflandırılmış piksellerin hata değeri ve e_{2i} i . kanal için dönüştürülmüş özellik matrisinin ikinci yarısındaki yanlış sınıflandırılmış piksellerin hata değerini temsil etmektedir.

E değeri, dönüşüm matrisi (W) için uygun olmayan ağırlıkların sonucunda oluşan doğrusal dönüşümün hatalı çalışması nedeniyle K-means ile kümeleme hatasını ölçer. Veri setinde renklerin daha iyi ayrımının yapılabilmesi için E değeri minimize edilmelidir. E değerinin minimize edilmesi ve dönüşüm matrisindeki 9 adet özelliği optimize etmek için YAK algoritması devreye girer.

5.2.3 Önerilen Yapay Arı Kolonisi Algoritma Adımları

- Adım-1.* Başlangıç parametrelerini başlat (Çizelge 5.1. 'de gösterilmiştir.)
- Adım-2.* İlk popülasyonu rastgele oluştur. (İlk popülasyonu oluşturduktan sonra önerilen Maliyet fonksiyonunu ile maliyetleri hesapla (Çizelge 5.1.'de önerilen maliyet fonksiyonu gösterilmiştir.))
- Adım-3.* İşçi Arı evresini başlat
- i.* Bu evrede komşuluk ilişkilerine dayanarak yiyecek kaynaklarını araştır.
 - ii.* Yeni yiyecek kaynağı için maliyet fonksiyonunu hesapla.
 - iii.* Bulduğun yiyecek kaynağı önceki yiyecek kaynağından daha iyi ise yiyecek kaynağı pozisyonunu güncelle. (W güncelle)
 - iv.* Yiyecek kaynağın daha iyi değilse terk etme sayacını 1 arttır.
- Adım-4.* Seçim olasılıklarını hesapla
- Adım-5.* Gözcü Arı evresini başlat
- i.* Seçim olasılıklarına göre yiyecek kaynaklarını belirle (Denklem 3.3'de ifade edildiği gibi)
 - ii.* Komşuluk ilişkilerine dayanarak en iyi yiyecek kaynaklarına yönel.
 - iii.* Yeni yiyecek kaynağı için maliyet fonksiyonunu hesapla.
 - iv.* Bulduğun yiyecek kaynağı önceki yiyecek kaynağından daha iyi ise yiyecek kaynağı pozisyonunu güncelle. (W güncelle)
 - v.* Yiyecek kaynağın daha iyi değilse terk etme sayacını 1 arttır.
- Adım-6.* Kaşif arı evresi
- i.* Eğer terk etme sayacı limit değerinden büyükse
 1. Her şeyi unut ve yeni popülasyon oluştur.
 2. Terk etme sayacını sıfırla
- Adım-7.* En iyi çözümü ve pozisyonu kaydet ve çık.

5.2.4 Görüntü Ön İşleme

Bu bölümde, veri setinde bulunan görüntülerin yoğunluk ve kontrast değerlerinin ayarlanması yapılmıştır. Böylelikle, görüntüler yeni uzaya dönüştürülmeden önce görünümü iyileşecek ve renk değerleri daha belirgin olacaktır. Görüntü ön işleme tabi tutulan test görüntüleri alev tespit sisteminin performansını arttırmaya yardımcı olmaktadır.

Kontrast ayarı sırasında, orijinal görüntüdeki her piksel için yoğunluk değeri bir transfer fonksiyonu kullanılarak dönüştürülür. Bu çalışmada, gamma kontrastının ayarlanması yapılmıştır. Gamma değeri veri setinde bulunan 100 görüntü üzerinde denenerek her renk kanalı için ayrı ayrı bulunmuştur. Gama değerleri R kanalı için 1.5 değerini, G kanalı için 0.9 değerini ve B kanalı için 1.5 değerini almıştır. R kanalı ve B kanalının baskın çıkması veri setinde alevin bu renk kanalları üzerinde yoğun dağılım gösterdiğini ifade etmektedir. Bulunan gamma değerleri Çizelge 5.1’de verilmiştir. Şekil 5.5’de görüntü ön iyileştirme işlemine tabi tutulmuş görüntüler verilmiştir.



Şekil 5.5. (a) Veri setinde bulunan orijinal görüntüler, (b) (a)'da verilen görüntülere gamma düzeltilmesi uygulanmış görüntüler

5.2.5 OTSU Eşik Belirleme Yöntemi

Görüntü ön iyileştirmeye tabi tutulan test görüntüsü, YAK algoritması tarafından geliştirilen dönüşüm matrisini kullanılarak yeni renk uzayına dönüştürülür. Elde edilen görüntüleri veri setinde bulunan gerçek yangın görüntüleri ile kıyaslayabilmek için ikili görüntülere dönüştürmek gerekir.

