



# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## İnsansız Hava Araçları ile Orman Yangınlarının Tespitinde Görüntü İşleme ve Yapay Zekâ Tabanlı Otomatik Bir Model

 Mustafa Alptekin ENGİN<sup>a</sup>,  Serhan KÖKHAN<sup>b,\*</sup>

<sup>a</sup> Elektrik – Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Bayburt Üniversitesi, Bayburt, TÜRKİYE

<sup>b</sup> Yönetim Bilişim Sistemleri Bölümü, Uygulamalı Bilimler Fakültesi, Bayburt Üniversitesi, Bayburt, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: serhankokhan@bayburt.edu.tr

DOI: 10.29130/dubited.1103375

### ÖZ

Nefes almak için gereksinim duyduğumuz oksijenin büyük bir kısmı, hayatta kalabilmemiz için hayati öneme sahip olan ormanlar tarafından üretilir. Bu yüzden ormanları korumak, içinde yaşadığımız yüzyılın en önemli konu başlıklarından bir tanesidir. Dünyanın farklı coğrafyalarında (ABD, Avustralya vb.) her yıl meydana gelen orman yangınları ciddi ekonomik kayba neden olmakta ve ekosistemi olumsuz olarak etkilemektedir. Ateşin çeşitli renk, şekil ve doku özelliklerine sahip olması orman yangınlarının uzaktan algılanmasını zorlaştırmaktadır. Yapılan bu çalışmada orman yangınlarının tespitinde insansız hava araçları vasıtasıyla tamamen otomatik bir sistem önerilmiştir. Ormanlık arazinin tespitinde uydu görüntüleri üzerine görüntü bölütleme yöntemi kullanılmış, insansız hava aracının tespit edilen bölgeyi en kısa zamanda ve en az görüntü ile kontrol edebilmesi için de küme kaplama yöntemi kullanılmıştır. Daha sonra elde edilen imgeler üretilen yapay zekâyâ dayalı ateş algılama modeline göre değerlendirilip başlangıç ve ileri aşamadaki yangınlar tespit edilmiş ve konumları elde edilmiştir. Sonuç olarak, yapılan çalışmada yaklaşık %97,51 değerinde doğrulukla yangın tespit eden bir erken uyarı modeli önerilmektedir.

**Anahtar Kelimeler:** Yangın Algılama, Görüntü İşleme, Küme Kaplama, Yapay Zekâ

## An Automatic Model Based on Image Processing and Artificial Intelligence via Unmanned Aerial Vehicles in Detection of Forest Fires

### ABSTRACT

Most of the oxygen we need to breathe is produced by forests, which are vital to our survival. Therefore, protecting forests is one of the most critical issues of the century. Forest fires that occur every year in different geographies of the World (USA, Australia etc.) cause severe economic loss and negatively affect the ecosystem. The fact that fire has various colors, shapes, and textures makes it challenging to detect forest fires from a distance. In this study, a fully automatic system is proposed by means of unmanned aerial vehicles in the detection of forest fires. The image segmentation method on satellite images was used in the detection of the forested land, and the cluster overlay method was used in order for the unmanned aerial vehicle to control the detected area in the shortest time and with the least amount of images. Then, the images obtained were evaluated according to the fire detection model based on artificial intelligence, and the initial and advanced stage fires were determined, and their locations were obtained. As a result, an early warning model that detects fire with an accuracy of approximately 97.51% is proposed in the study.

**Keywords:** Fire Detection, Image Processing, Set Covering, Artificial Intelligence

# I. GİRİŞ

Orman yangınları, çoğunlukla doğal alanlarda meydana gelen, rüzgâr, hava ve bitki örtüsü gibi faktöre bağlı olarak etki alanını arttırabilen, tarım arazilerini, yerleşim alanlarını ve dolayısıyla insanları etkileyen, kontrol edilmesi oldukça zor bir yangın türüdür [1]. Diğer doğal afetlerden farklı olarak, orman yangınlarının farklı sebepleri bulunmaktadır. Bunlar; yıldırım, yuvarlanan kayalardan çıkan kıvılcıklar, volkanik faaliyetler gibi doğal kaynaklı sebepler ile kamp ateşi, anız yakma, sönmemiş sigara izmariti, elektrik kontağı gibi ateş kaynağının yanıcı madde ile temas etmesinden kaynaklanan insan kaynaklı sebeplerdir [2, 3].

Orman yangınlarının kısa ve uzun dönemli birçok olumsuz etkisi bulunmaktadır. Örneğin orman yangınları ulaşımı, iletişimi, elektrik ve doğalgaz hizmetlerini ve su tedarikini sekteye uğratabilmektedir. Ayrıca hava kalitesinin bozulmasına [4] ve mülk, mahsul, kaynak, hayvan ve insan kaybına yol açabilmektedir [5]. Orman yangınları aynı zamanda atmosfere büyük miktarlarda karbondioksit, karbon monoksit ve ince partikül madde salarak havayı ve iklimi de etkilemesi gibi sebeplerden dolayı oluşan hava kirliliği, solunum ve kardiyovasküler problemler de dâhil olmak üzere bir dizi beden sağlık ve ruh sağlığı sorununa neden olabilmektedir [6].

