

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AFET YÖNETİMİ KAPSAMINDA AKILLI ŞEHİRLERDE
DEPREM SONRASI YANGINLARIN VE COĞRAFİ
KONUMLARININ DERİN ÖĞRENME VE STEREO GÖRÜŞ
TABANLI SİSTEMLERLE TESPİTİ

Tacettin KÜSTÜ

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Danışman

Prof. Dr. Alev TAŞKIN

Mayıs, 2023

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**AFET YÖNETİMİ KAPSAMINDA AKILLI ŞEHİRLERDE
DEPREM SONRASI YANGINLARIN VE COĞRAFİ
KONUMLARININ DERİN ÖĞRENME VE STEREO GÖRÜŞ
TABANLI SİSTEMLERLE TESPİTİ**

Tacettin KÜSTÜ tarafından hazırlanan tez çalışması 30.03.2023 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Alev TAŞKIN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Prof. Dr. Alev TAŞKIN, Danışman

Yıldız Teknik Üniversitesi

Prof. Dr. Selçuk ÇEBİ, Üye

Yıldız Teknik Üniversitesi

Doç. Dr. Erkan ÇELİK, Üye

İstanbul Üniversitesi

Danışmanım Prof. Dr. Alev TAŞKIN sorumluluğunda tarafımda hazırlanan Afet Yönetimi Kapsamında Akıllı Şehirlerde Deprem Sonrası Yangınların ve Coğrafi Konumlarının Derin Öğrenme ve Stereo Görüş Tabanlı Sistemlerle Tespiti başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Tacettin KÜSTÜ

İmza



Sevgili Aileme...

TEŞEKKÜR

Bu tezin hazırlanması ve eğitimim süresince bana olan katkılarından ötürü, başta tez danışmanım, değerli hocam, Prof. Dr. Alev TAŞKIN olmak üzere tüm Endüstri Mühendisliği Bölümü öğretim üyeleri ve personeline teşekkür ederim.

Ayrıca; yüksek lisans eğitim sürecimde, 2210-A Yurt İçi Genel Yüksek Lisans Burs Programı kapsamındaki desteklerinden ötürü Bilim İnsanı Destek Programları Başkanlığı (BİDEB)'na da teşekkürlerimi iletmek isterim.

Tacettin KÜSTÜ



İÇİNDEKİLER

SİMGE LİSTESİ	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	x
ÖZET	xi
ABSTRACT	xiii
1 GİRİŞ	1
1.1 Literatür Özeti	6
1.1.1 Geleneksel Yöntemlerle Görüntüye Dayalı Yangın ve Duman Tespit Çalışmaları.....	6
1.1.2 Derin Öğrenme Algoritmalarıyla Görüntü Tabanlı Yangın ve Duman Tespit Çalışmaları.....	12
1.2 Tezin Amacı.....	26
1.3 Orijinal Katkı	26
2 METODOLOJİ	28
2.1 Önerilen Çerçeve.....	28
2.2 Nesne Tespit Algoritması Olarak YOLOv5s	29
2.2.1 Geleneksel Nesne Tespit Algoritmaları	30
2.2.2 Derin Öğrenme Tabanlı Nesne Tespit Algoritmaları.....	32
2.3 Derinlik Tahmini Metodu Olarak Stereo Görüş	41
2.3.1 ToF.....	42
2.3.2 Ultrasonik Sensörler.....	42
2.3.3 LIDAR.....	42
2.3.4 Stereo Görüş.....	43
3 UYGULAMA	48
3.1 Uygulama ve İstanbul Örneği	48
4 SONUÇ VE ÖNERİLER	57
4.1 Deneysel Sonuçlar.....	57
4.2 Öneriler	59
KAYNAKÇA	61
TEZDEN ÜRETİLMİŞ YAYINLAR	70

SİMGE LİSTESİ

R	Döndürme
d	Eşlenik noktalar arasındaki mesafe
P	Gerçek dünyadaki nokta
E	Gerekli matris
n	Normal vektörü
f	Odak Uzunluğu
t	Öteleme
Z	P noktasının derinliği
x_r	P noktasının sağ kamera tarafından alınan görüntüdeki izdüşümü
x_l	P noktasının sol kamera tarafından alınan görüntüdeki izdüşümü
p_r	Sağ kamera görüntü düzleminde P noktasının görünümü
K_r	Sağ kamera içsel matrisi
C_r	Sağ kamera koordinat merkezi
f_r	Sağ kamera Odak Uzunluğu
p_l	Sol kamera görüntü düzleminde P noktasının görünümü
K_l	Sol kamera içsel matrisi
C_l	Sol kamera koordinat merkezi
f_l	Sol kamera Odak Uzunluğu
L	Taban çizgisi
F	Temel matris

KISALTMA LİSTESİ

CNN	Convolutional Neural Network
CSP	Cross Stage Partial Network
C-GICA	Cumulative Geometric Independent Component Analysis
CycleGAN	Cycle-Consistent Adversarial Networks
DCGANs	Deep Convolutional Generative Adversarial Networks
CONV	Evrişim Katmanı
Fast R-CNN	Fast Region-Based Convolutional Neural Network
Faster R-CNN	Faster Region-Based Convolutional Neural Network
FPS	Frame Per Second
GMFs	Gaussian Membership Functions
GICA	Geometric Independent Component Analysis
GMM	Gizli Markov Modeli
GMHI	Gradient Motion History Image
HOG	Histogram of Oriented Gradients
HSI	Hue, Saturation, Intensity
ICT	Information and Communications Technology
İHA	İnsansız Hava Araçları
IoT	Internet of Things
IoU	Intersection over Union
K-NN	K-Nearest Neighbor
LIDAR	Laser Imaging Detection and Range (LIDAR)
LBP	Local Binary Patterns
mAP	Mean Average Precision
MSCNN	Multi-Scale Deep Convolutional Neural Network
NMS	Non-Max Suppression
ROI	Region of Interest
RPN	Region Proposal Network
R-CNN	Region-Based Convolutional Neural Network

SIFT	Scale Invariant Feature Transformation
SSD	Single-Shot Multibox Detector
SEP	Spatial Expansion Parameter
SURF	Speeded-Up Robust Features
SVM	Support Vector Machine
FC	Tam Bağlantılı Katman
ToF	Time of Flight
WSN	Wireless Sensor Network
YOLO	You Only Look Once



ŞEKİL LİSTESİ

Şekil 2.1 Çalışmada önerilen yangın tespit mimarisi	29
Şekil 2.2 Bilgisayarlı görü temel çalışma alanları	30
Şekil 2.3 Geleneksel nesne tespit algoritması çalışma adımları	31
Şekil 2.4 Genel CNN mimarisi	33
Şekil 2.5 Maksimum havuzlama işlem gösterimi	34
Şekil 2.6 Nesne tespit algoritmaları yapıları	35
Şekil 2.7 IoU hesaplaması	36
Şekil 2.8 R-CNN Mimarisi [111]	37
Şekil 2.9 Fast R-CNN Mimarisi [112]	37
Şekil 2.10 Faster R-CNN Mimarisi [113]	38
Şekil 2.11 Önemli modellerin hız ve mAP değerleri [120]	39
Şekil 2.12 YOLOv5'in detaylı mimarisi	40
Şekil 2.13 Stereo görüş temellerinin gösterimi	43
Şekil 2.14 Kameralar arasındaki ötelenme (translation) ve döndürülme (rotation)	45
Şekil 2.15 Epipolar geometri yapısı	45
Şekil 3.1 (a) Veri setindeki görüntü sayısı (b) Görüntülere göre bounding-box boyut dağılımı	49
Şekil 3.2 Veri setinden örneklem olarak seçilmiş görüntüler	49
Şekil 3.3 Eğitim süreci kayıp eğrisi	51
Şekil 3.4 Veri kümesinde yangın tespit sonuçları	51
Şekil 3.5 Satranç tahtaları ile kalibrasyon	53
Şekil 3.6 Senaryoya göre yerleştirilen kamera konumları	56
Şekil 3.7 Gerçek hayat uygulamasından sahneler	57

TABLO LİSTESİ

Tablo 1.1 İstanbul'da MW=7,5 büyüklüğündeki deprem senaryosu için bina hasar tahmin sonuçları [25]	3
Tablo 1.2 İstanbul'da MW=7,5 büyüklüğünde gündüz gerçekleşen deprem senaryosu için can kaybı ve yaralı sayısı tahmin sonuçları [25]	4
Tablo 1.3 İstanbul'da MW=7,5 büyüklüğünde gece gerçekleşen deprem senaryosu için can kaybı ve yaralı sayısı tahmin sonuçları [25]	5
Tablo 1.4 Literatürdeki geleneksel yöntemlerle yapılan çalışmaların kullandıkları metotlara göre kıyaslanması	19
Tablo 1.5 Literatürdeki derin öğrenme algoritmalarıyla yapılan çalışmaların kullandıkları yöntemlere göre kıyaslanması	22
Tablo 3.1 Eğitim için kullanılan parametreler	50
Tablo 3.2 Mesafe ölçüm test sonuçları	54
Tablo 4.1 Test sonuçlarının farklı kamera kombinasyonlarına göre karşılaştırılması ...	58

Afet Yönetimi Kapsamında Akıllı Şehirlerde Deprem Sonrası Yangınların ve Coğrafi Konumlarının Derin Öğrenme ve Stereo Görüş Tabanlı Sistemlerle Tespiti

Tacettin KÜSTÜ

Endüstri Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Prof. Dr. Alev TAŞKIN

Her geçen gün kalabalıklaşan şehirler; çarpık kentleşme neticesinde altyapı, ulaşım, güvenlik ve çevre ile ilgili birçok sorunla karşı karşıya kalmaktadır. Bu tür sorunlar nedeniyle şehirler doğal afetlere karşı kırılgan hale gelmektedir. Bu sebeple, kent yaşamı kapsamında, doğal afetlere karşı birçok hazırlık yapılmaktadır. Ancak; bu hazırlıklar incelendiğinde, birçok şehir için, ikincil afetlerin göz ardı edildiği görülmektedir. İkincil afetler çok çeşitli olmakla birlikte, en yıkıcı ve sık görülen ikincil afetlerden birisi deprem sonrası yangınlardır. Bu çalışmada, şehirlerde deprem sonrası oluşabilecek kaotik ortamlarda, yangınların neden olduğu kayıpları en aza indirmek için yenilikçi bir erken yangın tespit sistemi önerilmiştir. Bu sistem, evrişimsel sinir ağları (CNN) tabanlı YOLO modeli ile yangını tespit eden, stereo görüş/epipolar geometri ile yangının coğrafi konumunu belirleyen ve kablosuz sensör ağı (WSN) aracılığıyla afet yönetim merkezine bilgi aktaran bir yapıdır. Bu sistem ile birlikte; deprem sonrası yangınların görsel tabanlı algoritmalarla gerçek zamanlı tespitinin sağlanması, yangının coğrafi konumunun elde edilmesi ve afet yönetim merkezine bildirilmesi ile yangına hızlı müdahale imkanı yaratılması, tüm sürecin insan faktörlerinden bağımsız olarak ve deprem sonrası oluşabilecek iletişim kesintilerinden etkilenmeden gerçekleştirilebilmesi, stereo görüş

tekninin kullanılarak düşük maliyet ve yüksek dođrulukla konum tespiti yapılabilmesi amaçlanmıştır. Gerçekleştirilen deneysel test sonuçları, önerilen sistemin düşük maliyetle, yüksek güvenilirlikle ve dođrulukla deprem sonrası yangın ve yangın konumu tespiti için faydalı olabileceđini göstermektedir.

Anahtar Kelimeler: Akıllı şehirler, ikincil afetler, deprem sonrası yangın, stereo görüő, afet yönetimi.



Deep Learning and Stereo Vision Based Detection of Post-Earthquake Fire Geolocation for Smart Cities within the Scope of Disaster Management

Tacettin KÜSTÜ

Department of Industrial Engineering

Master of Science Thesis

Supervisor: Prof. Dr. Alev GÜMÜŞ

Cities, which are getting crowded day by day, face many problems such as increasing need for planning, incomplete infrastructure, heavy traffic and security. Due to such problems, the cities become vulnerable to natural disasters. For this reason, many preparations are made against natural disasters within the scope of urban life. However, when these preparations are examined, it is seen that secondary disasters are ignored for many cities. One of the most destructive and frequent secondary disasters is fires after earthquakes. In this study, an early fire detection system is proposed in order to minimize the losses caused by fires in the chaotic environment that may occur after earthquakes in cities. This system is a structure that detects fire with convolutional neural network (CNN) based YOLO model, determines the geo-location of the fire with stereo vision/epipolar geometry and provides information to the disaster management center via wireless sensor network (WSN). With this system; it is aimed to provide real-time detection of fires after the earthquake with visual-based algorithms, to obtain the geographical location of the fire and reporting it to the disaster management center, to create a rapid response to the fire, to perform the whole process independently of human factors and without being affected by the communication interruptions that may occur

after the earthquake, to use stereo vision technique to detect location of fire. Experimental test results verify that the proposed system would be useful for post-earthquake fire and geo-location of fire detection with low cost, high reliability and high accuracy.

Keywords: Smart cities, secondary disaster, post-earthquake fire, stereo vision, disaster management.



Şehirleşme tüm dünyada hızla artmaktadır. Yapılan çalışmalarda şehirlerin nüfuslarının ivme kazanarak artmaya devam edeceği vurgulanmaktadır [1]. Birleşmiş Milletler tarafından yayınlanan rapora göre, 2050 yılına kadar dünya nüfusunun %68'inin kentsel alanlarda yaşayacağı öngörülmektedir [2].

Her geçen gün kalabalıklaşan şehirler, artan planlama ihtiyacı, altyapı ve güvenlik, ulaşım zorluğu ve aşırı kaynak kullanımı gibi birçok sorunla karşı karşıya kalmaktadır. Bu tür sorunların üst üste gelmesiyle günümüz kentlerinde deprem, sel, yangın, heyelan, fırtına gibi doğal afetlere karşı kırılgan bir yapı ortaya çıkmıştır.

Kalabalık şehirlerdeki afet tehlikesi daha derinlemesine incelendiğinde, dikkat edilmesi gereken bir diğer noktanın ikincil afetler olduğu görülmektedir. İkincil afetler, bir afet sonrasında ve ilk afetin etkisiyle meydana gelen yeni bir afet olayı veya olayları olarak tanımlanır. Deprem sonrası ikincil afetler ise, deprem sonrası meydana gelebilecek yangın, tsunami, sıvılaşma ve heyelan gibi afetleri ele alınmaktadır. Bu durum göz ardı edilmemesi gereken bir durumdur; öyle ki bazı vakalarda, deprem ve tsunami sonrasında çıkan yangınlar, sarsıntıdan kaynaklı kayıplardan çok daha fazla can ve mal kaybına neden olmuştur [3].