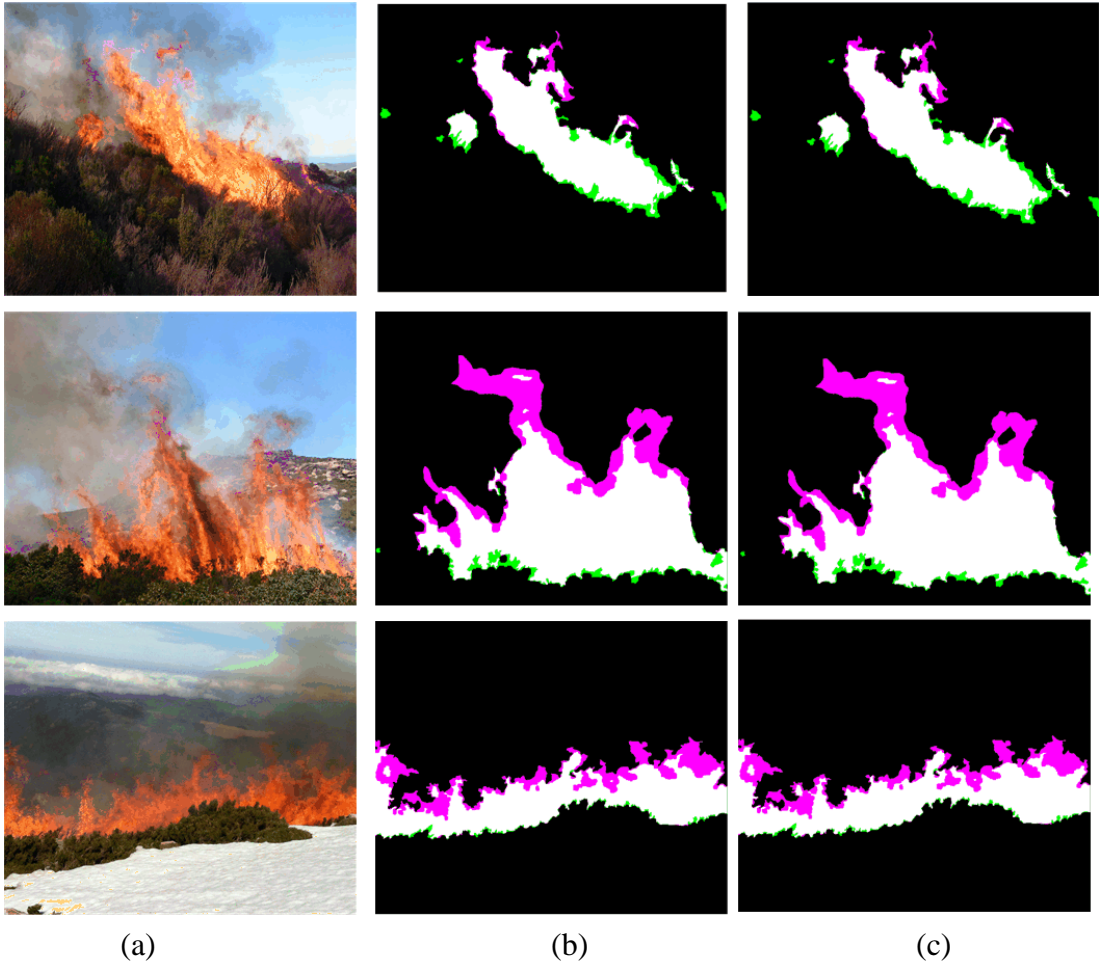
Ön işleme tabi tutulmuş görüntü için Otsu yöntemi ile eşik değeri elde edilir. Otsu algoritmasının seçilme nedeni her görüntü için otomatik eşik değerini belirlemesinden dolayıdır. Yeni renk uzayına dönüştürülen görüntü gri düzeye getirilir ve sonra da gri görüntüler üzerinde uygulanan Otsu yöntemi kullanılır. Böylelikle bölütlenmiş ikili görüntüler elde edilmiş olur. Şekil 5.6'da Otsu sonuçları gösterilmiştir.