Günümüzde bölgesel ve küresel iklim değişiklikleri nedeniyle orman yangınlarının sıklığı ve büyüklüğü gün geçtikçe artmaktadır [7]. Artan sıcaklık ortalamaları ile birlikte uzun dönem yağışsız geçen günler ve beraberinde gerçekleşen düşük yanıcı madde nemi değerleri, yangınların başlangıcını ve yayılmasını kolaylaştırıcı bir etkiyi ortaya koymaktadır. Orman yangınlarının bu vb. olumsuz sonuçları dikkate alındığında, bu süreçte etkin önleme ve erken uyarı mekanizmalarının oluşturulmasının önemi artmaktadır. Teknolojik gelişmeler yangınların önceden tahmin edilebilmesine imkân veren sistemlerin oluşturulmasında yeni fırsatlar sunmaktadır [8]. Fakat bazı durumlarda tahmin sistemlerinin kullanılmasına rağmen yine de olası yangınların tespiti ve önlenme sürecinde aksaklıklar yaşanabilmektedir. Bu durumlarda bir sonraki aşama olan başlangıç seviyesinde olan yangınların tespiti öne çıkmaktadır. Orman yangınlarının olası kısa vadeli zararlarının yanında uzun yıllar sürebilen olumsuz etkilerinin olabilmesi, çok daha etkin bir kontrol stratejisinin geliştirilmesini zorunlu kılmaktadır [9]. Orman yangınlarının çıkışı ve gelişmesine yönelik gerçekleştirilen çalışmalar iki ana kategoride sunulmuştur. Bunlar; yangın yönü ile yangın gelişimi ve yayılımına yönelik tahmin modelleme yaklaşımlarıdır [10,11]. Yangın tahmin modelleme yaklaşımları da olası yangınların tespiti ve başlangıç aşamasında olan yangınların tespiti olmak üzere kendi içerisinde ikiye ayrılmaktadır.

Olası yangınların tespiti yaklaşımlarında; 2021 yılında yapılan bir çalışmada Nijer geçiş ormanı içindeki orman yangınlarının seviyeleri ve risk bölgeleri belirlenmiş ve modellenmiştir [3]. Yine benzer şekilde Sivrikaya ve Küçük, bir orman yangını risk haritası oluşturmaya yönelik entegre bir yaklaşım önermişler, analitik hiyerarşi süreci (AHP) ve bir istatistiksel indeks (SI) ile coğrafi bilgi sistemi tabanlı çok kriterli karar analizini (GIS-MCDA) kullanmışlardır [4]. Model önerisinde bulunan Francos ve Übeda da yangının toprak, su ve bitki örtüsü üzerindeki etkilerine ilişkin çalışmaları incelemişler ve bir yangın yönetimi için etkin bir model önermiş ve bu parametrelerin geçerliliğini araştırmışlardır [12]. Yapılan bu çalışmaları kategorik olarak değerlendiren Naderpour vd. orman yangını duyarlılığı, tehlikesi ve risk değerlendirmesi için kullanılan yöntemlerin sistematik bir literatür incelemesini yapmış ve temelde dört genel kategoriye ayırmışlardır. Bunlar istatistiksel ve veriye dayalı modeller, makine öğrenimi modeller, çok kriterli karar verme modelleri, topluluk modellerdir [5].

Başlangıç aşamasında olan yangınların ve konumlarının hızlı bir şekilde saptanarak ilgili yetkililere anlık bilgilerin ulaştırılması önem arz etmektedir [16]. Geç kalınmış tespitler genellikle yangın olaylarının şiddetinin artmasına ve müdahale etkinliğinin düşmesine sebebiyet vermektedir [13,14,15]. Bu nedenle, doğru ve etkin erken uyarı mekanizmalarının geliştirilmesi önemlidir [16, 17, 18]. Özellikle son dönemde gelişen teknolojilerin etkisiyle bu alanda birçok yeni araştırma alanı da ortaya çıkmıştır. Bunlar yangın tespiti konusunda yapılan mevcut çalışmalar; kablosuz teknolojiler ve nesnelerin interneti (IoT) aracılığı ile kurulan sistemleri, insansız hava araçlarını (İHA), uydu teknolojilerini ve görüntü