Deprem sonrası yangınlar, depremlerin neden olduğu en tehlikeli ikincil afetlerdir [4] ve bazı kayıtlara göre [5] deprem sonrası çoklu yangın olayları ağır can kayıplarına ve ciddi maddi hasarlara neden olmuştur. Örneğin, 1994 Northridge depreminin devamı olarak yaklaşık 110 yangın rapor edilmiştir [6]. Japonya'daki 1995 Hanshin depreminin ardından çıkan yangınlar 7.504 yapıyı tahrip etmiş ve 500'den fazla insanın ölümüne sebep olmuştur [7]. Daha yakın bir tarihte ülkemizde, 1999 yılında İzmit Körfezi'nde meydana gelen deprem sonucunda, TÜPRAŞ petrol şirketine ait büyük rafineri tesisinde petrol sızıntıları ve yangınlar meydana gelmiştir. Felaket birkaç gün sürmüş ve çevreye büyük zararlar vermiştir [8]. 2011 Tohoku depreminden sonraki 330 yangının yaklaşık %40'ı büyük depremden sonra meydana gelmiştir [9]. Bu örneklerden de anlaşılacağı üzere, olası deprem sonrası yangın afetlerinin etkilerini azaltmak için araştırma yapılması bir zorunluluktur. Bu amaçla akıllı şehirlerde, afet yönetim sistemleri kullanılarak deprem

sonrası yangın olaylarının canlılar üzerindeki olumsuz etkilerinin azaltılabileceği değerlendirilmektedir.

Afetlerin, toplumsal yaşam üzerindeki kontrol edilemez etkileri, insanların afetlere karşı önlem almaları gerekliliğini ortaya çıkarmıştır. Afet yönetim sistemleri, afetlerin etkilerini en aza indirmek için afet öncesi ve sonrasında uygulanan bir dizi yol gösterici faaliyetlerdir. Afet yönetiminin etkin bir şekilde uygulanması ile maddi ve manevi hasar kaybı büyük ölçüde azaltılabilir. Bu nedenle afet yönetimi; Bilgisayar Bilimleri, Çevre Bilimleri ve Sağlık Bilimleri dahil olmak üzere birçok araştırma topluluğu tarafından ilgi görmüştür. Bu noktada tüm bu disiplinleri bir araya getirmek ve uygulamaları hayata geçirmek için akıllı şehir ortamlarının çok uygun altyapılar oluşturduğu görülmektedir.

Akıllı Şehirler Konseyi'ne göre akıllı şehirler; yaşanabilirliğini, çalışabilirliğini ve sürdürülebilirliğini artırmak için bilgi ve iletişim teknolojilerini (Information and Communications Technology (ICT)) kullanan şehirlerdir [10]. Akıllı şehirlerin temel amacı; ICT, nesnelerin interneti (Internet of Things (IoT)), kablosuz sensör ağı (Wireless Sensor Network (WSN)) ve diğer ilgili bilgi işlem teknolojilerine dayalı yaşam için daha iyi bir kentsel ortam sağlamaktır [11]. Akıllı şehirlerde tüm bilgiler gerçek zamanlı olarak elde edilir ve bu bilgiler öğrenme parametrelerinin sürekli izlenmesi ve uyarlanması için kullanılır [12]. Ayrıca, mevcut bazı akıllı şehir teknolojileri, özellikle afet verilerinin toplanması için çok uygundur. Çünkü kaotik afet koşullarında, insan etmeninden bağımsız olarak, karar vericilere bilgi aktarmaya devam edebilir ve onların alacağı kararlara olumlu tesir edebilirler [13].

Bu kapsamda Avrupa Birliği [14,15], Amerika Birleşik Devletleri [16], Japonya [17], Çin, Kore ve Singapur [18,19] ICT'ye dayalı akıllı şehirler geliştirmeye başlamıştır. Örneklerden anlaşılacağı üzere, günümüzde, birçok modern şehir akıllı şehir uygulamalarına odaklanmaktadır [20-24]. Bu kapsamda, akıllı şehir alanında araştırma ve geliştirme çalışmaları yapan şehirlerden birisi de İstanbul'dur.

Araştırma alanımız olan İstanbul, Kuzey Anadolu Fay Hattının hemen kuzeyinde yer almakta olup büyük bir deprem riski ile karşı karşıyadır. Marmara Denizi'nin altından geçen Kuzey Anadolu Fay Hattının bazı bölümlerinin kırılması sonucu meydana gelebileceği düşünülen depremin İstanbul'u ciddi şekilde etkileyeceği tahmin edilmektedir.

İstanbul Büyükşehir Belediyesi koordinasyonunda yürütülen 'İstanbul İli Olası Deprem Kayıp Tahminlerinin Güncellenmesi Projesi', İstanbul için olası MW=7,5 büyüklüğündeki bir depremin sonucunda ortaya çıkabilecek vahim tabloyu göz önüne sermektedir. Bu projenin sonuçlarına göre, MW=7,5 büyüklüğündeki deprem senaryosunda, binaların %26'sının hafif, %13'ünün orta, %3'ünün ağır ve %1'inin de çok ağır hasar görmesi beklenmektedir. Çalışma kapsamında, İstanbul'da incelenen toplam bina sayısı 1.166.330'dur. Ağır ve çok ağır hasarlı binaların deprem hasarı onarılamaz düzeydedir ve bu hasar seviyelerindeki binaların yıkılıp yeniden yapılması gerekmektedir. Öte yandan, orta derecede hasarlı binaları onarmak yerine, yıkmak ve yeniden inşa etmek genellikle daha uygundur. Tablo 1.1 ve Tablo 1.2'de gösterildiği gibi, deprem senaryosunda İstanbul'da 14.150 can kaybının olabileceği ve İstanbul'daki binaların %17'sinin (yaklaşık 194.000 bina) orta ve üzeri hasarlı olacağı tahmin edilmektedir. Yaklaşık 972.000 binanın ise hasarsız veya hafif hasarlı olarak depremi atlattığı öngörülmüştür [25].

Tablo 1.1 İstanbul'da MW=7,5 büyüklüğündeki deprem senaryosu için bina hasar tahmin sonuçları [25]

Hasar Seviyesi	Analiz Yöntemi			Ortalama	Toplam Bina Sayısına Oranı
	CSM	MADRS	CM		
Çok Ağır Hasarlı	18,580	9,309	12.595	13,495	%1,2
Ağır Hasarlı	39,512	27,131	36.391	34,345	%2,9
Orta Hasarlı	143,136	129,554	166.966	146,552	%12,6
Hafif Hasarlı	282,953	289,787	332.139	301,626	%25,9
Hasarsız	682,149	710.549	618,239	670,312	%57,5

*CSM: Kapasite Spektrum Yöntemi (Capacity Spectrum Method)

*MADRS: Değiştirilmiş İvme-Deplasman Tepki Spektrum Yöntemi (Modified Acceleration-Displacement Response Spectrum)

*CM: Katsayı Yöntemi (Coefficient Method)

Aynı çalışmaya göre; MW=7,5 büyüklüğünde deprem senaryosunun gece ve gündüz oluşma olasılığı için de ayrı ayrı can kaybı ve yaralı sayısı tahminleri yapılmıştır. Çünkü şehir halkının, gece ve gündüz nüfus dağılımları farklı şekillerde olmaktadır. Tablo 1.3'de gösterildiği gibi, bu büyüklükteki deprem senaryosunun gece meydana gelmesi durumunda İstanbul'da yaklaşık 14.150 can kaybının olabileceği tahmin edilmektedir. Depremin gündüz meydana gelmesi durumunda ise, beklenen can kaybı ortalama 12.400 civarındadır. Gece 8.100, gündüz 7.450 kişinin ağır şekilde yaralanacağı tahmin edilmiştir. Ayrıca hastane koşullarında tedavi edilmesi gereken yaralı sayısı tahminleri; gece depremleri için 39.650, gündüz depremleri için 37.500'dür [25]. Bu ölçekte bir yıkımın; kent genelinde kaotik ve trajik bir ortam yaratacağına şüphe yoktur.

Tablo 1.2 İstanbul'da MW=7,5 büyüklüğünde gündüz gerçekleşen deprem senaryosu için can kaybı ve yaralı sayısı tahmin sonuçları [25]

Yaralanma Seviyesi	Analiz Yöntemi			Ortalama
	CSM	MADRS	CM	
Can kaybı (4. Seviye)	14.373	8.124	14.757	12.418
Ağır Yaralı (3. Seviye)	9.742	4.842	7.754	7.446
Hastanede Tedavi (2. Seviye)	42.138	26.043	44.317	37.499
Hafif Yaralı (1. Seviye)	79.391	53.535	86.684	73.203

Tablo 1.3 İstanbul'da MW=7,5 büyüklüğünde gece gerçekleşen deprem senaryosu için can kaybı ve yaralı sayısı tahmin sonuçları [25]

Yaralanma Seviyesi	Analiz Yöntemi			Ortalama
	CSM	MADRS	CM	
Can kaybı (4. Seviye)	13.961	9.373	19.109	14.148
Ağır Yaralı (3. Seviye)	8.712	5.298	10.254	8.088
Hastanede Tedavi (2. Seviye)	39.134	27.183	52.605	39.641
Hafif Yaralı (1. Seviye)	73.350	53.986	98.399	75.245

İstanbul'da meydana gelebilecek büyük ölçekli afetlerin önüne geçebilmek için akıllı şehir planına uygun olarak, afet yönetimi alanında, teknolojik yatırımlar yapılmaktadır. Örneğin, Dinamik Deprem Hasar Kayıp Sistemi, Taşkın Erken Uyarı Sistemi, Acil Ulaşım Eylem Planı, İstanbul Deprem Master Planı, Deprem Zemin Etüt Çalışmaları, Otomatik Meteoroloji Gözlem İstasyonları, Buzlanma Erken Uyarı Sistemi [26] gibi faaliyetler İstanbul Büyükşehir Belediyesi Afet Koordinasyon Merkezi (AKOM) sorumluluğunda yürütülmektedir. Böylece çeşitli afetler karşısında oluşabilecek zararların etkileri en aza indirilmek istenmektedir.

Deprem sonrası oluşabilecek kaotik ortamlar da göz önüne alındığında; deprem sonrası yangınlara karşı otonom sistemlerin kullanılması gerekliliği ortaya çıkmaktadır. Çünkü, tecrübeler göstermiştir ki; büyük bir depremden sonra iletişim hatları devre dışı kalmakta, altyapı sistemleri çökmekte ve insanlar bireysel kaygılarını toplumsal kaygılardan daha üstün tutmaktadır. Bu durumda insana bağımlı sistemlerin, deprem sonrası ikincil afetler için büyük bir risk içerebileceği değerlendirilmiştir.

Bu çalışmada; yukarıda belirtilen sorunları gidermek için, deprem sonrası erken yangın tespit sistemi önerilmektedir. Bu sistem, evrimsel sinir ağları (Convolutional Neural Network (CNN)) tabanlı You Only Look Once (YOLO) algoritması ile yangını tespit eden, depreme dayanıklı ve jeneratör ile beslenen telekomünikasyon kuleleri üzerine kurulu iki veya daha fazla kamera ile stereo görüş/epipolar tekniğini kullanarak yangının

coğrafi konumunu belirleyen ve WSN aracılığıyla afet yönetim merkezine elde edilen bilgileri ileten bileşenleri içermektedir.

Çalışmanın geri kalanı şu şekilde yapılandırılmıştır: Deprem sonrası yangın ve duman tespiti ile ilgili literatür taraması Bölüm 1.1'de sunulmaktadır. Önerilen çerçeve ve yöntemler Bölüm 2'de açıklanmaktadır. Uygulama detayları Bölüm 3'te, Sonuçlar ve öneriler Bölüm 4'te ele alınmıştır.

1.1 Literatür Özeti

Literatürde; görüntüye dayalı yangın ve duman tespit çalışmaları incelendiğinde iki döneme ayrılan bir gelişim süreci ile karşılaşılmaktadır. İlk dönemde, yangın ve duman tespiti daha çok manuel olarak ayarlanan kurallara ve sınıflandırıcılara dayanmıştır. Bu periyotta icra edilen çalışmalarda, geleneksel yöntemler ve algoritmalar tercih edilmiştir. İkinci dönemde ise, daha sıklıkla derin öğrenme yöntemlerine dayanan yaklaşımlar kullanılmıştır.

1.1.1 Geleneksel Yöntemlerle Görüntüye Dayalı Yangın ve Duman Tespit Çalışmaları

Daha önce bahsedildiği gibi, geleneksel yöntemlerinin sıklıkla kullanıldığı bu dönemde renkli modeller ve manuel olarak tasarlanmış özellikler kullanılarak görüntü tabanlı yangın tespit çalışmaları yapılmıştır [32-39]. İlgili çalışmalarda genellikle alevin ve dumanın karakteristik renk, şekil ve hareket özelliklerine odaklanılmıştır.

Horn vd. [40] gerçek zamanlı alev tespiti için ton, doygunluk, yoğunluk (Hue, Saturation, Intensity (HSI)) renk modelini kullanmışlardır. HSI ile renk modeline dayalı yangın alevi özellikleri görüntüler analiz edilerek çıkarılmıştır. Daha sonra bu alev özelliklerine göre kırmızı ve turuncu renkli bölgeler kabaca görüntüden ayrıştırılmıştır. Elde edilen görüntüye, ateşe benzeyen ama ateş olmayan alanlardan kurtulmak için, renk maskeleyme tekniği uygulanmıştır. Son olarak, kullanıcıların detaylı olarak bilgilendirilmesi için yangın alevlerinin kuvvet derecesini tahmin etmeye yönelik algoritma ilave edilmiştir. Marbach vd. [41], görüntü sensörü tarafından yakalanan yangın yoğunluğunun geçici özelliklerini kullanan gerçek zamanlı bir yangın tespit algoritması önermişlerdir. Görüntü üzerindeki, alev bölgesine aday alanları seçmek için tam görüntü dizileri analiz edilmiştir. Aday alandan karakteristik yangın özellikleri çıkarılmış, daha sonra yangın ve yangın dışı

kalıpların varlığını belirlemek için bunlar birleştirilmiştir. Bu aday alanlarda, yangın tespit olasılığı belirli bir süre boyunca devam ederse yangın alarmını tetiklemişlerdir.

Borges ve Izquierdo [42] tarafından yangın tespiti için kullanılan metot, potansiyel yangın bölgelerini tanımlayan belirli düşük seviyeli özelliklerin, çerçeveden çerçeveye değişikliklerini analiz etmiştir. Bu özellikler renk, alan boyutu, yüzey pürüzlülüğü, sınır pürüzlülüğü ve tahmini yangın bölgelerindeki çarpıklıktır. Daha önceki çalışmalara nazaran, ateşin titreşen yapısı ve rastgelelik özellikleri nedeniyle, bu çalışmada kullanılan yöntem olumlu bir farklılık yaratmıştır. Bu özelliklerin her birinin davranış değişikliği değerlendirilmiş ve sonuçlar daha sonra güvenilirliği arttırmak adına Bayes sınıflandırıcısına girdi olacak şekilde birleştirilmiştir. Horng ve Peng [43], Horn vd.'ne [40] benzer HSI renk modelini kullanarak bir alev tespit yöntemi önermişlerdir. Bu çalışmada; önerilen sistem, daha eski çalışmalara nazaran gelişmiş bir donanım ortamında test edilmiştir. Qi ve Ebert [44], yalnızca yangının renk ve hareket özelliklerini kullanmakla kalmayıp aynı zamanda yangın yoğunluğunun geçici değişimini ve yangının belirli bir çevrede gruplanma eğilimini de analiz eden bir algoritma önermişlerdir. Yüksek frekanslı parlaklık titreşmesi olan alanları tespit etmek için kümülatif bir zaman türevi matrisi kullanmışlardır. Yangın sırasında yeşil piksellerdeki değişimin kırmızı ve mavi piksellere kıyasla daha fazla olduğunu gözlemişlerdir.