Şekil 5.6. (a) Orjinal görüntüler, (b) Otsu yöntemi sonucu oluşan ikili bölütlenmiş görüntüler

5.2.6 Benzerlik Ölçütleri

Otsu yöntemi kullanılarak elde edilen ikili görüntüler ile veri setindeki diğer görüntüleri kıyaslamak için benzerlik ölçüt yöntemleri kullanılmıştır. Jaccard ve Dice benzerlik ölçütleri kullanılarak bölütlenmiş görüntüler ile gerçek görüntüler arasındaki benzerlik oranı ölçülmüştür. Jaccard ve Dice benzerlik ölçütleri kullanımı basit ve yazılımı kolay olduğu için seçilmiştir. İki ayrı benzerlik ölçütünde denenmesinin sebebi ekstra kontrol sağlanması içindir. Veri setinde bulunan 500 görüntü için benzerlik oranları belirlenmiş ve her iki özellik için ortalama benzerlik değerleri hesaplanmıştır. Şekil 5.7’de Jaccard ve Dice benzerlik sonucu gösterilmiştir. Pembe renkli kısımlar gerçek ikili alev görüntülerine göre eksik alan bulunduğunu, yeşil renkli kısımlar ise fazla alan bulunduğunu göstermektedir.



Şekil 5.7. Jaccard ve Dice benzerlik ölçütü. (a) Orjinal yangın görüntüleri, (b) Jaccard benzerlik sonucu, (c) Dice benzerlik sonucu

Çizelge 5.1. Parametre ve Değerleri

YAK için başlangıç Parametreleri

Parametreler	Değerler
Karar değişkenlerin sayısı	9
Karar değişkenlerin alt sınırı	-5
Karar değişkenlerin üst sınırı	+5
Maksimum iterasyon sayısı	50
Koloni sayısı	10
Gözlemci arı sayısı	10
Hızlandırma katsayısının üst sınırı	1

YAK için Maliyet Fonksiyonu

$$Y = \text{Özellik Matrisi}(\mathbf{X}) * \text{Dönüşüm Matrisi}(\mathbf{W}) \text{ (Yiycek Pozisyonu)}$$
$$E = K\text{-means}(Y)$$

Diğer Parametre Değerleri

Gamma(R kanalı için)	1.5
Gamma(G kanalı için)	0.9
Gamma(B kanalı için)	1.5

6. SONUÇLAR VE DEĞERLENDİRME


Önerilen yöntem sonucunda optimum dönüşüm matrisi elde edilmiştir. CFDB isimli [2] veri seti üzerinden elde edilen dönüşüm matrisi Denklem (6.1) de ifade edildiği gibi bulunmuştur.

$$W = \begin{pmatrix} -1.4605 & 2.3773 & 2.3020 \\ 0.8842 & -2.0370 & -3.5807 \\ 1.4373 & 0.2414 & -4.5664 \end{pmatrix} \quad (6.1)$$

Veri seti içerisinde bulunan 500 görüntüye ait her renk kanalı için *gamma* dönüşümü uygulanmıştır. Veri setindeki görüntülere görüntü ön iyileştirilmesi yapıldıktan sonra Denklem (6.1) de ifade edilen *W* (dönüşüm matrisi) uygulanmıştır. Dönüşüm matrisi uygulanan görüntüler üzerinde Otsu yöntemi uygulandıktan sonra ikili görüntülere dönüştürülmüştür. Bölütlenmiş ikili görüntüler veri seti içerisindeki gerçek ikili alev görüntüler ile Jaccard ve Dice benzerlik ölçütü kullanılarak kıyaslanmıştır. Gerçek ve bölütlenmiş ikili görüntülere ait ilk 10 görüntü için görsel sonuçlar Şekil 6.1’de gösterildiği gibi bulunmuştur. Şekil 6.1’de verilen görsel benzerlik ölçütü sonuçları için hesaplanan sayısal sonuçlar Çizelge 6.1’de verilmiştir. Jaccard ve Dice benzerlik ölçütlerinin 1’e yaklaşması bölütlenmiş ikili görüntünün başarılı olduğunu göstermektedir.

Çizelge 6.1. Jaccard ve Dice benzerlik ölçüt sonuçları (10 görüntü için)

Görüntüler	Jaccard İndeksi	Dice İndeksi
Görüntü1	0,81	0,89
Görüntü2	0,72	0,84
Görüntü3	0,70	0,82
Görüntü4	0,57	0,72
Görüntü5	0,83	0,91
Görüntü6	0,85	0,92
Görüntü7	0,98	0,99
Görüntü8	0,80	0,89
Görüntü9	0,62	0,76
Görüntü10	0,86	0,92
Ortalama Benzerlik	0,77	0,87