işleme tekniklerini kullanan sistemleri konu başlıklarında incelenmiştir. Bu çalışmalar; 2016 yılında yapılan bir çalışmada, Spatio Wildfire Tahmin ve İzleme Sistemindeki (SWPMS) olası yanlış alarmların ortadan kaldırılması üzerine IoT tabanlı bir sistem önerilmiştir [19]. Diğer bir çalışmada ise tarımsal faaliyetlerde aktif yangın erlerinin tespiti, yayılması ve izlenmesi için bir IoT modülü, IoT sensör tabanlı detektörlerden oluşan derin öğrenme tabanlı bir model önerilmiştir [20]. 2021 tarihli bir çalışmada ise IOT tabanlı kablosuz haberleşme destekli geliştirme kartı (ESP32) üzerinde, yağmur sensörleri, ses sensörü, sıcaklık ve nem sensörü, pasif kızılötesi sensörü kullanarak geliştirilen cihaz ile yangınların tespiti üzerine bir model önerilmiştir [21]. AL-Dhief vd. yaptıkları çalışmada, reaktif Konum Destekli Yönlendirme (KDY), proaktif Optimize Edilmiş Bağlantı Durumu Yönlendirme ve KDY Tabanlı Güvenilir Yönlendirme Protokolü gibi Mobil Geçici Ağ yönlendirme protokollerine dayalı olarak orman yangını tespitinde kullanılan modern teknikler kapsamlı bir incelenmiştir [22]. Martinez vd., görsel ve kızılötesi mikro kamera ve yangın sensörü barındıran 3 İHA kullanarak, Çoklu Heterojen İnsansız Hava Araçlarının Gerçek Zamanlı Koordinasyonu ve Kontrolü projesi dâhilinde, sisteminin yetenekleri ve performansı, otomatik yangın algılama, doğrulama, lokalizasyon ve izleme üzerine çeşitli deneysel çalışmalar yapmışlardır [23]. Dios vd. çalışmalarında, kızılötesi ve görsel kameralarla donanımlandırılmış İHA'ların yangın tespitinde kullanımları incelemiştir [24]. Martins vd. FALCOS İHA'ya yerleştirilen düşük maliyetli dijital kameralar ve yakın kızılötesi sensörler ile yangın algılama sistemleri üzerine deneysel çalışmalar yapmışlardır [25]. Özkan çalışmasında, literatürde orman yangınlarını tespit etmeyi amaçlayan İHA sistemleri için bir matematiksel model geliştirmiştir. Modelde meteorolojik veriler ile oluşturulan günlük yangın risk haritaları dikkate alınarak uygun rotalarla yangın tespiti amaçlanmıştır [26]. Sudhakar vd. çalışmalarında, orman yangınlarının tespitinden İHA'lar için geçerli olan güvenilir ve kesin bir tanıma algoritması önermişlerdir [27]. Mohajane vd. Fas'ın kuzey bölgesindeki orman yangını duyarlılığını haritalamak için Frekans Oranı-Çok Katmanlı Algılayıcı (FR-MLP), Frekans Oranı-Lojistik Regresyon (FRLR), Frekans Oranı-Sınıflandırma ve Regresyon Ağacı (FR-CART), Frekans Oranı- Destek Vektör Makineleri (FR-SVM) ve Frekans Oranı-Rastgele Ormanlar (FR-RF) olmak üzere beş yeni hibrit makine öğrenme algoritması geliştirmişlerdir [28]. Singh vd. orman yangını tahmin güvenilirliğine yönelik bir paralel Destek Vektör Makinesi (SVM) uygulaması geliştirilmiştir [29]. Filizzola vd. çalışmalarında, birçok zamanlı değişiklik algılama tekniği olan, yangın algılama ve izleme için kullanılan RST-FIRES ve bunun görünür/kızılötesi görüntüleyici verileriyle MSG-SEVIRI entegrasyonuna yönelik bir uygulama yapmışlardır [30]. Bernabeu ve ark. (2004) pasif kızılötesi sensörler aracılığıyla otomatik orman yangını gözetimi için bir tahmin/tespit şeması önermişlerdir [31]. Sousa vd. tarafından önerilen yaklaşımda, orman yangını algılama uygulamalarındaki derin öğrenme yaklaşımlarının, çapraz doğrulama ile birlikte veri büyütme için önerilen çerçeveler çizilmiştir [32]. Yang vd. çalışmalarında denetim bilgilerinin etkileşimli dışbükey gövdeler tarafından sunulduğu piksel düzeyinde orman yangını görüntüleri için normal dikdörtgen düzenli şekilli bölgeler yerine, çokgen (düzensiz) yangın ve yangın olmayan bölgelerin görsel olarak seçilmesi için bir dışbükey gövde algoritması önermişlerdir [33]. Sharma vd. çalışmalarında yangın algılama sistemi için kablosuz sensör teknolojileri, İHA'lar ve bulut bilişimin birleşiminden oluşan entegre bir sistem önermişlerdir. Önerilen sistem sensör verilerine dayalı olarak gönderilen İHA'nın gerçek zamanlı görüntüleri elde etmesiyle farklı görüntü işleme tekniklerinin uygulanmasına dayanmaktadır. Bu çalışmada başarımlar, yangının tespit doğruluğu oranı açısından %98 olarak verilmektedir [34]. Liu vd. tarafından yapılan çalışmada, iki seviyeli bir sınıflandırıcıya dayalı bir orman yangını görüntü tanıma algoritması önerilmiştir [35]. Hu vd. orman yangını dumanı hedef tespitinin doğruluğunu ve etkinliğini geliştirmek için orman yangını dumanı tespiti için bir yöntem önermişlerdir [36]. Wang vd., Güney Georgia'da orman yangınlarını tespit etmeyi amaçlayan ve seçilen uydudan türetilen indekslerin "normalleştirilmiş çok bantlı kuraklık indeksi (NMDI), normalleştirilmiş fark su indeksi (NDWI) ve normalleştirilmiş yanma oranlarının (NBR)" tespitine yönelik bir model sunmuşlardır [37]. Orman yangınlarının erken tespiti üzerine yapılan bir diğer çalışmada ise görüntü işleme ve yapay zekâ teknikleri kullanılarak %96 değerinde doğruluk değerine ulaşılmıştır [38].

Bu çalışmada, başlangıç aşamasındaki orman yangınlarının erken tespitinin yapılabilmesi için İHA vasıtası ile tamamen otomatik olarak çalışan ve başarımları yüksek bir uyarı mekanizması önerilmiştir. Çalışma için uygulama alanı olarak Bayburt ilinde bulunan Aslandağı Vilayet Ormanı seçilmiştir. İlgili bölgeye ait uydu görüntüleri kullanılarak temel görüntü işleme ve optimizasyon yöntemleri aracılığı ile orman arazisini en az sayıda imge kullanarak inceleyebilmek için koordinatlar tespit edilmiştir. Elde

edilen fotoğraflarda yangın olup olmadığına ise yine görüntü işleme ve derin öğrenmeye dayalı teknikler kullanılarak karar verilmiştir.

## **II. MATERYAL VE YÖNTEM**


Yapılan çalışmanın akış şeması Şekil 1'de gösterilmektedir. Yapılan çalışmada öncelikle Bayburt Aslındağı Vilayet Ormanı'na ait Landsat uydu programından alınan uydu görüntülerine (Kasım, 2021), görüntü bölütleme (image segmentation) yöntemi uygulanmıştır. Bayburt Valiliği'nce 1995 yılında projelendirilerek uygulamaya konulan Aslan Dağı Vilayet Ormanı'na bugüne kadar toplam 624.438 adet sarı çam, akasya, alyantus, S. söğüt, N. söğüt, Süs ağacı, Akçağaç ve Y. akasya türlerinden ağaçlar dikilmiştir. Bu yöntemde ormanlık arazi dışındaki tüm yapılar maskeleyme ile inceleme alanının dışında tutulmuştur. Daha sonra elde edilen siyah beyaz görüntüde çözünürlük düşürülerek beyaz ile gösterilen orman arazisinin daha az piksel ile temsili sağlanmıştır. Yeniden boyutlandırılmış bu imgedeki orman arazisine ait piksel bilgileri kullanılarak küme kaplama yöntemi ile ormanlık arazinin en düşük adette fotoğraf sayısı ile temsili sağlanmıştır. İHA ile fotoğraf alınmasında en uygun noktalar tespit edildikten sonra görüntü filtreleme ve yapay zekâ teknikleri kullanılarak yangın tespiti üzerine bir model geliştirilmiştir. Fotoğrafların alındığı noktalarda yangın tespit edilmesi durumunda ise ilgili koordinatın elde edilmesi sağlanmıştır.