Günay vd. [45], yangın piksel tespiti için Gizli Markov Modeli (GMM) kullanmıştır. Alev sınırlarının düzensiz doğası, GMM kullanılarak geçici dalgacık analizi ile de tespit edilmeye çalışılmıştır. Ateşteki renk değişimleri, hareketli renk bölgelerinin uzaysal dalgacık dönüşümü hesaplanarak belirlenmiştir. Günay vd. [46], video tabanlı yöntemler kullanarak orman yangınlarını geceleri tespit etmeye yönelik çalışma yapmıştır. Önerilen yöntem dört ardışık alt algoritmadan oluşmaktadır: Yavaş hareket eden video nesnesinin tespiti, parlak bölgeleri algılama, periyodik hareket sergileyen nesnelerin tespiti ve videodaki hareketli bölgelerin değişimini yorumlayan bir alt algoritma. Alt algoritmalarından elde edilen kararları senkronize etmek için uyarlanabilir bir aktif füzyon yaklaşımı kullanmışlardır. Han ve Lee [47] tünellerdeki yanlış yangın tespitlerini en aza indirmek için renk ve hareket bilgilerini kullanan algoritma önermiştir ve bu algoritma ile birlikte yangın olaylarının tam konumunu erken aşamalarda tespit etmeyi amaçlamışlardır.

Ko vd. [48] yangın tespiti için hareket ve renk ipuçlarını kullanmayı amaçlamaktadırlar. Oluşturulan ardışık düzenin (pipeline) son aşamasında, dalgacık katsayıları olan ve radyal

temel işlev çekirdeğine sahip iki sınıflı destek vektör makineleri (Support Vector Machine (SVM)) sınıflandırıcısına uygulanan geçici bir yangın modeli kullanılmasını önermişlerdir. Zhu vd. [49], veri miktarını azaltmak için yangın ve yangın dışı durum geçişini, yangın hareketi bilgisi ile birleştirerek GMM yangın modeli önermişlerdir. Chen vd. [50], çok özellikli füzyona dayalı bir video alev tespit yöntemi oluşturmuşlardır. Renkli video dizilerindeki yangınları, normal alev hareketi ve renk ipuçları gibi alevlerin zamansal ve uzamsal (temporal and spatial) özelliklerini algılamak için şemaya bir alev titremesi tespit algoritması dahil etmişlerdir. İlk olarak, geliştirilmiş ‘Gauss mixture’ modeli yöntemi benimsenmiştir; ikinci olarak, tespit edilen hareketli nesnelere, bir alev renk filtreleme algoritması kullanılarak aday alev bölgeleri olarak sınıflandırılmıştır. Son olarak, istatistiksel frekans sayımına dayalı bir alev titremesi tanımlama algoritması kullanılmıştır.

Ko vd. [51] alev tespiti için bir renk ve arka plan modeli kullanmıştır. Önerilen sistemde, öncelikle bir arka plan ve renkli yangın modeli kullanılarak aday yangın bölgeleri belirlenmiştir. Ardından, ardışık çerçevelerdeki yangın piksel değerlerinin sürekli değiştiği gerçeğine dayalı olarak olasılıksal yangın modelleri oluşturulmuştur. Bu modeller daha sonra Bayes Ağlarında (Bayesian Networks) işlem görmüştür. Ko vd. [52], görsel özelliklere dayalı olasılık yoğunluk fonksiyonları ile bulanık sonlu otomatları kullanan yeni bir yangın tespit yöntemi önermektedirler. Böylece, hesaplama sistemlerinde düzensizliği ele almak için sistematik bir yaklaşım ve otomatların yeteneklerini bulanık mantıkla birleştirerek sürekli uzayları işleme yeteneği sağlayacağı düşünülmektedir. Rossi vd. [53] tarafından önerilen çerçevede, yangın bölgelerinden parçaların 3D modellenmesi için stereo görüş kullanılmaktadır. Bu yaklaşımda yer alan aşamalar şunlardır: Yangın bölgelerini çıkarmak için yangın görüntülerinin bölümlere ayrılması; özellik tespit algoritması ile bölümlere ayrılmış bölgelerden göze çarpan noktaların çıkarılması; korelasyona dayalı bir eşleştirme stratejisi kullanarak en iyi özelliklerin seçimi ki bu adım belirgin noktaların iyileştirilmesine, seçilmesine ve bir dizi karşılık gelen noktanın oluşturulmasına izin vermektedir; stereo çakışma kullanarak 3D yangın noktalarının hesaplanması; hacim rekonstrüksiyonu ve yangın karakteristiği hesaplaması için 3D yüzey işlemedir.

Yunyang vd. [54], alev alanının, hesaplanan eşiğine dayalı olarak geliştirilen bir alev görüntüsünün kontur (contour) özelliğini çıkarmak için bir yöntem önermektedir. Yaklaşımlarının arkasındaki fikir, yanan alevlerin kenar kısımlarının sürekli titreşmesi,

ancak ana hatlarının birbirine benzemesidir. Video dizilerindeki alevleri tespit yöntemi burada alevin dinamik konturuna dayalı olarak önerilmektedir. Qiu vd. [55] çalışmalarında kullandıkları algoritmayla, alev görüntüsündeki pürüzlü ve gereksiz kenarları algılamasını, alevin kenarlarını tanımasını ve uygun olmayan bölgelerin ortadan kaldırmasını önermektedir. Algoritmanın otomatik uyarılma özelliğinin, farklı senaryolar için birincil sembolik alev kenarlarının tanımlanmasını sağladığı ifade edilmektedir.

Mueller vd. [56]; çalışmalarında hareket tahmincilerine dayalı bir dizi özelliğe odaklanmaktadır. Ana fikir; türbülanslı, hızlı, ateşli hareket ile diğer nesnelerin yapılandırılmış, katı hareketi arasındaki farktan yararlanmaktır. Klasik optik akış yöntemleri, yangın hareketinin özelliklerini modellemediğinden, özellikle yangın tespit görevi için iki optik akış yöntemi tasarlanmıştır. Bunlar, dinamik doku tarafından ateşlenen optimal toplu aktarım modelleridir. Rong vd. [57], yangın hedeflerinin renk, hareket ve desen özelliklerine dayanan güvenilir bir yangın tespit algoritması önerdiklerini belirtmektedirler. Bu yangın tespit algoritmasında ilk olarak, büyük miktarda alev pikselleri üzerinde analize dayalı kural tabanlı genel bir renk modeli geliştirilmiştir. Daha sonra, geleneksel Geometrik Bağımsız Bileşen Analizi (Geometric Independent Component Analysis (GICA)) modelinden hareket tespiti için bir Kümülatif Geometrik Bağımsız Bileşen Analizi (Cumulative Geometric Independent Component Analysis (C-GICA)) modeli oluşturulmuştur. Son olarak, elde edilen verinin çoklu özelliklerine dayanan geri yayımlı (back-propagation) sinir ağı yangın tanıma modeli geliştirilmiştir. Temel olarak algoritma, hareket tespiti için statik bir arka plan olmadan kural tabanlı bir renk modeli ve C-GICA modelinden oluşmuştur.

Wang vd. [58], alev rengi olasılığının YCbCr renk uzayında öğrenilen Gauss modeline dayalı olarak tahmin edildiği bir yangın alevi tespit algoritması önermektedir. Hareket olasılığı, daha sonra yaklaşık medyan yöntemiyle (Approximate Median Method) dinamik olarak güncellenen arka plan görüntüsü kullanılarak elde edilmiştir. Renk ve hareket olasılıkları, her bir çerçeve için yedi özellikten oluşan bir özellik vektörünün çıkarıldığı alev aday bölgeleri elde etmek için entegre edilmiştir. Ardışık özellik vektörleri daha sonra önceki alev olasılığını elde etmek için Wald-Wolfowitz rastgelelik testine (Wald-Wolfowitz Randomness Test) tabi tutulmuştur. Son olarak, sistem güvenilirliğini iyileştirmek için önceki olasılığı bir sonraki olasılığa güncellemek amacıyla evrişim tanımlanmış ve bir sonraki olasılığa dayalı olarak bir alarm seviyesi ayarlanmıştır.

Ko vd. [59], kamera ile yangın alanı arasındaki mesafeyi hesaplamak ve yangın cephesinin üç boyutlu yüzeyini yeniden oluşturmak için stereo kamera kullanımına dayalı yangın tespit yöntemi sunmaktadır. Aday yangın bölgeleri, genel renk modelleri ve basit bir arka plan farkı modeli kullanılarak belirlenir. Daha sonra, ardışık çerçevelerdeki yangın bölgeleri sürekli değiştiği için yangın şekli, boyutu ve hareket değişimi amacıyla Gauss üyelik fonksiyonları (Gaussian Membership Functions (GMFs)) oluşturulur. Bu üç GMFs daha sonra gerçek zamanlı yangın doğrulaması için bulanık mantığa uygulanmıştır. Son olarak, yangın bölgelerini sol ve sağ görüntülerden bölümlere ayırdıktan sonra, bir eşleştirme algoritması kullanarak öznitelik noktaları çıkarılır. Mesafe tahmini ve üç boyutlu yüzey rekonstrüksiyonu için hesaplanan eşitsizlikler ele alınır.

Schröder vd. [60] parlama tespiti için iki aşamalı bir algoritma önermektedir. İlk adım, kromatik özellikleri ve dinamik yoğunluk davranışlarıyla olası parlama benzeri veya yangın benzeri pikselleri tanımaktadır. İkinci adım ise, tanımlanmış bir uzaysal genişleme parametresi (Spatial Expansion Parameter (SEP)) kullanarak sayılan piksellerin geçici genişlemesini değerlendirmektedir. Eşzamanlı olarak, zaman içinde tanımlanan piksel sayısındaki salınımlı değişiklik, frekans alanına dönüştürülmüştür. Araştırmacılar, frekans spektrumunun analizinin, yangınları tipik titreşim frekanslarıyla tanımlamayı kolaylaştırdığını düşünmüşlerdir. Ayrıca önerilen tespit yöntemi, her aşama için bulanık mantık sınıflandırması kullanılmaktadır. Stadler vd. [61] alevlerin en belirgin görsel özelliğinin titreşim olduğunu savunmuştur. Esas olarak, bu çalışmada, önceki çalışmada sunulan yöntemlere dayalı olarak beş farklı piksel yoğunluğu özelliği araştırılmıştır. Özellikler tarafından elde edilen sınıflandırma oranlarını, alev içeren ve alev içermeyen nesnelere oluşan geniş bir video veri tabanı ile karşılaştırılmıştır. Özelliklerin birbirlerine göre farklılıkları gösterilmiş ve bu farklılıkların sınıflandırma oranlarını nasıl etkilediği açıklanmıştır. Zhang [62], iki geliştirilmiş öznitelik temsilini kullanarak, olasılıksal bir yaklaşım önermektedir. Bu yaklaşımın kullandığı özellikler, renk ve harekettir. İlk olarak, renk tabanlı yangın tespiti için geliştirilmiş bir olasılık modeli önerilmiştir. Daha sonra bu modelden, aday yangın bölgeleri oluşturulmuş, son olarak, nihai karar için geliştirilmiş bir hareket özelliği kullanılmıştır.

Foggia vd. [63], güvenlik kameraları tarafından çekilen videoları analiz ederek yangınları tespit edebilen yöntemde bazı yenilikler sunmuşlardır. Bunlar, renk, şekil değişikliği ve hareket analizine dayalı tamamlayıcı bilgilerdir. Bu bilgiler oldukça uzmanlaşmış bir

sistem tarafından birleştirilmektedir. Dimitropoulos vd. [64], erken yangın tespit uyarı sistemi tarafından kullanılacak yangın tespiti için bir bilgisayarlı görü yaklaşımı önermektedir. Başlangıçta, bir çerçevedeki aday yangın bölgeleri, parametrik olmayan bir modele dayalı olarak arka plan çıkarma ve renk analizi kullanılarak belirlenmektedir. Daha sonra, her aday bölgede doğrusal dinamik sistemler kullanılarak dinamik doku analizi uygulanmakta ve yangın davranışı, renk olasılığı, titreme gibi çeşitli özellikler kullanılarak modellenmektedir. Son bir adım olarak, aday bölgeleri sınıflandırmak için iki sınıflı bir SVM sınıflandırıcısı kullanılmıştır. Qureshi vd. [65], iç veya dış ortamlar için, yangın olaylarının erken tespitini amaçlayan QuickBlaze adlı bir alev ve duman tespit sistemini geliştirmişlerdir. QuickBlaze, hareket ve renk ipuçlarını hesaplamak için basit görüntü ve video işleme tekniklerini kullanarak alev ve duman aday bölgelerinin arka plandan gerçek zamanlı olarak bölümlenmesini sağlar. QuickBlaze, renk dengelemesi ile işleme başlayan, ardından görüntü üzerinde ayrı ayrı duman akışları ve alev tespiti ile devam eden bir işleyişe sahiptir.

Rui vd. [66], literatüre, özellikle 50 m'den daha az mesafe için yangın tespitinde hem hassasiyeti hem de güvenilirliği artıracak; kromatik özellikler, dinamik özellikler, doku özellikleri ve kontur özellikleri gibi çoklu özelliklere dayalı bir yaklaşım sunmaktadır. İlk olarak, gradyan hareket geçmişi görüntüsüne (Gradient Motion History Image (GMHI)) dayalı olarak sıcak nokta tespit edilir. Ardından, hareketli piksellerin, daha önce K-ortalama (K-Means) algoritmasını kullanarak elde edilen ateş renkleriyle eşleşip eşleşmediği kontrol edilir. Daha sonra, titreme frekansları, hareket geçmişi görüntü bilgisiyle, yangın titreme frekansının eşleştiği aday pikselleri seçilir ve aday piksellerden yerel ikili modeller (Local Binary Patterns (LBP)) özelliği çıkarılarak bu özellik SVM ile sınıflandırılır. Son olarak, fraktal boyuta dayalı olarak aday piksellerin yakınındaki her bölgenin konturu analiz edilir ve hem fraktal boyut hem de SVM sınıflandırmasının sonuçlarının pozitif olması durumunda bir yangın olduğu sonucuna varılır. Han [67], video akışından hareketli nesnelere çıkarmak için Gaussian Blend Model tabanlı arka plan çıkarmayı kullanarak, hareket tespiti sağlayan bir algoritma önermiştir. Ardından, olası yangın bölgelerini elde etmek için RGB, HSI ve YUV renk alanını birleştiren çok renkli tabanlı tespit (Multicolor-Based Detection) sistemi kullanılmaktadır. Son olarak, doğru yangın alanlarını belirlemek için yukarıdaki iki adımın sonuçlarını birleştirilir. Gong vd. [68] çok özellikli bir alev füzyonu kullanmıştır. Onlara göre alev, düzensiz olsa da görüntünün dizilişinde belli bir benzerliği vardır. Bu özellik ile zaman-uzam ilişkisine

dayalı yeni bir alev merkezi sabitleme algoritması önerilmiş ve görüntünün her bir karesinin alev bölgesinin ağırlık merkezi hesaplanmıştır. Devamında, tanıma doğruluğunu iyileştirmek için alevin uzaysal değişkenliği, şekil değişkenliği ve alan değişkenliği gibi özellikleri çıkarılmaktadır. Son olarak, eğitim için SVM kullanılmaktadır.

