

## Yangın Tespiti için Derin Öğrenme Tabanlı Sınıflandırma: Baberti Külliyesi Örneği

Melek Kurşun<sup>1</sup>, M. Alptekin Engin<sup>2\*</sup>

<sup>1</sup>Acil Yardım ve Afet Yönetimi Bölümü, Bayburt Üniversitesi, Türkiye

<sup>2</sup>Elektrik Elektronik Mühendisliği Bölümü, Bayburt Üniversitesi, Türkiye

\*(maengin@bayburt.edu.tr) Başlıca yazarın mail adresi

**Özet** – Çevremizde gerçekleşen yangınlar yüzünden her yıl ciddi oranda can ve mal kaybı yaşanmaktadır. Bu bakımdan erken dönemde yani başlangıç aşamasında bir yangını tespit edebilmek, müdahale zamanının kısılması açısından oldukça önemlidir. Yapılan çalışmanın ana amacı belirli bir dış mekân ve çevresi için özelleştirilmiş ve yüksek doğruluk ile çalışan bir yangın algılama sisteminin gerçekleştirilmesidir. Bunun için Bayburt Üniversitesi Baberti Külliyesi uygulama alanında döner kanatlı insansız hava aracı kullanılarak fotoğraflar elde edilmiştir. Bu fotoğraflar rastgele olacak şekilde ikiye ayrılmış ve bir bölümüne yapay zekâ aracılığı ile yangın bileşenleri eklenmiştir. Bu şekilde bir yangın veri tabanı oluşturulmuş ve oluşturulan veri tabanındaki tüm fotoğraflara HSV renk uzayında belirlenen parametreler kullanılarak görüntü filtreleme ile ateş olan bölümleri tespit edip diğer kısımları maskeleyecek bir maske eklenmiştir. Daha sonra elde edilen filtrelenmiş fotoğraflar derin öğrenme ile yangının varlığı ve yokluğu durumlarına göre sınıflandırılmıştır. Sınıflandırma modelinin oluşturulması aşamasında evrimsel sinir ağıları tabanlı VGG16, VGG19, DenseNet201, InceptionV3, MobileNetV2, Resnet50, Resnet101 ve Resnet152 derin öğrenme mimarileri, transfer öğrenme yolu ile çalışmaya uyarlanarak kullanılmıştır. Sonuç olarak kullanılan mimariler içinde ateşin tespit edilmesinde F1-Skoru açısından en yüksek değerlere (%95) sahip olan VGG19, DenseNet201, MobileNetV2 ve Resnet152 mimarilerinin, en başarılı mimariler olduğu tespit edilmiştir. Bununla beraber bu mimarilerin ateşin olduğu ve olmadığı tüm durumlarda en yüksek sınıflandırma doğruluğuna (%95) sahip oldukları tespit edilmiştir.

*Anahtar Kelimeler – Görüntü İşleme, Sınıflandırma, Yangın Tespiti, Derin Öğrenme*

### I. GİRİŞ

Özellikle belirli alanlar içerisinde çok hızlı yayılım potansiyeline sahip olan yangınlar her yıl büyük can ve mal kaybına yol açmaktadır. Bu bakımdan erken dönemde yani başlangıç aşamasında bir yangını tespit edebilmek müdahale zamanının kısılması açısından oldukça önemlidir. Kapalı alanlarda yangın tespitinde kullanılan ısı, duman ve karbon monoksit detektörlerinin bu alanlar için tasarlanması sebebi ile dış mekânlarda verimli olarak çalışmaları söz konusu değildir [1]. Bu bakımdan hava durumu ışık miktarı gibi farklı birçok belirleyici etkene bağlı olarak geniş ve açık alanlar için yangının algılanması oldukça zordur. İç mekân yangın algılama sistemlerinin yetersiz