Şekil 1. Sistemin akış şeması

### **A. ORMANLIK ARAZİNİN TESPİTİ**

Yapılan çalışmada, uygulama alanına ait elde edilen uydu görüntüsü kullanılarak Matlab 2021b yazılımındaki imge bölütleme araç çubuğu aracılığı ile ormanlık arazinin tespiti gerçekleştirilmiştir. Bu uygulama bir görüntüyü eşikleme, kümeleme, grafik tabanlı bölütleme ve bölge büyütme gibi birçok yöntem vasıtası ile bölümlere ayırma işlemini gerçekleştirme kabiliyetine sahiptir. Bazı bölütleme teknikleri belirli imge türlerinde diğerlerinden daha yüksek başarımda sonuç verebilmektedir [39]. Yapılan çalışmada ilgili yazılımın otomatik kümeleme seçeneği kullanılmıştır. Bu yöntem bir görüntüyü ön ve arka plan öğelerine bölmek için kullanılan otomatik bir bölütleme tekniğidir. Görüntünün bölümlere ayrılmasının ardından ikili maskeyi kaydetmek ve yapılan ayarların kodlarını alıp başka imgelere de aynı şekilde tatbik etmek mümkündür. Şekil 2'de uygulama alanına ait uydu görüntüsü, bölütlenmiş ve maskelenmiş imge, Siyah beyaz renk dönüşümü yapılan imge ve çözünürlüğü düşürülmüş imge gösterilmektedir. Yapılan çalışmada imge bölütleme işleminin daha verimli gerçekleştirilebilmesi için yüksek çözünürlükteki (1024 x 768) uydu görüntüsü kullanılmıştır. Bölütlenmiş imgeyi daha sonra siyah beyaz hale getirmek ve çözünürlüğü düşürmekteki amaç ise küme kaplama yönteminde kullanılacak beyaz noktaları belirlemek ve bu noktaların sayısını azaltmaktır.



(a) (b) (c) (d)

**Şekil 2.** (a) Bayburt Aslındağı Vilayet Ormanı uydu görüntüsü, (b) İmge bölütleme ile ormanlık alanların tespiti, (c) Orman arazisini gösteren siyah beyaz imge, (d) Siyah beyaz imgenin yeniden boyutlandırma ile çözünürlüğünün 1/10 oranında düşürülmesi.

## B. KÜME KAPSAMA YÖNTEMİ

Küme kapsama yöntemi, tanımlı bir şebeke üzerinde bütün düğümlere daha önceden belirlenmiş bir zaman veya mesafe ( $r$ ) içerisinde en az bir kez ulaşılabilecek şekilde en az sayıda noktanın tespitine yönelik geliştirilmiş bir çözüm yöntemidir. Başka bir ifadeyle küme kapsama probleminde, her talep düğümünün en az bir tesis tarafından kapsanması için sonlu bir aday tesisler kümesi arasından en düşük maliyetli tesisler kümesinin bulunması amaçlanır [40]. Bu yöntem çoğunlukla ambulans, itfaiye aracı, mobil polis ekibi vb. tesislerin tespiti için yer seçiminde kullanılmaktadır.

Çalışmada ormanlık alanda tarama yapacak İHA'nın tüm alanları kapsayacak şekilde uygun rotalarda uçabilmesi için uygun geçiş koordinatları küme kapsama yöntemi kullanılarak tespit edilmiştir. Yöntemde kullanılan matematiksel modelde; amaç fonksiyonu (1) ile en az nokta dolaşımı ile tüm alanların görüntüsünün alınması hedeflenmektedir. 1. kısıt (2) tüm noktaların mutlaka bir kapsama alanı içerisine alınmasını, 2. kısıt (3)  $y_k$  değerini (0,1) tamsayısı olmasını sağlamaktadır. Modelde;  $Z$  amaç fonksiyonu değerini,  $y_k$  her bir koordinat noktasını,  $a_{ik}$  iki nokta arasındaki uzaklık değerini ifade etmektedir.

### Amaç Fonksiyonu;

$$\text{Min } Z = \sum_{k \in N} y_k \quad (1)$$

### Kısıtlar;

$$\sum_{k \in N} a_{ik} y_k \geq 1 \quad \forall i \in N \quad (2)$$

$$y_k \in \{0,1\} \quad \forall k \in N \quad (3)$$

### Karar Değişkenleri;


$$y_k = \begin{cases} 1, & \text{eğer } k \text{ noktası, geçiş koordinatı olursa } \forall k \in N \\ 0, & \text{diğer durumda} \end{cases} \quad (4)$$

$$a_{ik} = \begin{cases} 1, & \text{eğer } k \text{ noktası ile } i \text{ noktası arasındaki mesafe } r' \text{ ye eşit veya az ise } (\forall i, k \in N) \\ 0, & \text{diğer durumda} \end{cases} \quad (5)$$

Halk arasında drone olarak da bilinen İHA'lar, modern çağın en dinamik ve çok boyutlu teknolojilerinden biri olarak kabul edilmektedir. Bu teknoloji, koli teslimatı, spor yayını vb. ticari görevlerden araştırma uygulamalarına kadar farklı alanlarda aktif olarak kullanılmaktadır. [41]. Yapılan çalışmada döner kanatlı İHA'nın 100 metre yükseklikten uçtuğu takdirde dikey konumda çekilen bir fotoğraf ile yaklaşık 6 dekar boyutunda arazinin kapsanabileceği (Google Earth uygulaması ile 100 metre yükseklikten alınan resmin dairesel hale getirilmesi ile) hesaplanmıştır. Kullanılan uydu görüntülerindeki çözünürlük bilgisi aracılığı ile görüntüdeki bir pikselin yaklaşık 4 metrelik bir mesafeye tekabül edeceği bulunmuştur. Küme kaplama yönetiminde kullanılması gereken dairesel görüntüler ise Şekil 3'de şekliyle oluşturulmuştur. Görüntü kaybını ortadan kaldıracak şekilde oluşturulan dairesel alanların merkezi gezilecek noktalar olarak belirlenmiştir. Bu noktalar ilgili alanları temsil etmektedir. Bu verilerin kullanılması ile küme kaplama yönteminin uygulanmasından sonra elde edilen en uygun görüntü yakalama noktaları daha sonra çözünürlük geliştirme ile orijinal uydu görüntüsüne uygulanmıştır. Şekil 4'de yapılan çalışmada küme kaplama yöntemi ile elde edilen görüntü yakalama noktaları ve kapsama alanları gösterilmektedir.