Geleneksel yangın tespit yöntemlerinden elde edilen sonuçlar değerlendirildiğinde, bu yöntemlerle geliştirilen çerçevelerin ve algoritmaların, parlaklık ve gölgelerdeki değişimlere karşı duyarlılıkları nedeniyle nispeten yüksek yanlış pozitifler ürettiği değerlendirilmektedir. Öznitelik çıkarıcılar elle tasarlandığından, bu yöntemler yeterince güvenilir değildir ve farklı senaryoların ihtiyaçlarını karşılamakta zorlanırlar. Bu nedenle, bu tür yöntemler, baskın renk miktarı nedeniyle kırmızı arabaları, turuncu giysiler giyen insanları, pencereden yansıyan yoğun ışığı veya gün batımında güneşin görüntüsünü ateş olarak yorumlayabilmektedirler [69].

Ayrıca, geleneksel makine öğrenimi yaklaşımları, verileri ham formatta işlemekte zorluk çekmiştir. Bu verileri bir öznitelik haritasına dönüştürmek için bir özellik çıkarıcı (feature extractor) tasarlamak çok fazla uzmanlık gerektirmektedir [70]. Derin öğrenme yaklaşımları, bu zorlukları büyük ölçüde ortadan kaldırmıştır ve yangın/duman tespit etme çalışmalarına ivme kazandırmıştır [71]. Böylece görüntü tabanlı yangın ve duman tespit çözümlerinde derin öğrenme yöntemlerinin kullanımı oldukça önemli hale gelmiştir.

1.1.2 Derin Öğrenme Algoritmalarıyla Görüntü Tabanlı Yangın ve Duman Tespit Çalışmaları

Görüntü tabanlı yangın ve duman tespit tekniklerine yönelik yaklaşımların ikinci dönemi, büyük ölçüde derin öğrenme yöntemlerine dayanmaktadır.

Frizzi vd. [72] videolardaki yangını tanımlamak için CNN'e dayalı bir öneride bulunmuşlardır. Sonuçlar, gerçek video dizileri üzerinde test edilen yaklaşımla, buna karşılık gelen geleneksel video yangın tespit yöntemlerinden daha iyi bir sınıflandırma performansının elde edildiğini ve videolarda yangını tespit etmek için CNN'nin kullanılmasının çok umut verici olduğunu vurgulamıştır. Zhang vd. [73], birleştirilmiş derin CNN'de tam bir görüntü eğiterek orman yangını tespiti için bir yöntem önermiştir. Ayrıca; yangın yeri bulma sorununa da odaklanmış ve belirli büyüklükteki sınırlayıcı kutulara sahip mevcut yangın yamalarıyla bunu manuel olarak çözmeye çalışmışlardır.

Kim vd. [74], optik bir sensörle İHA'lardan gelen görüntüleri kullanan derin öğrenme tabanlı bir orman yangını izleme sistemi önermiştir. Çalışmalarının ilk aşamasında, nitelikli bir veri kümesine sahip olmaya odaklanmış ve böylece algılama doğruluğunu arttırmışlardır.

Wang vd. [75], CNN'e dayalı yangını tespit etmek ve bunu, Tensorflow kütüphanesini kullanarak SVM ile desteklemek için, literatüre yeni bir yaklaşım sunmaktadırlar. Başlangıçta, pozitif ve negatif örnek kümeleri olarak çok sayıda yangın ve yangın olmayan görüntü oluşturulmuştur. Ardından, ilgilenilen bölgeyi (Region of Interest (ROI)) çıkarmak için Haar özelliği ve AdaBoost kademeli sınıflandırıcısı uygulanmıştır. Son olarak, Haar tespit sonuçlarını filtrelemek ve negatif ROI'lerin sayısını azaltmak için CNN-SVM kullanılmış ve tam bağlı katmanı değiştirmek için SVM'yi ve eğitim modeline dayalı olarak örnek veri setini sırayla sınıflandırmak amacıyla softmax kullanılmıştır. Araştırmaya göre, bu değişiklik saf CNN'den daha iyi performans göstermiştir. Huttner vd. [76], Tensorflow'u kullanan Google'ın Inceptionv3'üne dayanan, derin öğrenmeye dayalı yaklaşım geliştirmişlerdir. Bu yaklaşıma göre, öğrenme oranlarının (learning rates) ve azaltım fonksiyonlarının (reduction functions) yakınsama süresini nasıl etkilediğini göstermek için farklı optimize ediciler kullanılmaktadır.

Muhammed vd. [77] tarafından, kapalı devre gözetleme videoları için, CNN'e dayanan, uygun maliyetli bir yangın tespit mimarisi önerilmiştir. Model, makul hesaplama karmaşıklığı ve amaçlanan soruna uygunluk dikkate alınarak GoogleNet mimarisinden esinlenmiştir ve verimlilikle doğruluğu dengelemek için hassas olarak ayarlanmıştır (finu-tuned). Ayrıca Muhammed vd. [69] yangını algılayabilen CCTV güvenlik kameraları için hassas şekilde ayarlanmış CNN kullanan bir erken yangın tespit çerçevesi daha önermiştir. Otonom müdahaleyi sağlamak için, afet yönetimi kapsamında, CNN ve nesnelerin multimedya internetini kullanan bir erken yangın tespit sistemi kullanmışlardır. Bu amaçla Alexnet çekirdek mimari olarak ele alınmıştır. Doğruluğunu ve karmaşıklığını akılda tutarak, onun üzerinde hassas ayar yapılmıştır. Yangının afet yönetimi kapsamındaki aciliyeti dolayısıyla, gözetleme sistemindeki kameralar için önemine göre kamera düğümlerinin durumunu uyarlanabilir bir şekilde değiştirebilen esnek bir önceliklendirme mekanizması tasarlanmıştır. Son olarak, afet yönetimi için güvenilir veri dağıtımı ve otonom bir yanıt sistemi sağlayan dinamik bir kanal seçim algoritması kullanılmıştır.

Shen vd. [78] alev tespiti için YOLO modelini kullanmaktadırlar ve bunun için en verimli yaklaşımı belirlemek maksadıyla, bunları geleneksel öğrenme yöntemleriyle karşılaştırmaktadırlar. Ayrıca, çalışmada video karelerinden alev tespiti için optimize edilmiş YOLO modelini kullanılmaktadır. YOLO, en hızlı nesne dedektörlerinden biridir ve saniyede 45 kareye (frame per second (fps)) kadar ulaşabilmektedir. Dolayısıyla çalışma, YOLO'nun gerçek zamanlı nesne tespiti açısından büyük bir avantaj sunduğunu göstermektedir. Zhao vd. [79] tarafından, hava görüntüleriyle yangın bölgesinin hızla konum tespiti ve bu bölgenin sınıflandırılması için dikkate değer yeni bir algılama algoritması önerilmiştir. Önerilen yöntemle, direkt olarak yeniden boyutlandırmanın neden olduğu özellik kaybının etkili bir şekilde önlenebileceği savunulmaktadır. Kendi kendine öğrenen bir yangın öznetelik çıkarıcı ve sınıflandırıcı olarak "FireNet" adlı 15 katmanlı CNN mimarisi tanıtılmıştır. Aslan vd. [80] alevleri tespit etmek için, Derin Evrişimli Çekişmeli Üretken Ağları (Deep Convolutional Generative Adversarial Neural Networks (DCGANs)) kullanan, görüntü tabanlı bir yöntem önermektedir. Önerilen yöntem, geçici görüntü parçaları elde etmek için $64 \times 128 \times 384$ piksel boyutundaki veri girişlerini kabul eden bir DCGAN yapısı kullanarak video karelerini gruplandırmaya ve geçici görüntüleri işlemeye dayanır. Üretici için yoğun birleştirilmiş bir katman, ardından beş evrişim katmanı ve ayırıcı için yoğun bir şekilde bağlı bir katman kullanılmaktadır. İlk olarak, alev ve gürültü dağılımını içeren görüntüleri kullanarak DCGAN eğitilir. Daha sonra üretici ağı olmadan ayırıcıyı geliştirerek yeniden eğitmişlerdir. Böylece daha sağlam bir mimari elde ettiklerini belirtmektedirler.

Muhammed vd. [81] yangın tespit ve yangın mahallinin anlamsal olarak anlaşılması için SqueezeNet mimarisinden esinlenerek hesaplama açısından verimli bir CNN mimarisi önermişlerdir. Yangın tespitinde, doğruluk ve maliyet arasındaki dengeye odaklanarak, modelin boyutunu küçültmek için yoğun ve tam bağlantılı katmanlar olmadan küçük çekirdekler kullanılmaktadır. Böylece, modelin boyutu 238 MB'den 3 MB'a düşürülmüştür. Bu sayede, çok fazla maliyet tasarrufu sağlanmış ve bu durum modeli gözetleme ağlarında uygulama için daha elverişli hale getirmiştir. Fark yarattıkları bir diğer nokta ise yangına dair anlamsal sonuçlar çıkarabilmeleridir. Bu, yangının binada, arabada, ormanda olup olmadığının tespit edilebileceği anlamına gelir. Bu şekilde itfaiye ekiplerinin hazırlanmasına katkıda bulunabilmeyi hedeflemektedirler.

Kim ve Lee [82] tarafından, insanların yangın tespit sürecini taklit eden ve video dizisini kullanan, derin öğrenmeye dayalı bir yangın tespit yöntemi önerilmiştir. Yangın için

şüpheli bölgelerin ve üç boyutlu özelliklere odaklanan yangın dışı bölgelerin tespit edilebilmesi için Faster Region-Based Convolutional Neural Network (Faster R-CNN) kullanılmaktadır. Daha sonra, bir yangının kısa bir süre içinde oluşup oluşmadığını sınıflandırmak için, birbirini izleyen çerçevelerdeki sınırlayıcı kutulardaki özetlenen özellikler Long Short-Term Memory tarafından toplanmaktadır. Ardışık kısa dönemler için kararlar, daha uzun bir dönemdeki nihai karar için birleştirilmektedir. Yin vd. [83] 14 katmandan oluşan yeni bir derin normalizasyon ve CNN algoritması önermektedir. Geleneksel yöntemle karşılaştırıldığında, CNN'de eğitim sürecini hızlandırmak ve duman tespit performansını iyileştirmek için evrişim katmanları normalizasyon ile değiştirilmiştir. Bu şekilde, otomatik öznitelik çıkarma ve sınıflandırma uygulayabileceklerini düşünmektedir. Ayrıca, yetersiz eğitim örneklerinden kaynaklanan aşırı uyumu azaltmak için çeşitli veri geliştirme teknikleri kullanılarak, orijinal eğitim veri kümelerinden daha fazla eğitim veri seti üretilmiştir.

Xu vd. [84] literatüre, alan adaptasyonu ve tespit etmeyi birleştirmek için Single-Shot Multibox Detector (SSD) ve Multi-Scale Deep Convolutional Neural Network (MSCNN) algoritmalarına dayalı, uçtan uca eğitilebilir bir çerçeve kullanan, video tabanlı bir duman tespit sistemi sunmaktadır. Yangın ve duman tespit algoritmalarının, en büyük sınırlayıcısı olarak, eğitim için kullanılacak görüntü eksikliği gösterilmiştir. Bu sorun çözülmeye çalışılmakta ve sentetik duman görüntüleri üzerinde eğitilmiş dedektör modelinin gerçek sahnelere uyarlanması için rekabetçi bir eğitim stratejisi geliştirilmektedir. Xu vd. [85], yeni bir duman tespit algoritması önermektedir. Burada, görsel belirginlik tespiti, bir görüntüdeki en önemli nesne bölgelerini vurgulamayı amaçladığından, bilgilendirici duman belirginlik haritasını çıkarmak için piksel düzeyinde ve nesne düzeyinde belirgin evrişimsel sinir ağları birleştirilmektedir. Videoda duman tespitinde, bir görüntüdeki dumanın varlığını tahmin etmek için derin bir öznitelik haritasını belirginlik haritasıyla birleştirerek, göze çarpan duman tespit ve duman varlığının tahmini için uçtan uca bir çerçeve önerilmektedir.

Namozov vd. [86], yangın ve dumanın renk ve dokusundaki yüksek varyansın üstesinden gelmek için geleneksel ReLU veya teğet işlevleri kullanmak yerine, ağız gizli katmanlarında uyarlanabilir parçalı doğrusal birimlerin kullanılmasını önermektedir. Veri kümelerindeki sınırlı sayıda görüntü nedeniyle, aşırı uyum sorununu çözmek için geleneksel veri büyütme teknikleri ve GAN kullanarak mevcut eğitim görüntülerinin sayısı artırılmaktadır. Bu amaçla, veri artırma yöntemleri olan; Cycle-Consistent

Adversarial Networks (CycleGAN) ve Image-to-Image Translation with Conditional Adversarial Networks kullanılmaktadır. Görüntü stili aktarım tekniklerini kullanma fikri; algoritmanın, farklı tarzlarda ve ışık koşullarında ortaya çıkan ateş ve duman özellikleri ile ilgili bilgi edinebilmesi için yeni görüntüler oluşturmayı amaçlamıştır.

Hu vd. [87] videoda duman tespiti için CNN kullanmış ve hibrit teknikler için yeni bir görüş ortaya atmışlardır. Bu görüş, geleneksel yöntemlerin ve derin öğrenme yaklaşımlarının birleşik olarak kullanılmasını sağlamıştır. Bu amaçla, ConvNet içeren iki akışın ayrı ayrı eğitildiği ve daha sonra geç SVM füzyonu ile birleştirildiği, duman tespiti için iki akış kullanmışlardır. Bu doğrultuda, ayrıca dumanı birlikte tanımak ve optik akışı aynı anda tek bir akışta tahmin etmek için çok görevli bir öğrenme stratejisini benimseyen gelişmiş bir mimari önerilmektedir. Çalışma sonucunda bazı geleneksel yaklaşımlar ve bazı CNN tabanlı yaklaşımlar ile nicel bir karşılaştırma da gözlemlenmiştir. İşlem hızı olarak 196 fps ile oldukça rekabetçi bir sonuca ulaşılmıştır.

Gaohua vd. [88], Faster R-CNN ve CNN'e dayalı ortak bir tespit çerçevesi geliştirerek video ve konumlandırma konusunda duman tespiti sorununu ele almaktadırlar. Kısaca, statik geçici bilgiye dayalı duman konumunu tespit etmek için maksimum olmayan ekleme ile Faster R-CNN geliştirilmekte ve daha sonra CNN dinamik bilgileri birleştirilerek duman tanıma gerçekleştirilmektedir. Biraz daha ayrıntılı incelenirse, sabit aralıklarla video dizilerinden seçilen hedef karelerde duman kutuları oluşturmak için Faster R-CNN kullanıldığı görülmektedir. Son olarak, video duman tespit modelini eğitmek için softmax veya SVM kullanılmıştır. Çerçeve tabanlı ön tespitin hesaplama karmaşıklığını azaltmanın mantıklı bir yolu olduğunu düşünülmüş olup, veri kümesini zenginleştirmek için donanımlı veri büyütme yöntemleri kullanılmıştır ve CNN'nin veri giriş katmanında yatay çevirme ve rastgele kırpma uygulanmıştır. Dumanın yukarı doğru hareketi göz önüne alındığında, dikey çevirme uygulanmamasına karar verilmiştir. Ağı besleyen klipler, 128×171 boyutuna yeniden getirildikten sonra, rassal olarak 112×112 boyutuna kırılmıştır.