kaldığı dış mekânlarda görüntü işleme yöntemleri aracılığı ile bu zorluğun üstesinden gelinmesi mümkündür [2]-[4]. Hatta özellikle gelişen yazılım, donanım teknolojileri ve makine öğrenmesi sayesinde insan müdahalesi olmadan dış ortamlardaki yangınların tespiti mümkün kılınmaktadır [5]. Ayrıca bu teknolojilerdeki gelişim afetlerde erken uyarı sistemlerinin tasarımına da imkân sağlamaktadır. Özellikle insansız hava araçlarının (İHA) kullanım alanlarının genişlemesi sebebiyle bu araçlara erişim kolaylaşmaktadır [6]. İHA kullanılarak kısa zaman içerisinde büyük miktarda coğrafi alanın taranabilmesi mümkündür. Başlangıç sebebi her ne olursa olsun yangın tespitinde de insansız hava

araçlarını kullanan mevcut çalışmalar bulunmaktadır [7]-[11]. Fakat bu çalışmaların tamamı orman yangınlarının tespiti üzerinedir.

Literatürdeki görüntü işleme tabanlı yangın tespiti üzerine olan mevcut çalışmalar yangın dumanının tespiti ve alevin tespiti üzerine iki bölümde incelenmektedir [12]. Bu iki alanda da dış mekânlarda yangın tespitinde İHA kullanılarak elde edilen fotoğraflar, yer istasyonlarından elde edilen fotoğraflara göre daha doğru ve detaylı bilgi sunabilmektedir [13]. İHA ve derin öğrenme aracılığı ile yangın tespiti üzerine literatürde farklı veri tabanları ile farklı teknikleri kullanan çok sayıda çalışma bulunmaktadır [14]-[20]

Alev tespiti üzerine yapına çalışmanın ana amacı belirtilen kampüs alanı ve çevresi için özelleştirilmiş ve yüksek doğruluk ile çalışan bir yangın algılama sisteminin gerçekleştirilmesidir. Bunun için ilgili alanda döner kanatlı İHA kullanılarak fotoğraflar elde edilmiştir. Bu fotoğraflar rasgele olacak şekilde ikiye ayrılmış ve bir bölümüne yapay zekâ aracılığı ile ateş eklenmiştir. Bu şekilde bir yangın veri tabanı oluşturulmuş ve oluşturulan veri tabanındaki tüm fotoğraflara görüntü filtreleme ile ateş olan bölümleri tespit edip diğer kısımları göz ardı edecek bir maske eklenmiştir. Daha sonra elde edilen filtrelenmiş fotoğraflar derin öğrenme ile sınıflandırılmıştır.

## II. MATERYAL VE YÖNTEM

Çalışmanın blok şeması Şekil 1'de verilmektedir.



Şekil 1. Çalışmanın blok şeması

### A. Veri Tabanı

Yapılan çalışmada Bayburt Üniversitesi Baberti külliyesi yerleşkesi uygulama alanı olarak belirlenmiştir. Bu alan içerisinde 180000 metrekare kapalı, 1240000 metrekare açık alan 3840 metre bisiklet yolu 10375 metre yürüyüş yolu ve 80000 metrekare yeşil alan bulunmaktadır. Şekil 2'de uygulama alanı olarak seçilen Bayburt Üniversitesi Baberti Külliyesine ait uydu görüntüsü verilmektedir. Sahip olduğu özellikler bakımından incelendiğinde kampüs alanında hem farklı insan yapıları hem de ağaçlandırılmış bölgeler bulunmaktadır.



Şekil 2. Bayburt Üniversitesi Baberti Külliyesi

Tüm bu karma yapısal özelliklere sahip olması nedeniyle uygulama alanına ait imgelerin kullanılması ile yüksek başarımda çalışmak için tasarlanacak bir erken yangın uyarı sistemine ihtiyaç duyulmaktadır. Kampüs alanının geniş olması, sabit kameralar kullanılarak yangın durumunun tespit edilmesi probleminin kapsayıcı bir şekilde çözümünü hem maliyet hem de harcanacak iş gücü açısından zorlaştırmaktadır. Bu bakımdan insansız hava araçları kullanılarak kampüs içindeki görüntüler vasıtasıyla bir veri tabanı oluşturup, bu veri tabanı üzerinden görüntü işleme ile yapay zekâ yöntemlerini kullanarak yangın tespitinde bir modelin oluşturulması ve yine insansız hava aracı vasıtasıyla belirli periyotlarla yangın devriyesine çıkılması yoluyla başlangıç aşamasındaki yangınların konumlarının tespiti yüksek doğrulukla sağlanabilecektir.