*Şekil 3. Küme kaplama yönteminde kullanılacak dairesel alan tespitinde görüntü seçimi*



*Şekil 4. Küme kaplama ile ormanlık alanda görüntü yakalama aygıtı için en uygun konumlarının tespiti ve kapsama alanı*

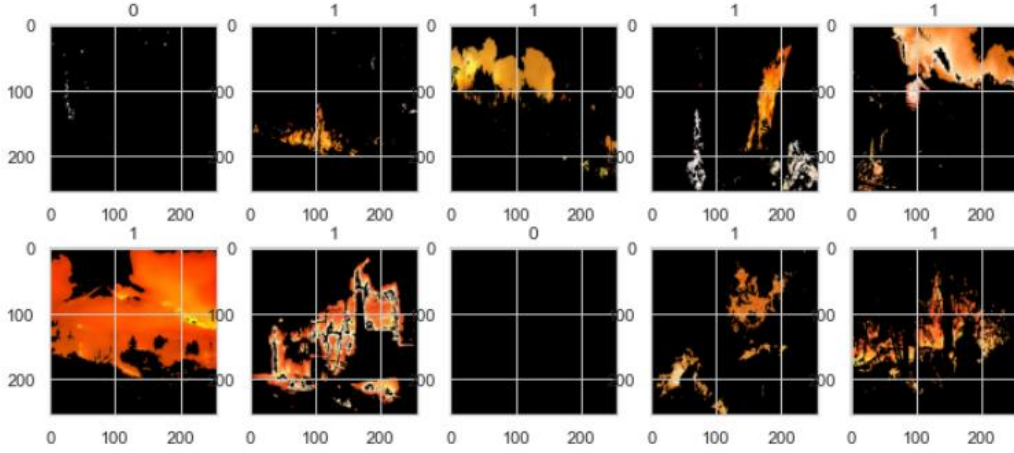
### C. YANGIN TESPİTİ

Yapılan çalışmada yangın tespiti üzerine geliştirilen karar verici modelinde python programlama dili ve açık kaynak Kaggle yangın veri tabanı kullanılmıştır [42]. Şekil 5'te örnek imgeler verilen ilgili veri tabanında, 755 adet muhtevasında ateş olan ve 244 adet ateş bulunmayan görüntü mevcuttur.




*Şekil 5. Veri tabanına ait örnek imgeler (0- yangın yok 1- yangın var)*

Kullanılan veri tabanın büyük bir veri tabanı olması dolayısıyla, içeriğinde farklı çözünürlük değerinde ve farklı renk uzayında verilerin bulunma ihtimaline karşılık ilk olarak veri tabanındaki tüm görüntülerin aynı çözünürlük değerinde ve aynı renk uzayında incelenmesi için 256x256 piksel içerecek şekilde yeniden boyutlandırma ve RGB renk uzayına dönüştürme işlemleri gerçekleştirilmiştir. Yangın var (1) ve yangın yok (0) olarak etiketlenen tüm imgelere Şekil 6'da gösterildiği üzere içeriğinde yangına ait renkleri tespit eden ve diğer renklerden ayırt eden bir renk filtresi uygulanmıştır. Kullanılan filtrede, piksel bazında, kırmızı değerlerin yeşil değerlerden büyük olması, yeşil değerlerin mavi değerlerden büyük olması ve kırmızı değerlerin 200 değerinden büyük olması olmak üzere ( $R>G$  ve  $G>B$  ve  $R>200$ ) üç koşulun aynı anda sağlanması incelenmektedir.



Şekil 6. Veri tabanına renk filtresi uygulanması ile elde edilen örnek imgeler(0- yangın yok 1- yangın var)

Renk filtresi uygulanması işleminden sonra makine öğrenmesine dayalı kör ve adil bir sınıflandırmanın gerçekleştirilebilmesi için, veri setindeki tüm imgeler %80 eğitim, %20 test veri kümesi olarak kullanılacak şekilde rastgele şekilde ayrılmıştır. Daha sonra başarıyı kanıtlanmış, VGG16, AlexNet, InceptionV3 ve Resnet50 mimarileri, aktarım öğrenme (transfer learning) tekniği kullanılarak sınıflandırma modeli eğitilmiştir. VGG16, görsel nesne tanımda büyük bir veri tabanı projesi olan ImageNet için yaygın olarak kullanılan bir Evrimsel Sinir Ağı mimarisidir.



Şekil 7. Derin öğrenmeye dayalı kullanılan modelin ayrıntıları

VGG16, 2014 yılında Oxford Üniversitesi'nden Karen Simonyan ve Andrew Zisserman tarafından geliştirilmiş ve tanıtılmıştır [43]. VGG ifadesi, Oxford Üniversitesi'nde bu mimariyi geliştiren bir grup araştırmacı tarafından oluşan Visual Geometry Group'un kısaltmasıdır. AlexNet, 2012 yılındaki ImageNet yarışmasını büyük bir farkla kazanan derin öğrenme modelidir [44]. InceptionV3 derin öğrenme modeli ise inception ailesinin çeşitli iyileştirmelere sahip olan ferdidir [45]. Resnet50 ise, artık sinir ağları ve artık blokları istifleyerek ağ oluşturan 50 katmanlı bir derin öğrenme modelidir [46]. Yapılan çalışmada kullanılan tüm modellerin epoch sayısı 100 olarak belirlenmiştir. Eğitim sırasında

kayıplar arasındaki fark açılmaya başladığı durumda modelin ezberlemesini engellemek için erken durdurma uygulanmıştır. Modellere ait kullanılan diğer parametreler Şekil 7'deki blok şema üzerinde gösterilmektedir.