Jadon vd. [89] modelin performans ve boyut sorunlarına odaklanmaktadır. Bu çalışmada, gerçek zamanlı yangın tespit uygulamaları için iyi performansa sahip, mobil ve gömülü uygulamalar için uygun, sıfırdan tasarlanmış, FireNet adlı hafif bir sinir ağı mimarisi önerilmektedir. Buna göre, model Raspberry-Pi/3B gibi daha az performanslı, ekonomik olarak uygun, tek kartlı bilgisayarlarda saniyede 24 kareden fazla bir kare hızında

çalışacaktır. Önerilen sinir ağı, üç evrişim katmanından ve bir çıktı softmax katmanı dahil olmak üzere toplam dört yoğun katmandan oluşmaktadır.

Jadon vd. [90] tarafından, mevcut çözümlere göre daha iyi yangın tespit performansı sergileyecek, ticari olarak temin edilebilen, düşük maliyetli, orta performanslı donanımlara dağıtılacak ve gerçek zamanlı uygulamalar için elverişli olacak bir çözüm sunulmaktadır. Donanım cihazında elde edilen kare hızını gerçek zamanlı yangın tespiti için yeterince makul seviyede tutarken önceki yaklaşımlardan daha iyi performans gösterebilecek bir sonuç elde etmeye çalışılmaktadır. Bu yöntem, gömülü ve mobil görüntü uygulamaları için uygun bir CNN temeli olan MobileNet-V2'den ilham almaktadır. MobileNet-V2'ye ek olarak, aşırı öğrenmeyi önlemek için son sınıflandırma katmanından önce bir dropout katmanı eklenmiş Ve bu dropout katmanını bir softmax sınıflandırma katmanı izlemiştir. Bu şekilde, iki sınıflı veri kümesi için modelde hassas ayar (fine-tune) yapılmıştır.

Sun vd. [91], mevcut yangın tespit modellerinin genel sorununu; el fenerleri, kırmızı nesnelere ve çok parlak arka planlar tarafından engellendiği ve yanıltıldığı şeklinde ele almaktadır. Bu amaçla, ışık kaynaklı bozulmayı bastırmak için sahne ön bilgisi ve nedensel çıkarım mekanizmalarını tanıtmaya odaklanılmışlardır. İlk olarak, YoloV3 ağını, ışık kaynaklarını tespit etmek ve tanımak için eğitmişlerdir. Daha sonra, veri kümesi yanlışlığı azaltmak amacıyla Local Grabcut Segmentasyon yöntemiyle ışık kaynakları maskelenmiştir. Sonuç olarak, önerilen yöntemin doğrudan yangın sınıflandırma yöntemlerine kıyasla, InceptionV4 ağlarında, yanlış alarm oranını önemli ölçüde azalttığı savunulmaktadır.

Huang vd. [92] 2D Haar dönüşümünü uygulayan yeni bir Wavelet-CNN yöntemi önermektedir. Ortak yangın tespit yaklaşımının genel çerçevesi, Faster R-CNN'ye dayanıyordu. Bu yöntemin amacı, yangın görüntüsü tespit teknolojisinde geleneksel spektral analizi kullanarak, görüntünün spektral özelliklerini çıkarmak ve bunları farklı katman aşamalarında CNN'lere girmek olarak tanımlanmıştır. Yöntemlerinin sağlamlığını test etmek için iki klasik backbone ağı olan ResNet50 ve MobileNet V2 kullanmışlardır. Karşılaştırmalı bir yangın veri seti ve bir video veri seti üzerindeki deneysel sonuçların, yöntemin yangın tespit doğruluğunu önemli ölçüde geliştirdiği ve özellikle hafif ölçekli uygulamalar için yanlış alarmları azalttığı öne sürülmektedir.

Literatür genel olarak incelendiğinde, ilgili alanda çok fazla çalışma yapıldığı ve gelişimin artan bir ivmeyle devam ettiği görülmektedir. Bu çalışmalar; Tablo 1.4'te ve Tablo 1.5 kullanılan yöntemlere göre kıyaslanmış ve genel çerçeve gösterilmiştir. Bu çalışmalar detaylı olarak incelendiğinde önerilen algoritmaların bazıları hızlı işlem süresi vaat etmesine rağmen; düşük doğrulukta çok sayıda yanlış alarm üretmiştir. Tam tersine, bazı çalışmalar yüksek yangın tespit doğruluğu sağlasa da çok uzun işlem sürelerine sahiptir. Bu nedenle, gerçek ortamlarda, özellikle küçük bir gecikmenin veya hatanın büyük bir felakete yol açabileceği deprem sonrası yangın ortamlarında uygulanmaları riskli olabilecektir.



Tablo 1.4 Literatürdeki geleneksel yöntemlerle yapılan çalışmaların kullandıkları metotlara göre kıyaslanması

Yazarlar	Renk tespit modeli/ yöntemi	Uzamsal farklılık analizi	Dinamik doku/desen analizi	Çarpıklık analizi	Sadeleştirme sonrası işlem	Konumlandırma	Alev tespiti	Yangın tespiti
Horng vd. [40], 2005	RGB/HSI	✓			✓		✓	
Marbach vd. [41], 2006	YUV			✓			✓	
Borges ve Izquierdo [42], 2010	RGB	✓	✓	✓			✓	
Horng ve Peng [43], 2008	RGB/HSI				✓		✓	
Qi ve Ebert [44], 2009	RGB/HSV	✓			✓		✓	
Gunay vd. [45], 2010	RGB/HSI	✓		✓			✓	
Gunay vd. [46], 2009	RGB	✓	✓	✓			✓	
Han ve Lee [47], 2009	RGB/FDA-SDA	✓	✓			✓	✓	✓
Ko vd. [48], 2009	RGB			✓	✓		✓	

Tablo 1.4 Literatürdeki geleneksel yöntemlerle yapılan çalışmaların kullandıkları metotlara göre kıyaslanması (devamı)

Yazarlar	Renk tespit modeli/ yöntemi	Uzamsal farklılık analizi	Dinamik doku/desen analizi	Çarpıklık analizi	Sadeleştirme sonrası işlem	Konumlandırma	Alev tespiti	Yangın tespiti
Zhu vd. [49], 2010	RGB/Markov		✓	✓			✓	
Chen vd. [50], 2010	RGB/HSI		✓				✓	
Ko vd. [51], 2010	RGB				✓		✓	✓
Rossi vd. [53], 2011	YUV/RGB				✓	✓	✓	
Yunyang vd. [54], 2012	RGB		✓				✓	
Qiu vd. [55], 2012	PEI	✓	✓				✓	
Mueller vd. [56], 2013	RGB-OMT-NSD-NN	✓		✓			✓	
Rong vd. [57], 2013	RGB/GICA		✓				✓	
Wang vd. [58], 2013	YCbCr/RGB			✓	✓		✓	

Tablo 1.4 Literatürdeki geleneksel yöntemlerle yapılan çalışmaların kullandıkları metotlara göre kıyaslanması (devamı)

Yazarlar	Renk tespit modeli/yöntemi	Uzamsal farklılık analizi	Dinamik doku/desen analizi	Çarpıklık analizi	Sadeleştirme sonrası işlem	Konumlandırma	Alev tespiti	Yangın tespiti
Ko vd. [59], 2014	GMFs	✓	✓			✓	✓	✓
Schroder vd. [60], 2014	RGB/Bulanık	✓	✓				✓	
Zhang [62], 2014	RGB	✓					✓	✓
Foggia et al. [63], 2015	MES		✓		✓		✓	
Dimitropoulos vd. [64], 2015	RGB/Adaptif Medyan	✓			✓		✓	
Qureshi vd.. [65], 2016	RGB				✓	✓	✓	✓
Rui vd. [66], 2017	GMHI		✓		✓		✓	
Han [67], 2017	HSI/YUV		✓		✓		✓	
Gong vd. [68], 2019	RGB/Gauss	✓	✓	✓			✓	

Tablo 1.5 Literatürdeki derin öğrenme algoritmalarıyla yapılan çalışmaların kullandıkları yöntemlere göre kıyaslanması

Yazarlar	Ağ/Yöntem	Veri seti	Çerçeve / Platform	Kesinlik / tespit oranı	Yanlış oranı	Konumlandırma	Alev tespiti	Duman tespiti
Polednik [39], 2015	DCNN	Blender 3D modelleme aracı ile oluşturuldu	Caffe	0.980	0.05	-	✓	-
Frizzi vd. [72], 2016	CNN (AlexNet)	27919 RGB etiketlenmiş 64x64 piksel boyutunda görüntü.	Theano	0.981 (yangın) - 0.965 (duman)	0.002 (yangın) - 0.015 (duman)	-	✓	✓
Zhang vd. [73], 2016	CNN (AlexNet)	240x320 piksel boyutunda 25 orman yangını videosu kullanıldı.	Caffe	0.848	0.012	-	✓	-
Wang vd. [75], 2017	CNN/SVM	32x32 piksel boyutunda 28137 görüntü kullanıldı.	Tensorflow	0.991	-	-	✓	-
Huttner vd. [76], 2017	CNN (Inception-v3)	Furg Fire veri seti	Tensorflow	0.980	-	-	✓	✓
Muhammad vd. [77], 2018	CNN (GoogleNet)	Farklı kaynaklardan 68457 görüntü kullanıldı.	Caffe	0.860	-	-	✓	-
Muhammad vd. [69]	CNN (AlexNet)	Farklı kaynaklardan 31 video kullanıldı.	Caffe	0.943	0.090	-	-	✓

Tablo 1.5 Literatürdeki derin öğrenme algoritmalarıyla yapılan çalışmaların kullandıkları yöntemlere göre kıyaslanması (devamı)

Yazarlar	Ağ/Yöntem	Veri seti	Çerçeve / Platform	Kesinlik / tespit oranı	Yanlış oranı	Konumlandırma	Alev tespiti	Duman tespiti
Shen vd. [78], 2018	YOLO	Farklı kaynaklardan görüntüler kullanıldı.	Tensorflow	0.760	-	-	✓	-
Zhao vdl. [79], 2018	Fire_Net	300 x 200'dan 4000 x 3000 piksel boyutuna değişen 1500 görüntü kullanıldı.	Caffe	0.98	0.005	✓	✓	✓
Aslan vd. [80], 2019	DCGAN	Alev sahneleri içeren 184 video kullanıldı.	Tensorflow	0.921	0.039	-	✓	-
Muhammad vd. [81], 2019	CNN (SqueezeNet)	Farklı kaynaklardan 68457 görüntü kullanıldı.	Caffe	0.900	0.088	✓	✓	-
Kim ve Lee [82], 2019	Faster R-CNN	Farklı kaynaklardan 73887 görüntü kullanıldı.	-	0.967	-	-	✓	✓
Yin vd. [83], 2017	Deep Normalization ve CNN	Veri geliştirme teknikleri uygulandı ve 25000'den fazla görüntü kullanıldı.	Tensorflow ve Keras	0.975	0.002	-	-	✓

Tablo 1.5 Literatürdeki derin öğrenme algoritmalarıyla yapılan çalışmaların kullandıkları yöntemlere göre kıyaslanması (devamı)

Yazarlar	Ağ/Yöntem	Veri seti	Çerçeve / Platform	Kesinlik / tespit oranı	Yanlış oranı	Konumlandırma	Alev tespiti	Duman tespiti
Xu vd. [84], 2019	SSD/MSCNN	30000 sentetik ve 2549 gerçek görüntüyü içeren veri seti kullanıldı.	Caffe		0.041	-	-	✓
Namozov vd. [86], 2018	CNN (12 Katmanlı)	2440 yüksek çözünürlüklü görüntüyü içeren veri seti kullanıldı.	-	0.961	0.003	-	✓	✓
Hu vd. [87], 2018	Spatio-temporal Stream	157 video içeren veri seti kullanıldı.	Caffe	0.970	0.035	-	-	✓
Gaohua vd. [88], 2019	R-CNN + 3D CNN	14150 klip içeren sentetik veri seti kullanıldı.	Tensorflow	0.952	0.039	-	-	✓
Jadon vd. [89], 2019	CNN (14 katmanlı)	2425 görüntü içeren veri seti kullanıldı.	-	0.939	0.019	-	✓	✓
Jadon vd. [90], 2020	CNN (MobileNetV2'den esinlenmiştir)	8481 görüntü içeren veri seti kullanıldı.	-	0.911	0.044	-	✓	-

Tablo 1.5 Literatürdeki derin öğrenme algoritmalarıyla yapılan çalışmaların kullandıkları yöntemlere göre kıyaslanması (devamı)

Yazarlar	Ağ/Yöntem	Veri seti	Çerçeve / Platform	Kesinlik / tespit oranı	Yanlış oranı	Konumlandırma	Alev tespiti	Duman tespiti
Sun vd. [91], 2021	YoloV3	18805 görüntü içeren veri seti kullanıldı.	-	0.947	0.061	-	✓	-
Huang vd. [92], 2022	Wavelet-CNN	4405 görüntü içeren veri seti kullanıldı.	-	0.989	0.037	-	✓	-

1.2 Tezin Amacı

Sebeup olabileceđi maddi ve manevi hasarların byklđ gz nne alındıđında deprem olayları, gezezenimiz iin en nemli dođal afetlerden biri olarak n plana ıkmaktadır. Bu bađlamda, depremlerin neden olabileceđi hasarlar farklı Őekillerde meydana gelebilmektedir. Bunlardan birisi de deprem sonrası ıkan yangınların insan sađlıđına, ekonomiye ve evreye verdiđi zararlarıdır.

Cođrafi olarak Kuzey Anadolu Fay Hattı zerinde olması ve yakın gelecekte $MW=7,5$ byklđnde bir depremin beklenmesi sebebiyle, ele alınan konunun İstanbul iin ne kadar nemli olduđu grlmektedir. İstanbul, nfus bakımından Trkiye'nin en byk Őehri olmasının yanı sıra, lke toplam nfusunun yaklaŐık beŐte birinin yaŐadıđı kalabalık ve afetlere karŐı kırılgan bir Őehirdir. Bunun yanında, lke sanayisinin ve teknoloji merkezlerinin de hayati bir blmn bnyesinde barındırmaktadır. Bu zellikler gz nne alındıđında İstanbul'da olası bir depremin yaratacađı tahribatın da ok byk olacađı aŐıkardır. Bu nedenle bu alıŐmada, akıllı Őehirlerde deprem sonrası yangınlarla oluŐabilecek kayıpları en aza indirmek iin itfaiye ve arama/kurtarma ekiplerinin etkin bir Őekilde ynlendirilmesi iin bir yangın tespit sistemi nerilmiŐtir. alıŐma, depreme karŐı kırılganlıđı ve hassasiyeti nedeniyle, İstanbul ilinde gerekleŐtirilen uygulama ile test edilmiŐtir. Kolay uygulanabilirliđi ve dŐk maliyeti nedeniyle, alıŐmanın diđer blgeler iin de hayata geirilebileceđi dŐnlmektedir.

1.3 Orijinal Katkı

Literatrde yangın tespiti ve konumlandırılması konusunu ele alan eŐitli alıŐmalar bulunmaktadır. Bunlar arasında, tez kapsamında nerilen sistemin zelliklerinden bir veya birkaını ieren alıŐmalar mevcut olup, bunlar "Literatr Taraması" baŐlıđı altında detaylı olarak incelenmiŐtir. Ancak ele alınan alıŐmanın tm zelliklerini ieren bir araŐtırmaya denk gelinmemiŐtir. Bu tezin literatre katkıları ve yaygın etkileri aŐađıdaki gibi zetlenmiŐtir:

(1) nerilen sistem ile deprem sonrası kaotik ortamda oluŐabilecek yangınlar hakkında, yksek hassasiyetli bilgi akıŐı sađlanarak yangın olaylarına zamanında mdahale edilmesi mmkn olacaktır. Bylece deprem sonrası yangından kaynaklanan kayıplar byk lde nlenmiŐ olacaktır.