Yapılan çalışmadaki ilk aşama olan veri tabanının oluşturulmasında 4k fotoğraf çekme kapasitesine sahip döner kanatlı insansız hava aracı kullanılarak, Bayburt üniversitesi Baberti külliyesi kampüs alanında çalışmaya ait fotoğraflar farklı zaman dilimlerinde elde edilmiştir. Çekilen fotoğrafların bina, yeşil alan, yol, ağaçlık alan gibi heterojen ortamların farklı yangın bağlamlarını temsil etmesi ve bulutlu, güneşli gibi farklı ışık

karakteristiklerini de içermesi sağlanmıştır. İlgili kampüs alanını temsil etmesi için 100 adet fotoğraf çekilmiş, bu fotoğrafların 50 tanesi fotoğraf düzenleme yazılımı olan Photoshop'un yapay zekâ ile entegre olan üretken dolgu (generative fill) özelliği kullanılarak düzenlenmiş ve yangın bileşenleri için eklentiler yapılmıştır. Ayrıca hassas düzenleme gerçekleştirilerek eklenen yangın bileşenlerinin ince görsel ayarları da sağlanmıştır. Üzerinde değişiklik yapılmayan ve düzenlenen görüntüler Şekil 3'de gösterilmektedir. Gerekli etiketleme işlemlerinin akabinde yangın içeren ve içermeyen yani toplam iki sınıfa ait fotoğraflar birleştirilerek çalışmada kullanılacak veri tabanı oluşturulmuştur.



Şekil 3. Veri tabanına ait örnek imgeler


### B. Görüntü İşleme

Yangın bileşenlerinden biri olan ateşin tespiti üzerine gerçekleştirilen ikinci aşamada bir imgede çıplak göz ile bakıldığında turuncu sarı ve yüksek parlaklık özelliklerine sahip ateş bileşenlerini arka plandan ayırmak için bir maske tasarlanmıştır. Bu tasarımda HSV renk uzayı kullanılmıştır. HSV renk uzayında bir renk, renk adı (hue), doygunluk (saturation) ve değer (value) bileşenleri ile tanımlanmaktadır. Bu bakımdan HSV modeli ile renk ve parlaklıkla ilgili bilgileri tespit etmek mümkündür. Bu amaçla veri tabanındaki tüm fotoğraflar, ilk elde edildiklerinde varsayılan olarak buldukları RGB renk uzayından HSV renk uzayına dönüştürülmüştür. Bu dönüşümün ardından ateş tespitinde kullanılacak maskenin

oluşturulmasında deneysel olarak tespit edilen ilgili değerler Denklem 1'de verilmektedir.

$$f(x,y) = \begin{cases} 1 & \text{Eğer} \\ 0 & \text{Diğer} \end{cases} \begin{cases} 0.01 < H(x,y) < 0.6 & \text{ve} \\ 0.85 < S(x,y) < 1 & \text{ve} \\ 0.31 < V(x,y) < 1 & \end{cases} \quad (1)$$

Burada  $H(x,y)$ ,  $S(x,y)$  ve  $V(x,y)$  değerleri sırasıyla bir imgedeki  $(x,y)$  uzamsal koordinatındaki renk tonu, doygunluk ve yoğunluk değerleridir. Denklem 1'de sınır şartları gösterilen filtrenin yangın içeren ve içermeyen imgelerdeki kullanılması ile elde edilen bazı sonuçlar Şekil 4'de verilmektedir.