Kullanılan veri tabanında yangın olan ve yangın olmayan görüntülerin eşit sayıda bulunmamasından dolayı üretilen modelin sadece doğruluğuna bakarak değerlendirilmesi yanıltıcı olabilmektedir. Bu bakımdan model sonucu elde edilen değerlerin gerçekteki değerler ile karşılaştırıldığı ve birbirleri arasındaki ilişkiyi özetleyen bir tabloya ihtiyaç duyulmaktadır. Yapılan çalışmada modelin performans değerlendirmesinde hata matrisi (confusion matrix) ve hata matrisinden elde edilen parametreler kullanılmıştır. Tablo 1'de gerçek ve tahmini değerlerin birbirleri ile ilişkilerinin gösterildiği bir hata matrisi verilmiştir.

**Tablo 1. Hata matrisi**

Hata Matrisi		Gerçek Sonuçlar	
		Pozitif (1)	Negatif (0)
Tahmin Edilen Sonuçlar	Pozitif (1)	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif (0)	Yanlış Negatif (FN)	Doğru Negatif (TN)

Tablo 1'de gösterilen değerler vasıtasıyla Tablo 2. de belirtilen eşitlikler kullanılarak bir sınıflandırma modelinin performansı doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru gibi farklı parametreler göz önüne alınarak değerlendirilebilmektedir [47].

**Tablo 2. Sınıflandırma metriklerinin hesaplanması**

Sınıflandırma Metrikleri	Denklem	Numara
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$	(1)
Duyarlılık (Sensitivity)	$\frac{TP}{TP + FN}$	(2)
Özgüllük (Specificity)	$\frac{TN}{TN + FP}$	(3)
Kesinlik (Precision)	$\frac{TP}{TP + FP}$	(4)
F1 Skoru	$2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık}$	(5)

### C. 1. Bulgular

Yapılan çalışmada, kullanılan aktarım öğrenme modellerinin sınıflandırma metriklerine göre performans değerlendirmesi Tablo 3'de, yangın tespitinde karar verici olarak kullanılan yapay zekâ




modelleri içerisindeki en başarılı model olan VGG16'ya ait, test veri seti kullanılarak elde edilen hata matrisi Tablo 4'de gösterilmektedir. Ayrıca VGG16 modelinde kullanılan epoch sayısına karşılık eğitim ve test aşamasındaki doğruluk ve kayıp grafikleri ise Şekil 8'de verilmektedir.

**Tablo 3.** Sınıflandırma modeline ait hata matrisi

Hata Matrisi		Gerçek Sonuçlar	
		Yangın Yok	Yangın Var
Tahmin Edilen Sonuçlar	Yangın Yok	46	3
	Yangın Var	2	150

**Tablo 4.** Sınıflandırma metriklerine göre modelin performansı

Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1-Skoru
0,9751	0,9804	0,9583	0,9868	0,9836



**Şekil 8.** Kullanılan modele ait doğruluk ve kayıp grafikleri

## **IV. SONUÇ**

Yapılan çalışmada İHA kullanılarak başlangıç aşamasındaki (özellikle A sınıfında yer alan “1 hektar ve daha küçük alanlar” için) orman yangınlarının tespiti üzerine otomatik bir sistem tasarlanmıştır. Çalışmanın başındaki uygulama bölgesi olan Bayburt Aslındağı Vilayet Ormanı'na ait uydu görüntüleri alınmış ve ormanlık arazi görüntü bölütleme ile tespit edilmiştir. Daha sonra İHA'nın devriyesi için orman alanının tamamını kapsayacak şekilde fotoğraf alınacak koordinatlar, küme kaplama yöntemi ile tespit edilmiştir. Orta düzeyde döner kanatlı bir İHA'nın 100 metre yükseklikten 45 dakikalık uçuşu süresince elde edilebilecek 302 adet imge ile ilgili bölgenin tamamen temsiline mümkün olduğu hesaplanmıştır. Elde edilen görüntülerde yangın olup olmadığı hususuna ise görüntü filtreleme ve yapay zekâ modeli ile karar verilmiştir. Karar verici olarak kullanılan model sonuçlarının literatürdeki diğer orman yangını tespiti üzerine olan çalışmalar ile karşılaştırılması Tablo 5'de gösterilmektedir.











**Tablo 5.** Sunulan yöntemin literatürdeki benzer çalışmalar ile karşılaştırılması

Çalışma	Kullanılan Yöntem	Doğruluk
Sunulan	Görüntü İşleme ve Derin Öğrenme (Yangın Tespiti)	%97,51
[38] Aksoy vd.	Görüntü İşleme ve Derin Öğrenme (Yangın Tespiti)	%96,48
[48] Cui	IoT ve Derin Öğrenme (Yangın Tespiti)	%87,10
[49] Jiao vd.	Derin Öğrenme (Yangın Tespiti)	%91,00

Ayrıca oluşturulan modelin yeni verilere karşı başarımını incelemek için internet kaynaklı web kaynaklı rastgele döner kanatlı İHA ile çekilmiş orman ve orman yangını resimleri bulunmuş, sunulan modelde incelenmiş ve Tablo 6’da sonuçları gösterilmiştir.

Tasarlanan model vasıtası ile İHA ile elde edilen görüntülerde yangın tespit edildiğinde ilgili fotoğrafın çekildiği koordinat bilgisi de elde edilmektedir. Bu sayede çıkması muhtemel bir yangına erken müdahale imkânı sağlanmaktadır. Orman yangınlarının tamamen otomatik tespiti üzerine yapılan bu ön çalışma ile gelecekte tasarımı planlanan İHA’nın temelleri atılmaktadır. İlerleyen çalışmalarda farklı transfer öğrenme tekniklerinin ilgili alanda kullanımı daha büyük veri tabanı ile kıyaslanarak başarımlarının sağlanması planlanmaktadır.