(2) İnsansız hava araları (İHA) ve uydu grntleri gibi alternatif zmlere kıyasla dŐk maliyetli, yksek dođruluk oranına ve hassas cođrafi konum bilgisine sahip srekli

bilgi akışı sağlanacaktır. Buna karşın, örneğin İHA'lar yük taşıma kısıtları nedeniyle maliyetlidir ve menzilleri sınırlıdır. Ayrıca, genellikle kullanıcı olarak insanlara bağımlıdır ve olumsuz hava koşullarından etkilenerek, afet sonrası oluşacak hava trafiğinde tıkanıklığa neden olabileceklerdir [27-29]. Bunun aksine; önerilen sistemin, mevcut yüksek görüş açılarına sahip yüksek telekomünikasyon kuleleri üzerine yerleştirilmesi ile ihtiyaç duyulan kamera sayısı büyük ölçüde azaltılacak ve sistem çok daha uygun maliyetli hale getirilecek ve her türlü hava koşulunda sürekli bir bilgi akışı sağlayacaktır.

(3) Yangın ve duman tespitinde istenen hassasiyet düzeyine ulaşamayan yangın tespit algoritmalarının dezavantajlarından farklı olarak, YOLOv5s algoritması, yangını erken aşamada tespit eden nesne tespit algoritması olarak kullanılacaktır. Böylece, YOLOv5s'nin nesne tespit özellikleri kullanılarak, yangına ait coğrafi konum bilgileri belirlenebilecektir.

(4) İletişim, afet yönetimi süreçlerinin her birinde kritik rol oynamaktadır, ancak afet sonrası ortamlarda sıklıkla bağlantı kopmaları meydana gelmektedir [30, 31]. Bu ortamlarda, önerilen sistem unsurlarından olan WSN bağlantısı sayesinde iletişim kesintilerinden etkilenmeden afet yönetim merkezine güncel veri göndermeye devam edebilecektir.

(5) Sistem tamamen otonom olduğu için yangın tespit etmede insana olan bağımlılığı ortadan kaldırılacaktır. Ayrıca, meydana gelen tüm yangın olayları hakkında bilgileri sağladığından, yangınla mücadele ekiplerinin genel resmi algılamasına ve önceliklendirme yapmasına olanak tanıyacaktır.

(6) Sistem ikincil afetler için tasarlanmış olsa da yüksek hassasiyette yangın tespiti için günlük hayatta da etkin kullanıma çok uygun olacaktır.

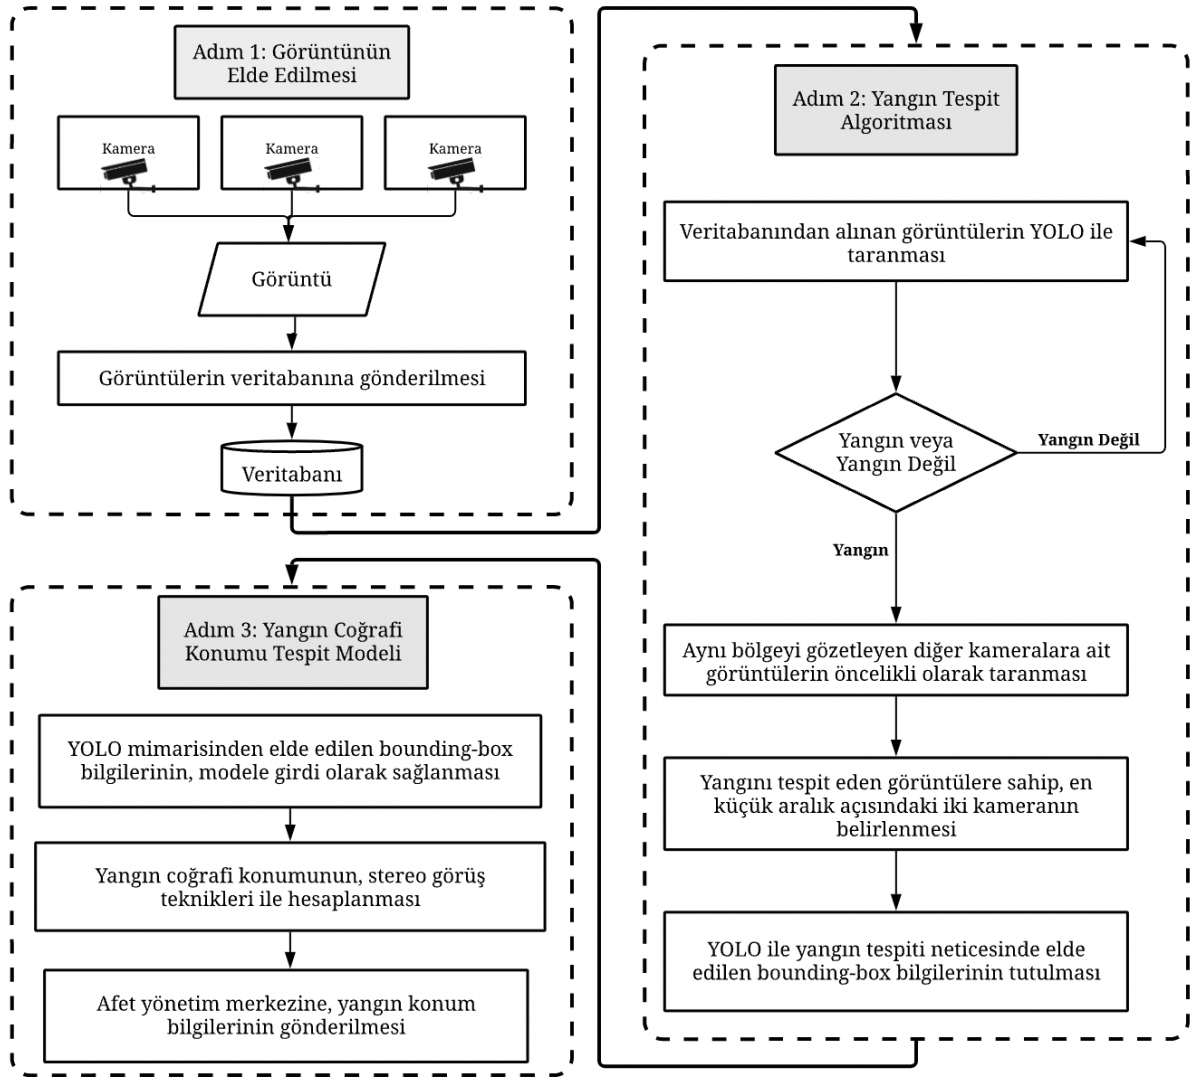
2 METODOLOJİ

Şehirlerde, afet yönetim sistemleri kapsamında deprem sonrası yangınların erken tespit edilebilmesi, deprem sonrası yangınların insan sağlığına verdiği zararlar başta olmak üzere, ekonomik ve sosyal zararlarından korunmayı sağlayabilir. Ancak, şehir yaşamının çeşitli faktörlerinden olan; farklı ışık kaynaklarının varlığı, değişen aydınlatma koşulları ve hareketli yaşam gibi etmenler yangınların görsel tabanlı olarak tespiti açısından birçok farklı sorunu ortaya çıkarmaktadır. Bu nedenle şehir ortamlarında, görsel tabanlı erken yangın tespit sistemleri için daha güvenilir algoritmalara ihtiyaç duyulmaktadır.

Literatürden de anlaşılacağı gibi, geleneksel modeller kullanılarak yapılan yangın tespiti, zaman alan ve yüksek mühendislik gerektiren öznel çıkarma yöntemlerine ihtiyaç duymaktadır. Geleneksel görsel tabanlı yöntemler, değişen kentsel çevre koşullarının zorlu etkisi altında düşük tespit başarısı sergilemiştir. Bu durum göz önüne alındığında, derin öğrenme modelleri, erken aşamalarda potansiyel yangınların tespiti için daha uygun bir yöntemdir.

2.1 Önerilen Çerçeve

Önerilen çerçeve; deprem sonrası yangını tespit etmek için görüntünün yakalanmasından, işlenen verilerin afet yönetim merkezine iletilmesine kadar üç aşamayı barındırır. İlk aşama, yangını tespit etmek için yangın/duman görselleriyle eğitilmiş, yüksek doğruluk oranına sahip YOLOv5s algoritması kullanılır ve algılanan yangınlar için sınırlayıcı kutu (bounding box) parametreleri elde edilir. İkinci aşamada; aynı yangına ait sahneyi tespit eden kameralardan elde edilen sınırlayıcı kutu parametreleri, yangının coğrafi konum bilgilerini bulmak için stereo görüş uygulama aşamasında ele alınır ve yangının coğrafi konumu tespit edilir. Üçüncü aşamada; bir önceki aşamada elde edilen bilgiler, afet koşullarındaki tahribat dikkate alınarak, alternatif bir iletim kaynağı olan WPS üzerinden afet yönetim merkezlerine iletilir. Önerilen çerçevenin tüm aşamaları Şekil 2.1'de gösterilmektedir.



Şekil 2.1 Çalışmada önerilen yangın tespit mimarisi

2.2 Nesne Tespit Algoritması Olarak YOLOv5s

Nesne tespiti, giriş görüntüsündeki olası bölgelerin önerisi ve önerilen her bölgedeki tüm nesnelerin sınıflandırılması işlemidir. Nesne tespiti, bilgisayarlı görünün birçok alanından biridir. Bilgisayarlı görü çalışma alanlarından olan; görüntü sınıflandırma, nesne lokalizasyonu, nesne tespiti, örnek bölümlenme ve anlamsal bölümlenmeye ait örnek çıktılar Şekil 2.2'de gösterilmiştir.




Şekil 2.2 Bilgisayarlı görü temel çalışma alanları

Görüntü sınıflandırma, görüntüdeki baskın nesneye göre görüntünün sınıflandırılması işlemidir. Nesne lokalizasyonu, görüntüdeki baskın nesneyi içeren görüntü parçasının tahminidir. Bu tahmin edilen parça içindeki görüntü daha sonra sınıflandırılabilir. Nesne tespiti, bir görüntüdeki tüm nesnelerin konumlandırılması ve sınıflandırılmasıdır. Bu süreç genellikle görüntü parçasının önerilmesini ve nesnenin önerilen bu bölge içinde sınıflandırılmasını içerir. Anlamsal bölümleme, görüntünün tüm piksellerinin belirli sınıflara göre etiketlenmesidir. Örnek bölümleme, görüntüdeki her bir nesnenin tüm piksellerinin aynı sınıftaki başka bir nesneden ayrılarak etiketlenmesidir.

Bilgisayarlı görünün araştırma alanları olan nesne tespit algoritmaları incelendiğinde iki ana kısma ayrılan yöntemlerden bahsetmek mümkündür. Bunlar geleneksel nesne tespit algoritmaları ve derin öğrenme tabanlı nesne tespit algoritmalarıdır.

2.2.1 Geleneksel Nesne Tespit Algoritmaları

Geleneksel nesne tespit algoritmalarında, giriş görüntüsü üzerinde doğrudan nesne tespiti gerçekleştirilmez. Bu algoritmalarda temel olarak şu aşamalar izlenir: Görüntü girişi ve ön işleme, öznitelik çıkarma ve sınıflandırma. Geleneksel nesne tespit algoritması adımları Şekil 2.3'te gösterilmiştir.



Şekil 2.3 Geleneksel nesne tespit algoritması çalışma adımları

2.2.1.1 Görüntü Girişi ve Ön İşleme

Bu aşamanın amacı; görüntüyü elde etmek ve mevcut formatta bir matrise dönüştürmek, görüntü üzerindeki gürültüyü ortadan kaldırmak, görüntü keskinliğini artırmak ve görüntüyü öznitelik tanımlayıcı tarafından belirtilen en-boy oranı ve boyutlarına getirmektir.

2.2.1.2 Öznitelik Çıkarma

Gereksiz bilgileri ortadan kaldırarak görüntüyü en iyi tanımlayan özellik vektörünün elde edilmesi ve bu vektörün ışık değişimlerine karşı normalleştirilmesi aşamasıdır. Öznitelik çıkarmı, öznitelik tanımlayıcıları tarafından gerçekleştirilir. Birçok öznitelik tanımlayıcı olmasına rağmen literatürde en çok kullanılanları Scale Invariant Feature Transformation (SIFT) [93], Speeded-Up Robust Features (SURF) [94] ve Histogram of Oriented Gradients (HOG) [95]'dir.

SIFT, yerel görüntü özelliklerini tanımlamak için bir tespit algoritmasıdır. Yerel görüntü özellikleri, nesnelere tespit ederek tanımlamaya yardımcı olur. SIFT özellikleri bağlamsaldır, nesnenin konumuna bağlıdır. Yani, görüntü boyutu ve rotasyonundan etkilenmez. Ayrıca aydınlatma, titreme ve küçük perspektif kaymalarında da etkilidirler.

SURF, yaygın olarak bulunan bir nesne tanımlayıcısıdır. SIFT'den kısmen etkilenmiştir. SURF, SIFT'den birkaç kat daha hızlı olarak kabul edilir ve görüntü dönüştürmelerine karşı SIFT'den daha iyi olduğu iddia edilmektedir. Bu, sinyal kırımları için bileşik görüntüler kullanılarak önde gelen akım detektörlerinin ve tanımlayıcılarının gücü kullanılarak gerçekleştirilmiştir.

HOG, nesne tespitine dayanan görüntü analizi için bir özellik tanımlayıcıdır. Histogramın arkasındaki öncül, bir dizi yoğunluk gradyanları veya sınırlarının bir görüntü içindeki yerel nesnelere varlığını ve yapısını temsil etmesidir. Resimler, hücre adı verilen küçük, bağlantılı bölgelere ayrılır. Her hücredeki pikseller için bir gradyan yönleri histogramı

oluşturulur. Tanımlayıcı, bu histogramların birleşimidir. HOG tanımlayıcısının diğer tanımlayıcılara göre çeşitli avantajları vardır. Lokal hücreler üzerinde çalıştığı için geometrik ve fotometrik dönüşümlerde nesne yönelimi dışında değişmez.

2.2.1.3 Sınıflandırma

Sınıflandırma, çok sayıda pozitif ve negatif örnekle eğitilmiş makine öğrenmesi algoritmaları ile özellik vektörünün mümkün olan en verimli, kesin ve hızlı şekilde etiketlenmesi ve sınıflandırılması aşamasıdır.

Bu aşamada örnek olarak bazı uygulamalar şu şekildedir;

Görsel nesne tespitinde, K-En Yakın Komşuluk (K-Nearest Neighbor (K-NN)) algoritmasının daha verimli çalışması için temel sınıflandırıcılardan biri olan Naive Bayes modeli bu algoritma ile kullanılmıştır. SVM modeli, yüz tanıma, karakter tanıma, el yazısı tanıma ve tıbbi tahminde kullanılmıştır. Karar ağaçları modeli, gerçek zamanlı görsel nesne tanıma problemlerinde sınıflandırma için kullanılır. Rastgele orman modeli (Random Forest), çok sınıflı nesne tespiti ve insan vücudu hareketlerinin takibi için Microsoft Xbox'larda kullanılmıştır. Yine K-NN modeli, görsel nesne sınıflandırma alanında, özniteliklerin bir kombinasyonunu oluşturmak ve daha verimli ve başarılı sınıflandırma yapmak için kullanılmaktadır.