Şekil 4. HSV uzayında filtre işlemi

### C. Sınıflandırma

Veri tabanında yangın var ve yangın yok sınıflarına ait etiketlenen tüm fotoğraflara filtre uygulandıktan sonra sınıflandırma modelinin oluşturulması işlemine geçilmiştir. Bu modeli oluşturulurken ilk aşamada tüm verilerin %80'i modelin eğitiminde ve kalan %20'si ise eğitimde geliştirilen modelin sınanması için test aşamasında kullanılmak üzere rastgele bölünmüştür. Ayrıca eğitim aşamasında 5 katmanlı çapraz doğrulama yöntemi de kullanılmıştır. Verilerin bölünme aşamasının ardından evrişimsel sinir ağları (ESA) kullanılarak sınıflandırma modeli geliştirilmiştir. ESA mimarisi çok katmanlı bir yapıdan oluşan derin öğrenme tabanlı bir mimaridir. Her katmanın farklı bir işlevi bulunmakta ve bir katmanın çıkışı

bileşenleri ardından gelen diğer katmanın giriş bileşenlerini oluşturmaktadır.

Sınıflandırma aşamasında başarıyı kanıtlanmış ESA tabanlı mevcut sınıflandırma modelleri, transfer öğrenme yolu ile çalışmaya uyarlanarak kullanılmıştır. Transfer öğrenme, büyük veri tabanlarının sınıflandırılmasında oluşturulan modelin daha küçük bir veri setindeki farklı veya benzer problemlerin çözümünde kullanılmasını inceleyen bir yaklaşımdır [21]. Yapılan çalışmada VGG16, VGG19 [22], DenseNet201 [23], InceptionV3 [24], MobileNetV2 [25], Resnet50, Resnet101 ve Resnet152 [26] mimarileri transfer öğrenme ile uygulanmıştır. Kullanılan tüm modellerde giriş olarak 256x256 piksel içeren filtrelenmiş görüntüler kullanılmıştır. Ayrıca sınıflandırma modelinin oluşturulmasında kullanılan parametrelerden batch değeri 8, epoch değeri ise 100 olarak alınmıştır.

#### D. Karşılaştırma

Yapılan çalışmada kullanılan yöntemlerin başarımlarının ölçülmesinde hata matrisi (confusion matrix) ve bu matristen elde edilen karşılaştırma metrikleri kullanılmıştır. Tablo 1’de gösterilen hata matrisi sayesinde bir sınıflandırma modelinde tahmin edilen değerlerin gerçekte var olan etiket değerleri ile kıyaslanması söz konusudur. Tablo 2’de ise hata matrisinden elde edilen farklı karşılaştırma metriklerinin hesaplanmasına yer verilmiştir.

Tablo 1. Hata Matrisi

Hata Matrisi		Gerçek	
		Pozitif	Negatif
Tahmin	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Tablo 2. Karşılaştırma Metrikleri

Metrik	Denklem
Doğruluk (Accuracy)	$\frac{TP + TN}{TP + TN + FP + FN}$
Duyarlılık (Recall)	$\frac{TP}{TP + FN}$
Kesinlik (Precision)	$\frac{TP}{TP + FP}$
F1 Skoru (F1 Score)	$\frac{2 \times (\text{Kesinlik} \times \text{Duyarlılık})}{\text{Kesinlik} + \text{Duyarlılık}}$

Son aşama olarak Tablo 1 ve Tablo 2’deki metrikler hesaplanarak uygulanan sınıflandırma modellerinin başarımları karşılaştırılmıştır. Karşılaştırma sonuçlarının tarafsız olarak elde edilebilmesi için modellerde kullanılan eğitim ve test kümeleri sabit olarak kullanılmıştır.

### III. BULGULAR

Yapılan çalışmada kullanılan mimarilere ait test hata matrisleri Tablo 3’de, karşılaştırma metriklerini içeren sonuçlar ise Tablo 4’de verilmektedir.