**Tablo 6.** Sunulan yöntemin yeni verilere karşı başarımı

				
Yangın Var 1,46e-04 Yangın Yok 0,99	Yangın Var 8,51e-06 Yangın Yok 0,99	Yangın Var 2,11e-05 Yangın Yok 0,99	Yangın Var 4,75e-05 Yangın Yok 0,99	Yangın Var 1,46e-04 Yangın Yok 0,99
				
Yangın Var 1,00e+00 Yangın Yok 4,69e-26	Yangın Var 1,00e+00 Yangın Yok 8,25e-23	Yangın Var 1,00e+00 Yangın Yok 1,60e-27	Yangın Var 1,00e+00 Yangın Yok 4,73e-35	Yangın Var 0,99 Yangın Yok 2,83e-04

## **V. KAYNAKLAR**

- [1] A. Dhall, A. Dhasade, A. Nalwade, M. Raj, and V. Kulkarni, "A survey on systematic approaches in managing forest fires," *Appl. Geogr.*, vol. 121, no. 102266, p. 102266, 2020.
- [2] A. Bouguettaya, H. Zarzour, A. M. Taberkit, and A. Kechida, "A review on early wildfire detection from unmanned aerial vehicles using deep learning-based computer vision algorithms," *Signal Processing*, vol. 190, no. 108309, p. 108309, 2022.
- [3] M. A. Enoch, U. C. Okeke, and N. Y. Narinua, "Identification and modelling of forest fire severity and risk zones in the Cross – Niger transition forest with remotely sensed satellite data," *Egypt. J. Remote Sens. Space Sci.*, vol. 24, no. 3, pp. 879–887, 2021.
- [4] F. Sivrikaya and Ö. Küçük, "Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region," *Ecol. Inform.*, vol. 68, no. 101537, p. 101537, 2022.
- [5] M. Naderpour, H. M. Rizeei, N. Khakzad, and B. Pradhan, "Forest fire induced Natech risk assessment: A survey of geospatial technologies," *Reliab. Eng. Syst. Saf.*, vol. 191, no. 106558, p. 106558, 2019.
- [6] S. Chaturvedi, P. Khanna, and A. Ojha, "A survey on vision-based outdoor smoke detection techniques for environmental safety," *ISPRS J. Photogramm. Remote Sens.*, vol. 185, pp. 158–187, 2022.
- [7] M.D. Flannigan, B.D. Amiro, K.A. Logan, B.J. Stocks and B.M. Wotton, *Forest Fires and Climate Change In The 21st Century, Mitigation and Adaptation Strategies for Global Change*, vol.11, pp.847–859, 2005.
- [8] B. Christensen, "Technological advances in rural fire management: use of organizational knowledge and simple economic analysis", Lincoln University, 2014.
- [9] J. San-Miguel-Ayanz, "Forest fires in Europe, middle east and north Africa 2017," 2017.
- [10] M. Mutlu, S. C. Popescu, and K. Zhao, "Sensitivity analysis of fire behavior modeling with LIDAR-derived surface fuel maps," *For. Ecol. Manage.*, vol. 256, no. 3, pp. 289–294, 2008.
- [11] T. J. Duff and K. G. Tolhurst, "Operational wildfire suppression modelling: a review evaluating development, state of the art and future directions," *Int. J. Wildland Fire*, vol. 24, no. 6, p. 735, 2015.
- [12] M. Francos and X. Úbeda, "Prescribed fire management," *Curr. opin. environ. sci. health*, vol. 21, no. 100250, p. 100250, 2021.
- [13] M. Avcı ve M. Korkmaz, "Türkiye’de orman yangını sorunu: Güncel bazı konular üzerine değerlendirmeler", *Turkish Journal of Forestry*, vol. 22, no.3, s. 229-240, 2021.
- [14] E. Bilgili, İ. Baysal, B. Dinç Durmaz, B. Sağlam, Ö. Küçük, "2008 yılında çıkan büyük orman yangınlarının değerlendirilmesi", III. Ulusal Karadeniz Ormancılık Kongresi, 20-22 Mayıs, Artvin, s. 1270-1279, 2010.
- [15] E. Bilgili, B. Dinç Durmaz, İ. Baysal, B. Sağlam, Ö. Küçük, "Doğu Karadeniz ormanlarında orman yangınları" III. Ulusal Karadeniz Ormancılık Kongresi, 20-22 Mayıs, Artvin, s. 1280-1290, 2010.