Bunların yanı sıra yapay sinir ağları birçok alanda karmaşık ve zor problemlerin çözümünde kullanılmakta ve genel olarak başarılı sonuçlara ulaşmaktadır. Modern görüntü sınıflandırma tarihi, LeNet [96] ve Bounded Boltzman makineleri [97] ile 2012 yılında ILSVRC 2012 yarışmasındaki AlexNet [98]'in başarıları sonucunda başlamıştır.


2.2.2 Derin Öğrenme Tabanlı Nesne Tespit Algoritmaları

Ham bir görüntü, geleneksel nesne algılama algoritmalarıyla işlenemez. Öncelikle ham görüntüden öznitelik çıkarma işlemi ile öznitelik vektörünün elde edilmesi gerekmektedir. Bu işlem uzun zaman alır. Ayrıca derin bilgi ve yüksek deneyim/mühendislik gerektirir.

Derin öğrenme tabanlı nesne tespit algoritmaları ise geleneksel algoritmalarından farklı olarak öznitelik çıkarımına ihtiyaç duymadan görüntüyü işleme yeteneğine sahiptir. Bilgisayar donanım altyapısının gelişmesi ve daha fazla verinin elde edilmesi ile derin öğrenme tabanlı algoritmalar tercih edilir hale gelmiştir. Tüm derin öğrenme tabanlı

nesne tespit algoritmalarının temel modeli, CNN'lerdir. Bu noktada CNN mimarisini detaylı şekilde incelemekte fayda görülmektedir.

CNN mimarisi girdi, evrişim, havuzlama, tam bağlantı ve sınıflandırma katmanlarından oluşur. Temel yapısı Şekil 2.4'te gösterilmiştir.



Şekil 2.4 Genel CNN mimarisi


Giriş katmanı, ham görüntünün ağa verildiği katmandır. Ağa verilecek görüntünün boyutu hem ağ derinliği hem de donanım yetenekleri dikkate alınarak belirlenir.

Evrişim katmanı (CONV); girdiyi boyutlarına göre tararken, evrişim işlemlerini gerçekleştiren filtreler kullanır. Hiper-parametreleri, filtre boyutunu ve adımını içerir. Filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Ortaya çıkan çıktıya özellik haritası veya aktivasyon haritası denir. Aktivasyon haritası, her filtrenin özneliklerinin çıkarıldığı bölgedir [132].

Aktivasyon haritası, farklı filtreler kullanılarak elde edilir. Görüntüye 32 filtre uygulanırsa 32 aktivasyon haritası elde edilir. Aktivasyon haritasındaki değerler, filtre katsayılarının toplamına bölünerek normalize edilir. Evrişim katmanında matematiksel işlemler yapıldığından, ağ lineer bir yapıya sahiptir. Genellikle öğrenilecek fonksiyon lineer olmadığı için sigmoid, tanh ve ReLU gibi lineer olmayan aktivasyon fonksiyonları kullanılarak ağ lineer olmayan bir yapıya dönüştürülür.

Havuzlama katmanı, genellikle evrişim katmanından sonra uygulanan bir alt örnekleme işlemidir. Özellikle maksimum ve ortalama havuzlama, sırasıyla maksimum ve ortalama değer alınmış özel havuzlama türleridir. Bu katmanda; öğrenilecek parametre sayısı ve ağda gerçekleştirilen hesaplama miktarı azaltılır. Havuzlama katmanı, bir evrişim katmanı tarafından oluşturulan öznelik haritasının bir bölgesinde bulunan özellikleri

sınıflandırma için kullanılan iki sinirsel alt ağdan oluşurken, tek aşamalı algoritmalar da vardır. Şekil 2.6, iki farklı yaklaşımın bir özetini vermektedir.




Şekil 2.6 Nesne tespit algoritmaları yapıları

2.2.2.1 İki Aşamalı Nesne Tespit Algoritmaları

İki aşamalı nesne tespit algoritması, kilit alanların algılandığı ve ardından bu alanlarda bir nesnenin tespit edilip edilmediğini görmek için sınıflandırıldığı bir ön aşama kullanır. Esas olarak iki aşamayı içerir. İlk adımda, bir nesne içerebilecek görüntünün bölge önermeleri veya alt kümeleri belirlenir. İkinci aşamada, algoritma bir önceki aşamada oluşturulan ilgili bölgeler üzerinde bölgesel sınıflandırma ve konum iyileştirmesi gerçekleştirir [110].

İki aşamalı nesne tanımada, görüntüdeki tüm nesnelere için sınırlayıcı kutular önerilir. Sınırlayıcı kutu çizimi için cismin bulunduğu sol üst köşenin veya merkez noktasının (x, y) koordinatları ile yükseklik ve genişlik olmak üzere 4 farklı parametre gereklidir. Bu parametreler doğru bir şekilde tahmin edilirse, tahmin edilen sınırlayıcı kutu ve temel gerçek sınırlayıcı kutu büyük ölçüde örtüşecek ve yüksek bir kesiştirilmiş bölgeler (Intersection over Union (IoU)) ile sonuçlanacaktır. IoU hesaplamasında göz önüne alınan gerçek sınırlayıcı kutu ve tahmin edilen sınırlayıcı kutuya örnek Şekil 2.7'de gösterilmiştir. IoU değeri Denklem (2.1)'deki hesaplama ile elde edilir.

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} \quad (2.1)$$



Şekil 2.7 IoU hesaplaması

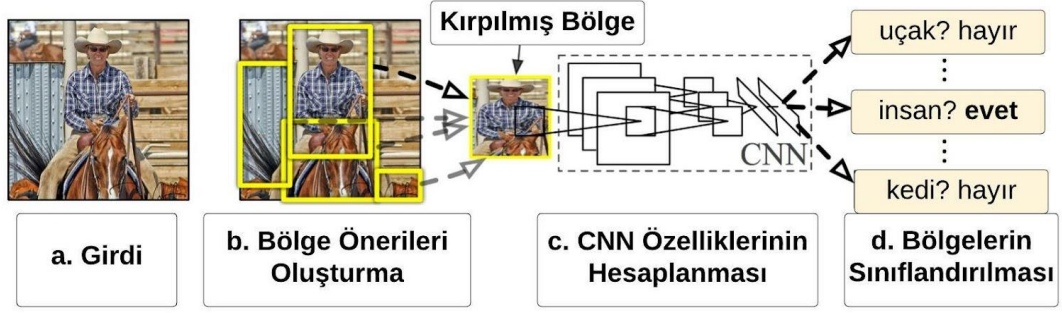
Görüntü üzerinde en iyi sınırlayıcı kutuları önermek için önce belirli bir güven puanının altındaki tüm sınırlayıcı kutular elenir, ardından güven puanı en yüksek olan sınırlayıcı kutular seçilir ve belirli eşik değerinin üzerindeki IoU değeriyle çakışan diğer tüm kutular atılır. Bu işleme, maksimum olmayanları atma (non max suppression (NMS)) denir.

İki aşamalı konum belirleyicilere örnek olarak R-CNN, Fast R-CNN [112], Faster R-CNN [113], mask R-CNN [114] ve RFCN [115] verilebilir. En yaygın kullanılan algoritma, R-CNN ailesinin en iyi sürümlerinden biri olan Faster R-CNN'dir.

- **R-CNN**

Bölge tabanlı evrimsel sinir ağları, önceki geleneksel makine öğrenme yöntemlerine göre, nesne tespiti alanında bir gelişme sağlamıştır. R-CNN, seçici bir arama algoritması yardımıyla bölge önerilerinde bulunur. Seçici arama, ilgili görüntüde bulunması gereken bölgeleri tanımak için kullanılan bir algoritmadır [116]. Algoritmada önce küçük bölgeler belirlenir. Benzer bölgelerin birleştirilmesiyle daha büyük bölgeler elde edilir. İşlem tekrarlanarak nesnelere kümelendirilir. Aday bölgeler bu şekilde belirlenir. Daha sonra belirlenen bölgeler ayrı ayrı CNN modeline aktarılır. Çıkarılan öznitelikler ile sınıf ve sınırlayıcı kutu tahmini yapılır.


Doğru sınırlayıcı kutuların seçimi, NMS ile yapılır. Bu algoritma, yalnızca IoU değeri 0,5'ten büyük olanları alır. Bir nesne için 0,5'ten fazla puan alan sınırlayıcı kutulardan en yüksek puana sahip olan alınır [111]. Şekil 2.8, R-CNN mimarisini göstermektedir.



Şekil 2.8 R-CNN Mimarisi [111]

- **Fast R-CNN**

R-CNN yaklaşımını öneren yazarlardan biri olan Ross Girshick tarafından geliştirilen Fast R-CNN, nesne tespitini hızlandırmak için farklı teknikleri bir araya getirmiştir. Bölge önerileri yapmak yerine, tüm görüntü, Fast R-CNN algoritması üzerinde CNN'ye yerleştirilir. Sonuç olarak, oldukça kararlı bir evrişimsel öznitelik haritası elde edilir. Seçimli arama yoluyla evrişimsel öznitelik haritasında yaklaşık 2000 ilgi alanı tanımlanır. Önerilen bölgeler, havuzlama katmanı aracılığıyla sabit boyutta sarılır ve daha sonra tam bağlantılı katmana bağlanır. Softmax, ilgili her bölge için nesnenin sınıfını bulmak maksadıyla kullanılır. Sınırlayıcı kutu regresyonu ile sınırlayıcı kutu bulunur [112]. Fast R-CNN'nin avantajı, evrişimsel öznitelik haritaları kullanmasıdır, ancak seçimli arama işlemi darboğaz oluşturmaktadır. Şekil 2.9, Fast R-CNN mimarisini göstermektedir.




Şekil 2.9 Fast R-CNN Mimarisi [112]

- **Faster R-CNN**

Bölge önermek için seçimli arama algoritmasını kullanmak yerine, bölge önerme ağı (Region Proposal Network (RPN)) kullanır. Bu şekilde işlem yükü azaltılır. Önceki R-

CNN modellerinden daha hızlıdır. RPN, evrişimli bir sinir ağıdır. Bir bölge önerirken ait olabileceği nesnelere her boyuttaki nesne puanına göre dikdörtgen bir önerme oluşturur. Öneri, evrişim katmanı tarafından oluşturulan özellik haritasındaki küçük bir ağı kaydırmaktır. Daha sonra üretilen hesaplamalar Fast R-CNN mimarisine verilir. Burada nesnenin sınıfı ve sınırlayıcı kutularla konumu tahmin edilir [113]. Faster R-CNN mimarisi Şekil 2.10’te gösterildiği gibidir.



Şekil 2.10 Faster R-CNN Mimarisi [113]

2.2.2.2 Tek Aşamalı Nesne Tespiti Algoritmaları

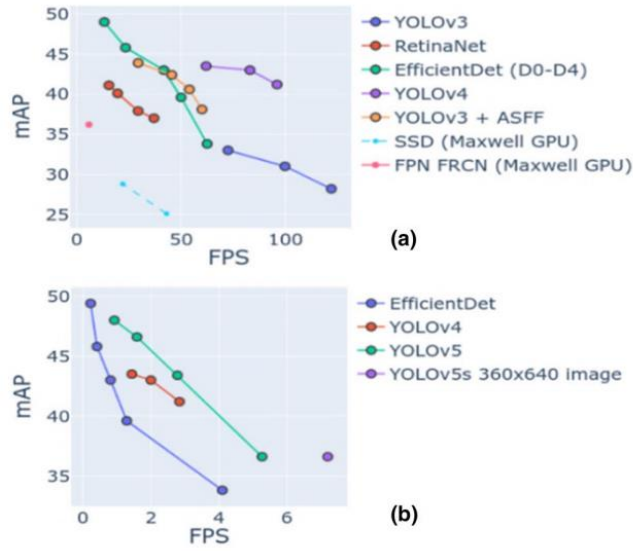
Tek aşamalı nesne tespit modelleri, bir ön adıma ihtiyaç duymadan nesnelere tespit yeteneğine sahiptir. Tek aşamalı nesne tespitinin avantajı, hızlı bir şekilde tahminlerde bulunabilmesi ve gerçek zamanlı kullanıma imkân sağlamasıdır. Tek aşamalı nesne dedektörleri, kayan bir pencere kullanarak çeşitli kategorilerdeki nesnelere bulur. Giriş görüntüleri ızgaralıdır ve bağlantı kutuları uzamsal olarak yerleştirilmiş bölgeleri temsil eder. Bu bölgelerin CNN çıkışları, nesnelere arka plandan ayırmak için kullanılır.

Algoritma daha kısa ve nettir, çünkü tek adımlı algoritmanın bir bölge önerisi oluşturması gerekmez. Sık kullanılan tek aşamalı nesne dedektörlerine örnek olarak SSD [117], YOLO [105] ve CornerNet [118] verilebilir. Bu noktada YOLOv5 algoritması hızıyla birlikte duyarlılığı ve kesinliği daha yüksek olduğu için detaylı olarak incelenecektir.

- YOLOv5s

YOLO algoritmaları, sınır kutularını ve içlerinde bir nesne olma olasılıklarını aynı anda öngören tek aşamadan oluşur. Bu yapı, diğer algoritmalara göre daha hızlı işlem süresi avantajı sağlar.

Bahsedilen nesne algılama algoritmalarının başarısını karşılaştırmak için; ortalama kesinlik değerinin ortalaması (mean average precision (mAP)) değeri kullanılır. Bu, algılanan nesnelere için öngörülen sınırlayıcı kutuların, gerçek kutular ile ne kadar iyi hizalandığının bir ölçüsüdür. Şekil 2.11, COCO veri kümesi [119] üzerindeki popüler nesne tespit algoritmalarının fps, diğer bir deyişle hız ve mAP değerlerini göstermektedir.