Tablo 3. Kullanılan modellere ait hata matrisleri

VGG16	$\begin{bmatrix} 10 & 0 \\ 2 & 8 \end{bmatrix}$
VGG19	$\begin{bmatrix} 9 & 1 \\ 0 & 10 \end{bmatrix}$
DenseNet201	$\begin{bmatrix} 10 & 0 \\ 1 & 9 \end{bmatrix}$
InceptionV3	$\begin{bmatrix} 10 & 0 \\ 2 & 8 \end{bmatrix}$
MobileNetV2	$\begin{bmatrix} 10 & 0 \\ 1 & 9 \end{bmatrix}$
Resnet50	$\begin{bmatrix} 10 & 0 \\ 2 & 8 \end{bmatrix}$
Resnet101	$\begin{bmatrix} 8 & 2 \\ 0 & 10 \end{bmatrix}$
Resnet152	$\begin{bmatrix} 10 & 0 \\ 1 & 9 \end{bmatrix}$

### IV. TARTIŞMA VE SONUÇLAR

Sonuçlar incelendiğinde HSV renk uzayında tasarlanan filtre vasıtası ile kullanılan tüm yöntemlerde yüksek başarıma ulaşıldığı görülmektedir. İlk olarak VGG16 mimarisinin kullanılması ile veri tabanındaki tüm ateş içeren test fotoğrafları tespit edilmekle beraber ateş bulunmayan 2 fotoğrafında ateş var olarak algılanması sonucunda toplamda %90 oranında bir sınıflandırma doğruluğu söz konusudur. VGG19 mimarisinin kullanılması ile gerçekte ateş içermeyen tüm fotoğraflar doğru tespit edilmesine rağmen gerçekte ateş içeren 10 fotoğraftan 1 tanesinin ateş içermediği algılanmıştır. Toplamda %95 oranında sınıflandırma doğruluğu elde edilmiştir. DenseNet201 mimarisinin kullanılması ile ateş içeren tüm fotoğraflar doğru tespit edilmiş fakat ateş içermeyen 1 adet fotoğraf ateş içeriyormuş gibi algılanmıştır. Bu mimaride de başarımlar %95 oranındadır. InceptionV3 ve

Resnet50 mimarileri ile elde edilen sonuçlar VGG16 mimarisinin kullanılması ile elde edilen sonuçların aynısıdır.

Tablo 4. Kullanılan modellere ait sınıflandırma sonuçları

<b>VGG16</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,83	1,00	0,91
Yangın Yok	1,00	0,80	0,89
Sınıflandırma Doğruluğu	0,90		
<b>VGG19</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	1,00	0,90	0,95
Yangın Yok	0,91	1,00	0,95
Sınıflandırma Doğruluğu	0,95		
<b>DenseNet201</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,91	1,00	0,95
Yangın Yok	1,00	0,90	0,95
Sınıflandırma Doğruluğu	0,95		
<b>InceptionV3</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,83	1,00	0,91
Yangın Yok	1,00	0,80	0,89
Sınıflandırma Doğruluğu	0,90		
<b>MobileNetV2</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,91	1,00	0,95
Yangın Yok	1,00	0,90	0,95
Sınıflandırma Doğruluğu	0,95		
<b>Resnet50</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,83	1,00	0,91
Yangın Yok	1,00	0,80	0,89
Sınıflandırma Doğruluğu	0,90		
<b>Resnet101</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	1,00	0,80	0,89
Yangın Yok	0,83	1,00	0,91
Sınıflandırma Doğruluğu	0,90		
<b>Resnet152</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 Skoru</b>
Yangın Var	0,91	1,00	0,95
Yangın Yok	1,00	0,90	0,95
Sınıflandırma Doğruluğu	0,95		

Aynı şekilde MobileNetV2 ve Resnet152 mimarisi ile elde edilen sonuçlar, DenseNet201 mimarisi ile elde edilen sonuçlarla aynıdır. Resnet101 mimarisi ile de ateş içermeyen tüm fotoğraflar doğru tespit edilmesine rağmen, ateş içeren 2 fotoğraf yanlış tespit edilmiştir. Bu mimarinin de toplam sınıflandırma doğruluğu üzerine başarıyı %90 olarak tespit edilmiştir.