Şekil 6.1. Jaccard ve Dice benzerlik ölçütleri. (a) RGB görüntü, (b) Gerçek ikili görüntü, (c) Bölütlenmiş ikili görüntü, (d) Jaccard benzerlik sonucu, (e) Dice benzerlik sonucu

6.1 Sistemin Başarı Ölçütünün Hesaplanması

T.Toulouse ve arkadaşları [2] tarafından paylaşımına açık veri seti üzerinde Khatami ve arkadaşları [32] tarafından önerilen sistem çalıştırılmıştır. Khatami ve arkadaşları [32] çalışmalarında PSO kullanarak W güncelleme işlemi yapmıştır. Veri seti üzerinde PSO ile W güncelleme işlemi uygulandığında Denklem (6.2)'de verilen W değeri bulunmuştur.

$$W = \begin{pmatrix} 1.0020 & 5.8966 & 1.8242 \\ -1.3185 & -5.5528 & -3.0578 \\ -8.3643 & -9.0642 & -4.8726 \end{pmatrix} \quad (6.2)$$

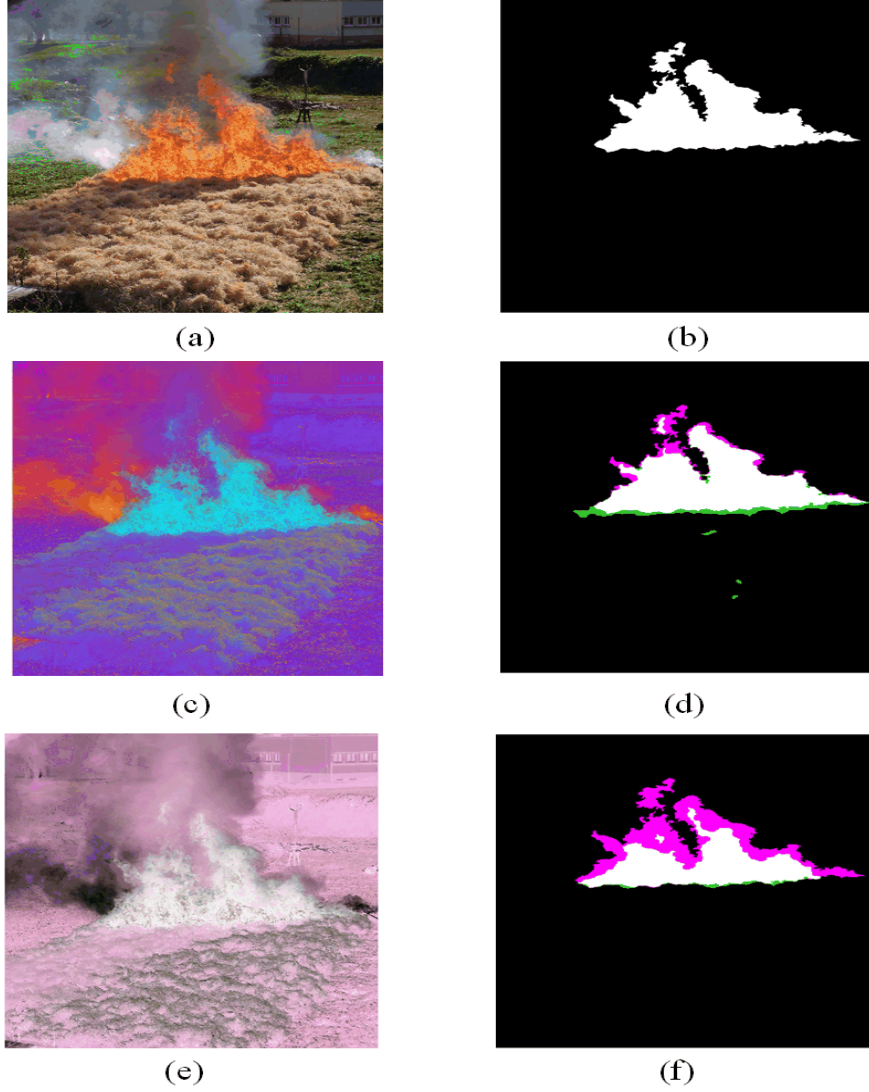
Denklem (6.1)'de verilen W değeri 500 görüntü üzerinde denenerak Denklem (6.2)'de verilen W değerinden alınan sonuçlarla kıyaslanmıştır. Her iki W değerinden alınan sonuçlar için Jaccard ve Dice benzerlik ölçütü hesaplanmıştır. Her iki yöntem içinde 0.5'ten küçük olan değerler başarısız kabul edilmiştir. Kıyaslama verileri Çizelge 6.2'de gösterildiği gibidir.