- [16] E. Bilgili, Ö. Küçük, B. Sağlam and K.A. Coşkuner, “Mega Forest Fires: Causes, Organization And Management”, *Forest Fires*, Ankara, Türkiye Bilimler Akademisi, s. 1-23, 2021.
- [17] E. Bilgili, Ö. Küçük, B. Sağlam, İ. Baysal, B.D. Durmaz ve K.A. Coşkuner, “Türkiye Orman Ekosistemlerinde Yangınların Ekolojik Rolü”, *Ekoloji ve Ekonomi Ekseninde Türkiye’de Orman ve Ormancılık*, Ankara: Sonçağ Akademi, s. 75-115, 2021.
- [18] K.A. Coşkuner ve E. Bilgili, “Orman yangın yönetiminde etkili bir karar destek sisteminin kavramsal çerçevesi”, *Doğal Afetler ve Çevre Dergisi*, s.6, no.2, s. 288-303, 2020.
- [19] G. Narasimha Rao, P. Jagadeeswara Rao, R. Duvvuru, S. Bendalam, and R. Gemechu, “Fire detection in kambalakonda reserved forest, visakhapatnam, Andhra pradesh, India: An internet of things approach,” *Mater. Today*, vol. 5, no. 1, pp. 1162–1168, 2018.
- [20] A. Sharma et al., “IoT and deep learning-inspired multi-model framework for monitoring Active Fire Locations in Agricultural Activities,” *Comput. Electr. Eng.*, vol. 93, no. 107216, pp. 107216, 2021.
- [21] P. Kanakaraja, P. Syam Sundar, N. Vaishnavi, S. Gopal Krishna Reddy, and G. Sai Manikanta, “IoT enabled advanced forest fire detecting and monitoring on Ubidots platform,” *Mater. Today*, vol. 46, pp. 3907–3914, 2021.
- [22] F. T. AL-Dhief, N. Sabri, S. Fouad, N. M. A. Latiff, and M. A. A. Albader, “A review of forest fire surveillance technologies: Mobile ad-hoc network routing protocols perspective,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 31, no. 2, pp. 135–146, 2019.
- [23] J. R. Martínez-de Dios, L. Merino, F. Caballero, A. Ollero, and D. X. Viegas, “Experimental results of automatic fire detection and monitoring with UAVs,” *For. Ecol. Manage.*, vol. 234, p. S232, 2006.
- [24] J. R. M. Dios, L. Merino, and A. Ollero, “Fire detection using autonomous aerial vehicles with infrared and visual cameras,” *IFAC proc.* vol., vol. 38, no. 1, pp. 660–665, 2005.
- [25] A. Martins et al., “Forest fire detection with a small fixed wing autonomous aerial vehicle,” *IFAC proc.* vol., vol. 40, no. 15, pp. 168–173, 2007.
- [26] O. Ozkan, “Optimization of the distance-constrained multi-based multi-UAV routing problem with simulated annealing and local search-based matheuristic to detect forest fires: The case of Turkey,” *Appl. Soft Comput.*, vol. 113, no. 108015, p. 108015, 2021.
- [27] S. Sudhakar, V. Vijayakumar, C. Sathiy Kumar, V. Priya, L. Ravi, and V. Subramaniaswamy, “Unmanned Aerial Vehicle (UAV) based Forest Fire Detection and monitoring for reducing false alarms in forest-fires,” *Comput. Commun.*, vol. 149, pp. 1–16, 2020.
- [28] M. Mohajane et al., “Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area,” *Ecol. Indic.*, vol. 129, no. 107869, p. 107869, 2021.
- [29] K. R. Singh, K. P. Neethu, K. Madhurekaa, A. Harita, and P. Mohan, “Parallel SVM model for forest fire prediction,” *Soft Computing Letters*, vol. 3, no. 100014, p. 100014, 2021
- [30] C. Filizzola et al., “RST-FIRES, an exportable algorithm for early-fire detection and monitoring: description, implementation, and field validation in the case of the MSG-SEVIRI sensor,” *Remote Sens. Environ.*, vol. 186, pp. 196–216, 2016.
- [31] P. Bernabeu, L. Vergara, I. Bosh, and J. Igual, “A prediction/detection scheme for automatic forest fire surveillance,” *Digit. Signal Process.*, vol. 14, no. 5, pp. 481–507, 2004.

- [32] M. J. Sousa, A. Moutinho, and M. Almeida, "Wildfire detection using transfer learning on augmented datasets," *Expert Syst. Appl.*, vol. 142, no. 112975, p. 112975, 2020.
- [33] X. Yang et al., "Pixel-level automatic annotation for forest fire image," *Eng. Appl. Artif. Intell.*, vol. 104, no. 104353, p. 104353, 2021.
- [34] A. Sharma, P. K. Singh, and Y. Kumar, "An integrated fire detection system using IoT and image processing technique for smart cities," *Sustain. Cities Soc.*, vol. 61, no. 102332, p. 102332, 2020.
- [35] Z. Liu, K. Zhang, C. Wang, and S. Huang, "Research on the identification method for the forest fire based on deep learning," *Optik (Stuttg.)*, vol. 223, no. 165491, p. 165491, 2020.
- [36] Y. Hu et al., "Fast forest fire smoke detection using MVMNet," *Knowl. Based Syst.*, vol. 241, no. 108219, p. 108219, 2022.
- [37] L. Wang, J. J. Qu, and X. Hao, "Forest fire detection using the normalized multi-band drought index (NMDI) with satellite measurements," *Agric. For. Meteorol.*, vol. 148, no. 11, pp. 1767–1776, 2008.
- [38] B. Aksoy, K. Korucu, Ö. Çalışkan, Ş. Osmanbey, and H. D. Halis, "İnsansız Hava Aracı ile Görüntü İşleme ve Yapay Zekâ Teknikleri Kullanılarak Yangın Tespiti: Örnek Bir Uygulama," *Düzce Üniv. bilim ve teknol. derg.*, pp. 112–122, 2021.
- [39] F. Bulut, İ. Kılıç ve İ. F. İnce, "Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması ve Analizi", *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, c. 20, sayı. 58, s. 173-186, Oca. 2018.
- [40] M. S. Daskin, *Network and discrete location: Models, algorithms, and applications*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 1995.
- [41] M.A. Khan, W. Ectors, T. Bellemans, D. Janssens, G. Wets, "UAV-Based Traffic Analysis: A Universal Guiding Framework Based on Literature Survey, *Transportation Research Procedia*", vol. 22, pp. 541-550, 2017.
- [42] "Fire Dataset," Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/phyllake1337/fire-dataset>. [Accessed: 04-Spring-2022].
- [43] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv [cs.CV]*, 2014.
- [44] A. Krizhevsky, I. Sutskever and G. Hinton, "ImageNet classification with deep convolutional neural networks." In *NIPS'2012*, 23, 24, 27, 100, 200, 371, 456, 460, 2012.
- [45] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [46] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [47] U. Konur, "Sınıflandırma Başarımını Ölçme ve Seyreklik İşleme Üzerine", *EMO Bilimsel Dergi*, c. 10, sayı. 2, s. 43-56, Ara. 2020.
- [48] F. Cui, "Deployment and integration of smart sensors with IoT devices detecting fire disasters

in huge forest environment,” *Comput. Commun.*, vol. 150, pp. 818–827, 2020.

[49] Z. Jiao et al., “A YOLOv3-based learning strategy for real-time UAV-based forest fire detection,” in 2020 Chinese Control And Decision Conference (CCDC), 2020.