Sınıflandırma modellerinin yangının varlığı ve yokluğu üzerine iki sınıf için genel değerlendirmesi yapıldığında karşılaştırma metriklerinden F1-Skoru

açısından VGG19, DenseNet201, MobilenetV2 ve Resnet152 mimarileri en yüksek değerlere (%95) sahiptir. Fakat bu mimariler içinde VGG19 mimarisinin kesinlik değeri %90, duyarlılık değeri %100 iken DenseNet201, MobilenetV2 ve Resnet152 mimarilerinin kesinliği %100, duyarlılık değeri ise %91 olarak bulunmuştur. Bununla beraber bu mimariler en yüksek doğruluğa (%95), sahip oldukları için en başarılı yöntemlerdir. Ayrıca bu mimariler ile oluşturulan modellerin yangının varlığını veya yokluğunu sınıflandırma görevi için kesinlik ile duyarlılık arasında iyi bir denge kurdukları görülmektedir. Resnet101 mimarisi bu mimarilere kıyasla daha düşük doğruluk (%90) değerine rağmen yüksek duyarlılığa (%100) sahiptir. Ayrıca bu modelde kesinlik (%80) biraz daha düşüktür. VGG16, InceptionV3 ve Resnet50 mimarileri, diğer modellere kıyasla yüksek kesinlik (%100) değerine sahip olmalarına rağmen, en düşük doğruluğa (%90) ve duyarlılığa (%83) sahiptir. Dolayısıyla yangının varlığını veya yokluğunu tespit etmede VGG19, DenseNet201, MobilenetV2 ve Resnet152 mimarilerinin diğer mimarilerden daha başarılı olduğu söylenebilir. Fakat Kesinlik ve Duyarlılık metrikleri dikkate alındığında yanlış alarmlardan kaçınmaya (Yanlış Pozitifleri en aza indirmeye) öncelik verilirse, daha yüksek Kesinliğe (%100) sahip olan DenseNet201, MobilenetV2 ve Resnet152 mimarilerini tercih etmek daha avantajlı olacaktır. Bununla beraber mümkün olduğu kadar çok sayıda gerçek yangın örneğini yakalamaya öncelik verilir ise (Gerçek Pozitifleri en üst düzeye çıkararak), daha yüksek Duyarlılık (%100) özelliğine sahip VGG19 mimarisi tercih edilebilir.

Sonuç olarak kullanılan mimariler arasındaki seçim, uygulamanın özel gereksinimlerine ve kısıtlamalarına bağlıdır. Bir adet hatalı tespite rağmen (yangın yok iken varmış gibi algılayan) tüm yangınları doğru olarak tespit edebilme kabiliyetine sahip DenseNet201, MobilenetV2 ve Resnet152 mimarileri projenin amacı olan erken dönemde yangın tespiti için daha uygun olduğu tespit edilmiştir.

## TEŞEKKÜR

Yazarlar, bu çalışmayı 2209-A kapsamında 1919B012217591 numaralı projeye destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumuna (TÜBİTAK) teşekkür ederler.