Çizelge 6.2. 500 görüntü için ortalama Jaccard ve Dice benzerlik sonucu

Görüntüler	YAK Algoritması	PSO Algoritması	Toplam Görüntü Sayısı
Ortalama Jaccard İndeksi	0.76	0.40	500
Ortalama Dice İndeksi	0.85	0.50	500
0.5'ten büyük Jaccard İndeks Sayısı	460	300	500
0.5 ve 0.5'ten düşük Jaccard İndeks Sayısı	40	200	500
0.5'ten büyük Dice İndeks Sayısı	482	226	500
0.5 ve 0.5'ten düşük Dice İndeks Sayısı	18	274	500

Veri seti içerisinde rastgele alınan bir görüntü üzerine Denklem (6.1) ve Denklem (6.2)'de verilen W değerleri ayrı ayrı uygulanmıştır. Uygulama sonucunda YAK algoritması ile elde edilen dönüşüm matrisi Denklem (6.1) ve PSO algoritması ile elde edilen dönüşüm matrisi Denklem (6.2) sonrası oluşan bölütlenmiş ikili



görüntüler Şekil 6.2.d ve Şekil 6.2.f'de verilmiştir. Şekil 6.3'de ise Şekil 6.2.a, Şekil 6.2.c ve Şekil 6.2.e de verilen renk uzayları için alev ve alev olmayan piksellere ait renk dağılımları verilmiştir.




Şekil 6.2. Renk uzayları ve benzerlik ölçüt sonucu. (a) RGB görüntü, (b) Gerçek ikili alev görüntüsü, (c) ABC ile elde edilen renk uzayı, (d) (c) Görüntüsü için Otsu yöntemi sonrası jaccard benzerlik sonucu, (e) PSO ile elde edilen renk uzayı, (f) (e) Görüntüsü için Otsu sonrası Jaccard benzerlik sonucu




(a)



(b)




(c)



Şekil 6.3. Renk uzaylarında alev ve alev olmayan piksellerin renk dağılımı. (a) RGB görüntü ve renk dağılımı, (b) ABC ile elde edilen renk uzayındaki görüntü ve renk dağılımı, (c) PSO ile elde edilen renk uzayındaki görüntü ve renk dağılımı

Şekil 6.3’de verilen 3D görüntülerden de anlaşılacağı gibi YAK algoritması kullanılarak modellenen renk uzayı, PSO algoritması kullanılarak modellenen renk uzayına göre yangın ve yangın olmayan pikselleri daha iyi ayırt edebilmiştir. RGB renk uzayındaki görüntüde ise alev ve alev olmayan renk piksellerinin iç içe bir yapıda olduğu gözlemlenmiştir. Renk dağılımları dikkatle incelendiğinde de RGB uzayında alev ve alev olmayan renk piksellerini ayırma işleminin daha zor olduğu sonucuna varılabilir.

Denklem (6.1) ve (6.2)’de verilen W değerleri görüntüler üzerine uygulandıktan sonra veri seti içerisinde bulunan 500 görüntü üzerinde istatistiksel doğruluk hesaplaması yapılmıştır. Doğruluk ölçütü olarak TPR , TNR , FNR , FPR ve F -score doğruluk ölçütleri kullanılmıştır. Alıcı işlem karakteristiği (ROC) kullanarak da iki W sonucu için başarı ölçütleri kıyaslanmıştır. ROC eğrisinin altında kalan alan (AUC) her iki sistem içinde hesaplanmış ve sonuçlar Şekil 6.4’de gösterilmiştir.




Şekil 6.4. Alıcı işlem karakteristiği ile ABC ve PSO sonuçlarının karşılaştırılması

Alicı işlem karakteristiği eğrisi altında kalan alan (AUC) için doğruluk ölçütü YAK algoritması için 0.98 olarak PSO algoritması için 0.86 olarak hesaplanmıştır.

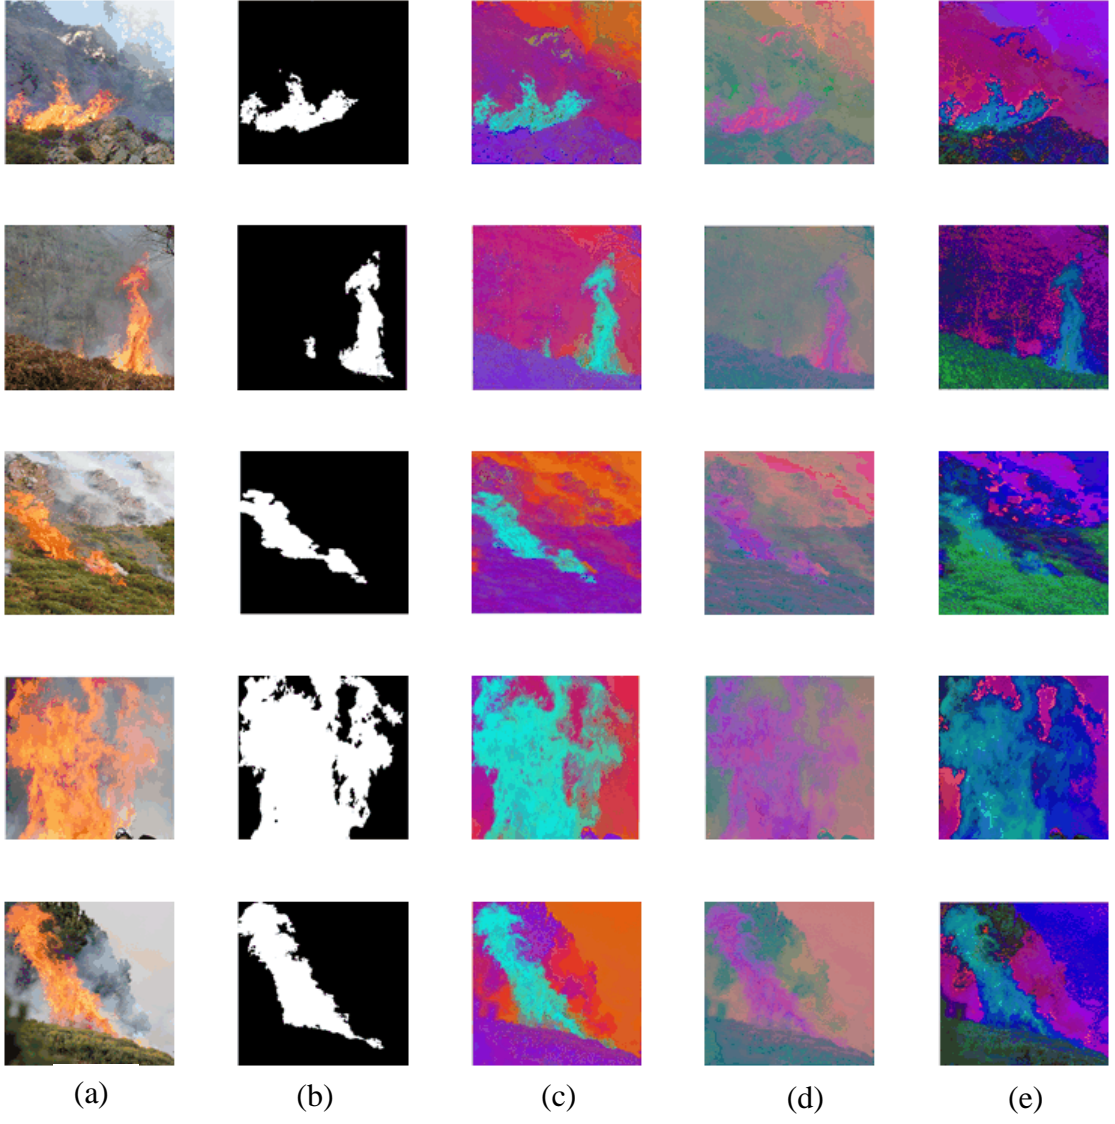
YAK ve PSO algoritması ile elde edilen W değerleri veri seti içerisindeki Şekil 6.5’de verilen beş görüntü üzerinde denemiştir. Şekil 6.5’de verilen görüntülerin RGB uzayındaki ikili alev görüntüleri ile YAK ve PSO kullanarak oluşturulan dönüşüm matrisleri yardımı ile elde edilen ikili bölütlenmiş görüntüleri verilmiştir. Şekil 6.5’de verilen görüntüler için hesaplanan doğruluk ölçütleri ise Çizelge 6.3’de verilmiştir. Çizelge 6.3’deki sonuçlar incelendiğinde, YAK algoritmasının yangını bulmada PSO algoritmasına göre daha iyi W güncellemesi yaptığı gözlemlenmiştir. Alev görüntüsünün farklı renk uzaylarındaki görünümü ise Şekil 6.6’da verilmiştir.