## KAYNAKLAR

- [1] Kukuk, S. B. & Kilimci, Z. H. (2021). Comprehensive Analysis of Forest Fire Detection using Deep Learning Models and Conventional Machine Learning Algorithms . *International Journal of Computational and Experimental Science and Engineering* , 7 (2) , 84-94 . DOI: 10.22399/ijcesen.950045
- [2] C.-B. Liu and N. Ahuja, "Vision based fire detection," in *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004, 2004.*
- [3] T.-H. Chen, P.-H. Wu, and Y.-C. Chiou, "An early fire-detection method based on image processing," in *2004 International Conference on Image Processing, 2004. ICIP '04, 2005..*
- [4] B. Ugur Töreyn, Y. Dedeoğlu, U. Güdükbay, and A. Enis, "Computer vision based method for real-time fire and flame detection," *Pattern recognition letters*, vol. 27, no. 1, 2006.
- [5] E. Den Breejen *et al.*, "Autonomous forest fire detection Coimbra, Portugal: ADAIAssociacao para o Desenvolvimento da Aerodinamica Industrial," pp. 2003–2012, 1998.
- [6] D. Tezza and M. Andujar, "The state-of-the-art of human–drone interaction: A survey," *IEEE Access*, vol. 7, pp. 167438–167454, 2019.
- [7] C. Yuan, Z. Liu, and Y. Zhang, "UAV-based forest fire detection and tracking using image processing techniques," in *2015 International Conference on Unmanned Aircraft Systems (ICUAS), 2015.*
- [8] C. Yuan, K. A. Ghamry, Z. Liu, and Y. Zhang, "Unmanned aerial vehicle based forest fire monitoring and detection using image processing technique," in *2016 IEEE Chinese Guidance, Navigation and Control Conference (CGNCC), 2016.*
- [9] S. Sudhakar, V. Vijayakumar, C. Sathiya 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.
- [10] W. Lee, S. Kim, Y.-T. Lee, H.-W. Lee, and M. Choi, "Deep neural networks for wild fire detection with unmanned aerial vehicle," in *2017 IEEE International Conference on Consumer Electronics (ICCE), 2017.*
- [11] B 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.
- [12] J. Seebamrungsat, S. Praising, and P. Riyamongkol, "The Analysis of Directional Time Series: Applications to Wind Speed and Direction, ser," in *Third ICT International Student Project Conference (ICT-ISPC)*, vol. 61, Nakhonpathom, Thailand; Berlin, Germany: Springer, 1989, pp. 95–98.
- [13] M. S. Allauddin, G. S. Kiran, G. R. Kiran, G. Srinivas, G. U. R. Mouli, and P. V. Prasad, "Development of a surveillance system for forest fire detection and monitoring using drones," in *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium, 2019.*
- [14] Z. Jiao *et al.*, "A deep learning based forest fire detection approach using UAV and YOLOv3," in *2019 1st International Conference on Industrial Artificial Intelligence (IAI), 2019.*
- [15] M. M. Fouda, S. Sakib, Z. M. Fadlullah, N. Nasser, and M. Guizani, "A lightweight hierarchical AI model for UAV-enabled edge computing with forest-fire detection use-case," *IEEE Netw.*, vol. 36, no. 6, pp. 38–45, 2022.
- [16] 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.*
- [17] A. Z. R. Rahman, "Unmanned Aerial Vehicle Assisted Forest Fire Detection Using Deep Convolutional Neural Network," *Intelligent Automation and Soft Computing*, vol. 35, pp. 3259–3277, 2023.
- [18] F. M. A. Hossain, Y. Zhang, C. Yuan, and C.-Y. Su, "Wildfire flame and smoke detection using static image features and artificial neural network," in *2019 1st International Conference on Industrial Artificial Intelligence (IAI), 2019.*
- [19] L. Zhang, M. Wang, Y. Fu, and Y. Ding, "A forest fire recognition method using UAV images based on transfer learning," *Forests*, vol. 13, no. 7, p. 975, 2022.
- [20] Y. Chen *et al.*, "UAV image-based forest fire detection approach using convolutional neural network," in *2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA), 2019.*
- [21] F. Zhuang *et al.*, "A comprehensive survey on transfer learning," *Proc. IEEE Inst. Electr. Electron. Eng.*, vol. 109, no. 1, pp. 43–76, 2021.
- [22] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv [cs.CV]*, 2014.
- [23] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017.*
- [24] 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.*
- [25] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," 2018.
- [26] 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.*