Çizelge 6.3. Veri seti üzerinde hesaplanan doğruluk ölçüt hesaplama sonuçları

Görüntüler	Resim1	Resim2	Resim3	Resim4	Resim5
Toplam Alev Piksel Sayısı	3289862	2390033	131987	1491508	6176774
Toplam Alev Olmayan Piksel sayısı	361722	291823	16392	2872340	1645946
TP (YAK)	347265	272567	15951	2748878	1518991
TP (PSO)	20944	21211	9320	595241	532675
FN (YAK)	14457	19256	441	123462	126955
FN (PSO)	340778	270612	7072	2277099	1113271
TPR (YAK)	0.96	0.93	0.97	0.95	0.92
TPR (PSO)	0.05	0.072	0.56	0.20	0.32
F-Score (YAK)	0.95	0.94	0.95	0.96	0.95
F-Score (PSO)	0.10	0.13	0.72	0.34	0.48



Şekil 6.5. Veri seti içerisinde rastgele seçilen 5 görüntü için uygulama sonuçları. (a) Orjinal görüntüler, (b) Veri seti içerisinde bölütlenmiş gerçek ikili görüntüler, (c) Denklem (6.1)'de verilen dönüşüm matrisi uygulanmış görüntü, (d) (c) sonrası Otsu yöntemi uygulanmış ikili görüntü, (e) Denklem (6.2)'de verilen dönüşüm matrisi uygulanmış görüntü (f) (e) sonrası Otsu yöntemi uygulanmış ikili görüntü



Şekil 6.6. Veri setinin farklı renk uzaylarında görünümü. a) RGB uzayında ki görüntü, b) İkili bölütlenmiş alev görüntüsü, c) ABC uzayındaki görüntü, d) YCbCr renk uzayındaki görüntü, e) HSI renk uzayındaki görüntü

7. KAYNAKLAR

- [1] W. T. Sommers, R. A. Loehman, and C. C. Hardy, *Wildland fire emissions, carbon, and climate: Science overview and knowledge needs*, **Forest Ecology and Management**, vol. 317, pp. 1–8, 2014.
- [2] T. Toulouse, L. Rossi, A. Campana, T. Celik, and M. A. Akhloufi, *Computer vision for wildfire research: An evolving image dataset for processing and analysis*, **Fire Safety Journal**, vol. 92, no. June, pp. 188–194, 2017.
- [3] K. Nakau, M. Fukuda, K. Kushida, H. Hayasaka, K. Kimura, H. Tani, *Forest Fire Detection Based on MODIS Satellite Imagery, and Comparison of NOAA Satellite Imagery with Fire Fighters Information*, 2006 pp. 18–23, 2006.
- [4] A. E. Çetin , *Video fire detection - Review*, **Digital Signal Processing: A Review Journal**, vol. 23, no. 6, pp. 1827–1843, 2013.
- [5] J. Lloret, M. Garcia, D. Bri, and S. Sendra, *A wireless sensor network deployment for rural and forest fire detection and verification*, **Sensors**, vol. 9, no. 11, pp. 8722–8747, 2009.
- [6] B. Son, Y. Her, and J. Kim, *A design and implementation of forest-fires surveillance system based on wireless sensor networks for South Korea mountains*, **International Journal of Computer Science and Network Security (IJCSNS)**, vol. 6, no. 9, pp. 124–130, 2006.
- [7] T. Çelik and H. Demirel, *Fire detection in video sequences using a generic color model*, **Fire Safety Journal**, vol. 44, no. 2, pp. 147–158, 2009.
- [8] T. Celik, H. Demirel, H. Ozkaramanli, and M. Uyguroglu, *Fire detection using statistical color model in video sequences*”, **Journal of Visual Communication and Image Representation**, vol. 18, no. 2, pp. 176–185, 2007.
- [9] N. Izzati, N. Anis, M. Razali, and H. Achmad, *Fire Recognition Using Rgb And Ycbcr Color Space*, **ARNP Journal**, vol. 10, no. 21, pp. 9786–9790, 2015.
- [10] I. Khan, S. K. Singh, I. Ali, and M. Tech, *Fire Detection Using Image Processing Based on Color Analysis*, **IRJET**, vol.3, no. 06, 2016.
- [11] P. Patel and S. Tiwari, *Flame Detection using Image Processing Techniques*, **International Journal of Computer Applications**, vol. 58, no. 18, pp. 13–16, 2012.

- [12] B. U. Töreyn, "*Dalgacık Dönüşümüyle Sıkıştırılmış Videoda Hareketli Bölge Tespiti*" Yüksek lisans Tezi, Bilkent Üniversitesi, Türkiye, 2003
- [13] B. U. Töreyn, Y. Dedeoğlu, U. Güdükbay, and A. E. Çetin, *Computer vision based method for real-time fire and flame detection*, **Pattern Recognition Letters**, vol. 27, no. 1, pp. 49–58, 2006.
- [14] B.U.Töreyn, Y.Dedeoglu, A. E. Cetin, "Flame Detection in Video Using Hidden Markov Models" , IEEE International Conference on, Genova, 2005.
- [15] 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**, vol. 73, pp. 91–101, 2015.
- [16] X. B. Li, Y. Hua, and N. Xia, *Fire detecting technology based on dynamic textures*, **Procedia Engineering**, vol. 52, pp. 186–195, 2013.
- [17] S. Fazekas, T. Amiaz, D. Chetverikov, and N. Kiryati, *Dynamic texture detection based on motion analysis*, **International Journal of Computer Vision**, vol. 82, no. 1, pp. 48–63, 2009.
- [18] S. Fazekas and D. Chetverikov, *Analysis and performance evaluation of optical flow features for dynamic texture recognition*, **Image Commun.**, vol. 22, no. 7–8, pp. 680–691, 2007.
- [19] A. Stadler, T. Windisch, and K. Diepold, *Comparison of intensity flickering features for video based flame detection algorithms*, **Fire Safety Journal**, vol. 66, pp. 1–7, 2014.
- [20] J. Chen, Y. He, and J. Wang, *Multi-feature fusion based fast video flame detection*, **Building and Environment**, vol. 45, no. 5, pp. 1113–1122, 2010.
- [21] F. Erden ,B.U.Töreyn, B.B.Soyer, I.Inac, O.Gunay, K.Kose, A.E.Cetin, *Wavelet based flame detection using differential PIR sensors*, SIU, 2012 20th, pp. 3–6, 2012.
- [22] B. Toptas and D. Hanbay, *HSI Renk Uzayı Kullanarak Alev Tespiti*, IDAP, Malatya, Turkey, pp. 1–5, 2017.
- [23] R. Chi, Z.-M. Lu, and Q.-G. Ji, *Real-time multi-feature based fire flame detection in video*, **IET Image Processing**, vol. 11, no. 1, pp. 31–37, 2017.
- [24] A. M. Lopes and J. A. T. Machado, *Computational comparison and pattern visualization of forest fires*, **Chaos, Solitons and Fractals**, vol. 102, pp. 407–413, 2017.

- [25] R. C. Gonzalez and R. P. Woods, *Derivation of HSI-to-RGB and RGB-to HSI Conversion Equations*, **Color Image Processing**, pp. 229–237, 1992.
- [26] Gabor Szedo, *Color-Space Converter : YCrCb to RGB*, Xilinx, 2007.
- [27] D. Liu and J. Yu, “Otsu method and K-means,” **International Conference on Hybrid Intelligent Systems**, vol. 1, no. 2, pp. 344–349, 2009.
- [28] S. Jimenez, F. A. Gonzalez, and A. Gelbukh, *Mathematical properties of soft cardinality: Enhancing Jaccard, Dice and cosine similarity measures with element-wise distance*, **Information Sciences**, vol. 367–368, pp. 373–389, 2016.
- [29] D. Karaboga and B. Akay, *A modified Artificial Bee Colony (ABC) algorithm for constrained optimization problems*, **Applied Soft Computing Journal**, vol. 11, no. 3, pp. 3021–3031, 2011.
- [30] C. Li, R. Zhai, H. Liu, Y. Yang, and H. Wu, *Optimization of a heliostat field layout using hybrid PSO-GA algorithm*, **Applied Thermal Engineering**, vol. 128, pp. 33–41, 2018.
- [31] M. Işık, A. Y. Çamurcu, K-means, k-medoids ve bulanık c-means algoritmalarının uygulamalı olarak performanslarının tespiti, *İTÜ Fen Bilimleri Dergisi*, pp. 31–45, 2007.
- [32] A. Khatami, S. Mirghasemi, A. Khosravi, C. P. Lim, and S. Nahavandi, *A new PSO-based approach to fire flame detection using K-Medoids clustering*, **Expert Systems with Applications**, vol. 68, pp. 69–80, 2017.

ÖZGEÇMİŞ

Adı Soyadı: Buket TOPTAŞ

Doğum Yeri ve Tarihi: Sivas-1991

Adres: Çöşnük Mahallesi, Defne Sokak Battalgazi/Malatya

E-Posta: buketecrinozturk@gmail.com

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

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

B. Toptas, D.Hanbay, “HSI Renk Uzayı Kullanarak Alev Tespiti”, International Artificial Intelligence And Data Processing Symposium (IDAP), 2017.

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