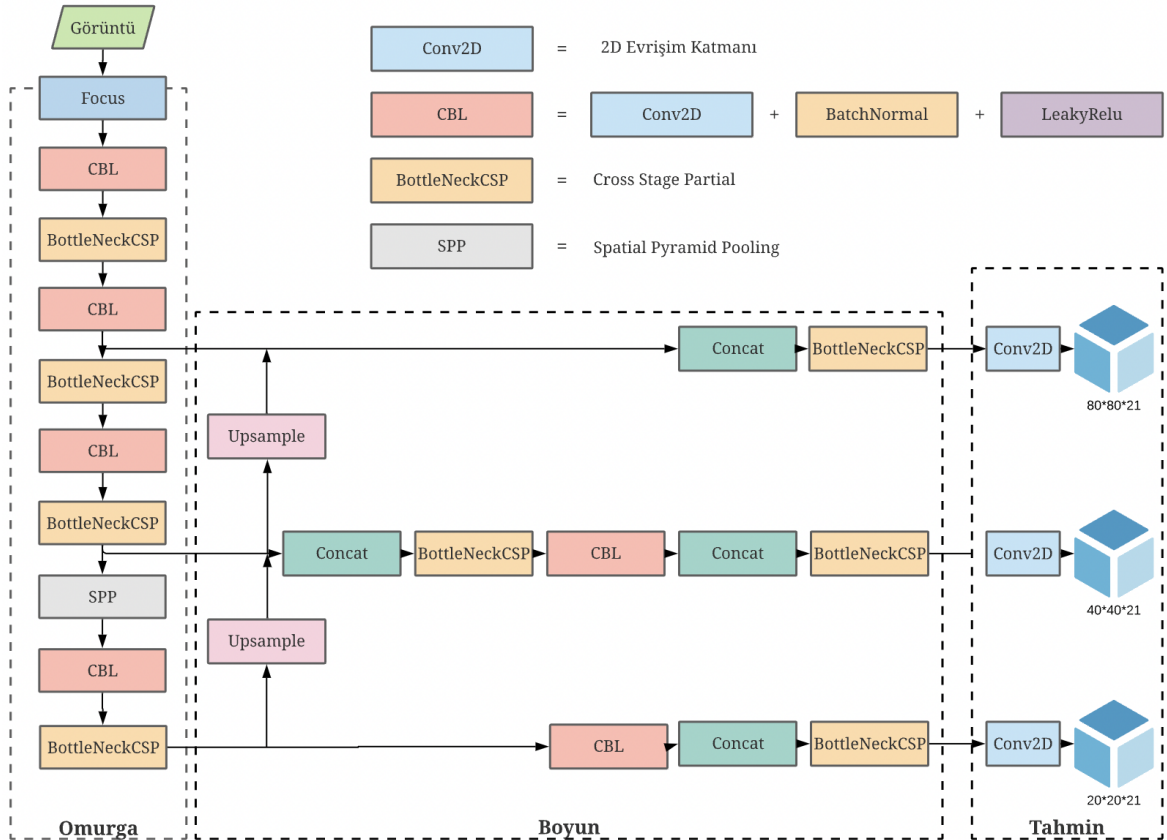
Şekil 2.11 Önemli modellerin hız ve mAP değerleri [120]

Şekil 2.11'de gösterildiği gibi YOLOv5, diğer nesne tespit algoritmalarından daha yüksek hız ve mAP değerlerine ulaşmaktadır. YOLOv5, nesnelere için tatmin edici kutular üretmede diğerlerini geride bırakan son derece güçlü bir algoritmadır [120]. Bu nedenle çalışmamızda kullanılmak üzere YOLOv5 algoritması seçilmiştir. YOLOv5, kendi içinde farklı konfigürasyonları da barındırmaktadır. Bu çalışmada diğer konfigürasyonlardan çok daha küçük boyutta olan YOLOv5s mimarisi kullanılmıştır. Dolayısıyla, bu durum performans açısından büyük bir avantaj yaratmaktadır.

YOLO mimarisi ilk olarak 2015 yılında ortaya çıkmış ve günümüze kadar çeşitli aşamalardan geçerek gelişimini sürdürmüştür. 2015 yılında Redmon vd. diğer nesne tespit algoritmalarından çok daha hızlı olan YOLO algoritmasını [105] önermişlerdir. Redmon vd. [106] 2018'de tespit hızını ve doğruluğunu daha da artıran YOLOv3 nesne

algılama algoritmasını literatüre tanıtmışlardır. 2020 yılına gelindiğinde ilginç gelişmeler yaşanmaya başlanmıştır. Bochkovskiy vd. [108], YOLOv4 nesne tespit algoritmasını önermiş ve Nisan 2020'de YOLO serisinin geliştirilmesine devam etmişlerdir. YOLOv4'ün yayınlanmasından kısa bir süre sonra, 30 Mayıs'ta YOLOv5, Ultralytics LLC ekibi tarafından yayınlanmıştır.

Şekil 2.11'de görüldüğü gibi, YOLOv5 algoritması çok başarılı sonuçlar üretmiştir. Diğer YOLO serisi algoritmalar ile karşılaştırıldığında YOLOv5, Tesla P100 ile algılamada 140 fps hıza ulaşabilir, buna karşılık YOLOv4 sadece 50 fps'ye ulaşabilmektedir [121]. YOLOv5 ve YOLOv4 yaklaşık olarak aynı doğruluğa sahip olsa da Darknet mimarisini kullanan YOLOv4 244 MB, YOLOv5s ise yalnızca 27 MB boyutundadır. YOLOv4'e dayalı olarak YOLOv5, EfficientDet'te doğruluğu, hızı ve model parametrelerinin sayısını dinamik olarak dengeleyebilen bileşik model ölçekleme yöntemiyle birleştirmiştir [122].



Şekil 2.12 YOLOv5'in detaylı mimarisi

Şekil 2.12'te gösterildiği gibi, YOLOv5 ağı üç ana parçadan oluşur:

1. Omurga (Backbone) - Omurga, farklı ayrıntı düzeylerinde görüntü özelliklerini toplayan ve oluşturan bir CNN'dir. Omurgada, $640 \times 640 \times 3$ çözünürlüklü giriş görüntüsü “Focus” yapısından geçer ve dilimleme işleminden sonra uygulanan 32 evrişim çekirdeği kullanılarak $320 \times 320 \times 32$ öznitelik haritası haline gelir. YOLOv5, çapraz aşamalı kısmi ağ (Cross Stage Partial Network (CSP)) darboğazı aracılığıyla görüntüden zengin bilgiler çıkararak öznitelik haritasında görüntü özellikleri oluşturur. CSP yapısı, ConvNet omurgalarının diğer büyük ölçekli ağlara kıyasla daha zengin bir gradyan kombinasyonu elde etmesini sağlar ve optimizasyon sürecinde gradyan bilgisi hesaplamasını azaltabilir.

2. Boyun (Neck) - Boyun parçası, görüntü özelliklerini karıştırmak, birleştirmek ve daha sonra bunları tahmine iletmek için kullanılan bir dizi katmandır.

3. Baş (Head) – Algoritmanın baş kısmı, boyundaki özellikleri ele alır, sınırlayıcı kutu ve sınıf adımlarının bir tahminini alır.

Tez kapsamında eğitilmiş olan YOLO algoritması, tespit edilen yangınların sınır kutusu değerlerinin koordinatlarını verir. Bu bilgi, daha sonra stereo görüş tabanlı mesafe tahminleri hesaplamalarında kullanılan, sol ve sağ kameralardaki konum parametrelerini elde etmek için çok faydalıdır.

2.3 Derinlik Tahmini Metodu Olarak Stereo Görüş

Derinlik tahmini, görüntüden derinliği tahmin etmek için tasarlanmış bilgisayarlı görü araştırma alanıdır ve bir sahnenin uzamsal yapısının bir temsilini elde etmek için bir dizi teknik ve algoritmaya dayanır. Derinlik tahmini, bilgisayarlı görü alanındaki ana çalışma başlıklarından biridir. Robotik, sahne anlama, üç boyutlu rekonstrüksiyon ve tıp alanında kullanım potansiyeli yüksek bir çalışma alanıdır.

Bu tezin odak noktası, pasif algılama tekniklerinden biri olan stereo görüş/epipolar geometri ile mesafe tahminidir. Ancak derinlik tahmini için, rekabet eden başka teknolojiler de mevcuttur. Diğerlerinin yanı sıra; uçuş zamanı (Time of Flight (ToF)) ölçümü, ultrasonik sensörler, ışık tespiti ve uzaklık tayini (Laser Imaging Detection and Range (LIDAR)) gibi yöntemler, çeşitli biçimlerde gelen aktif algılamaya güvenirlir.

2.3.1 ToF

ToF kameralar derinlik ölçümü için ışınları kullanır ve bunlarla uzaklık tahmini yapar. Kameradan gelen ışınlar nesnelere dönerek, nesnelere olan uzaklıkları hesaplanır. Ucuz ve hızlı bir kamera ile ölçüm yapılmasına rağmen, düşük görüntü kalitesi bu kamera ile ilgili bir sorundur.

2.3.2 Ultrasonik Sensörler

Ultrasonik sensörler, 20 kHz ve üzeri ses dalgaları ile mesafeyi tahmin etmek için kullanılırlar. Vericiden gönderilen sinyal ile alıcıdan gelen sinyal arasındaki zaman farkına bakılarak mesafe ölçümü yapılır [123]. Ultrasonik sensörlerin en önemli avantajlarından biri yağmur, kar, sis ve gün ışığı gibi hava koşullarından etkilenmemeleridir. Ancak, nispeten düşük ses hızı ve Doppler etkisi nedeniyle yüksek hızlarda performansını düşürebilir. Ayrıca ses dalgalarının yansımaları her zaman istenildiği gibi olmayabilir, bu da başarı oranını önemli ölçüde azaltır [123].

2.3.3 LIDAR

LIDAR'ın çalışma prensibi şu aşamalarla özetlenebilir: İlk aşamada, lazer sinyali cihaz tarafından gönderilir. İkinci aşamada, lazerin yansımaları algılanır. Üçüncü aşamada, ışık hızı kullanılarak iletilen lazer radyasyonu ile yansıyan lazer radyasyonu arasındaki zaman farkına dayalı olarak mesafe ölçümü yapılır. Sensörün konumu ve açısına göre yansıyan yüzeyin x, y ve z eksenleri hesaplanır. LIDAR cihazları ile 3 farklı değer bulunabilir. Bunlar ölçülen yüzeye olan mesafe, tarama açısı ve yansımaya katsayısıdır. Nesne tespit mesafeleri, 2,5 cm'lik bir hata payı ile 100 metreye kadar ulaşabilir. Bu sayede aynı anda binlerce noktayı çok yüksek hassasiyetle tanımlama imkânı sağlar. Ancak bu hassasiyet, diğer mesafe ölçüm tekniklerinden çok daha yüksek maliyetler gerektirir [124].

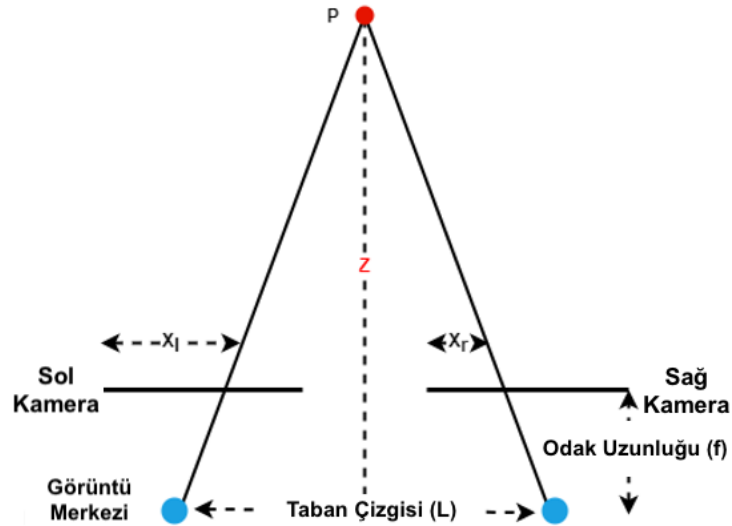
Aktif algılama ile derinliği ölçen bu tekniklerin dezavantajı, derinliği tespit etmek için gerekli ortamın bozulması durumudur. Yüksek doğruluk ve hassasiyetlerine rağmen, bu sensörler gerçek uygulamalar için pratik dağıtımlarını sınırlayan bazı önemli zayıflıklara sahiptir. Örneğin; LIDAR sensörleri, yanlış hizalama, yansıtıcı ve soğurucu yüzeyler nedeniyle eksik lazer dönüşleri sonucunda, hatalı hesaplanmış değerlere neden olabilir.

2.3.4 Stereo Görüş

Stereo görüş, iki veya daha fazla kamera tarafından aynı anda elde edilen görüntülerden derinlik çıkarımı için kullanılan bir tekniktir. Stereo görüş ile birbirine göre konumları bilinen kameralardan alınan görüntüler çeşitli işlemlerden geçirilerek nesnelerin coğrafi konum bilgisi elde edilebilir. Nesnelerin mesafesini ölçmek için kullanılan stereo görüş tabanlı yöntem, nesnelere herhangi bir sinyal emisyonu içermediği için pasif bir yöntemdir. Herhangi bir sinyal içermediğinden, mesafeyi ölçmek için arama alanını mümkün olduğunca daraltmak maksadıyla kullanılan geometrik işlemler, yoğun bir hesaplama zorluğu içerir.

İki kamera kullanılırken, stereo görüntüleme dört adımı içerir [125] :

1. Radyal ve teğet lens bozulması matematiksel olarak ortadan kaldırılır; buna distorsiyon denir,
2. Düzeltme adı verilen bir işlem ile kameralar arasındaki açılar ve mesafeler ayarlanır,
3. Sol ve sağ kamera görüntülerinde aynı özellikleri bulunur. Bu çakışma olarak bilinen bir işlemdir,
4. Kameraların geometrik düzeni bilindiğinden, eşitsizlik haritası üçgenleme (triangulation) yoluyla mesafelere çevrilir. Bu adıma reprojeksiyon denir.



Şekil 2.13 Stereo görüş temellerinin gösterimi

Stereo görüş tabanlı mesafe ölçüm yönteminin temellerini gösteren Şekil 2.13 aşağıdaki formülasyonlarla açıklanmıştır.

Denklem (2.2)'de gösterildiği gibi, kameraların odak uzunluklarının birbirine eşit olduğu varsayılmaktadır. f (Odak uzaklığı); ışığın kamera lensinin içinde bulunduğu noktadan , kamera sensörüne kadar olan mesafeyi göstermektedir.

$$f = f_l = f_r \quad (2.2)$$

Eşlenik noktalar arasındaki mesafe diğer adıyla eşitsizlik (d) değeri de denklem (2.3)'de ifade edilmektedir. Burada; x_l P (görüntünün gerçek dünyadaki noktası) noktasının sol kamera tarafından alınan görüntüdeki izdüşümünü, x_r ise P noktasının sağ kamera tarafından alınan görüntüdeki izdüşümünü ifade etmektedir.

$$d = x_l = x_r \quad (2.3)$$

Üçgenler arasında benzerlik kurulduğunda denklem (2.4) elde edilir.

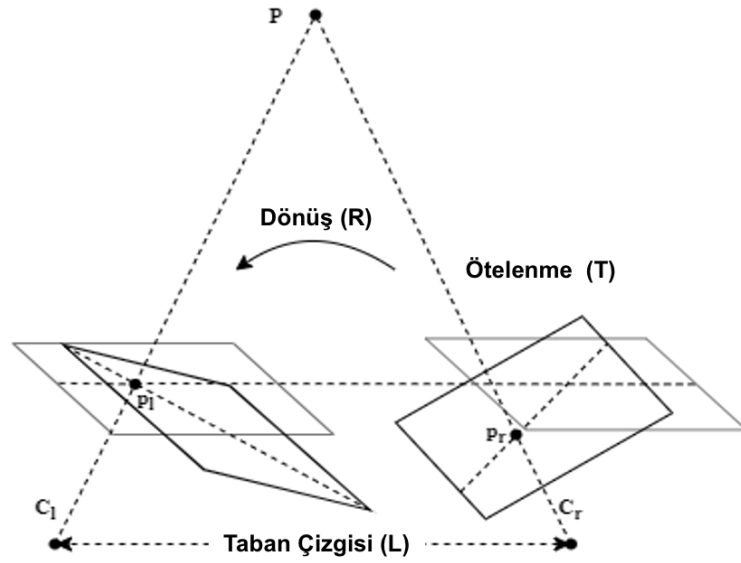
$$\frac{x}{x_l} = \frac{z}{f} \quad \frac{x-L}{x_r} = \frac{z}{f} \quad (2.4)$$

Denklem (2.4)'teki denklemler ortak bir çözümle çözümlerse, uzaydaki aralık olan Z mesafesi denklem (2.5)'teki gibi bulunur.

$$Z = \frac{f \times L}{x_l - x_r} \quad (2.5)$$

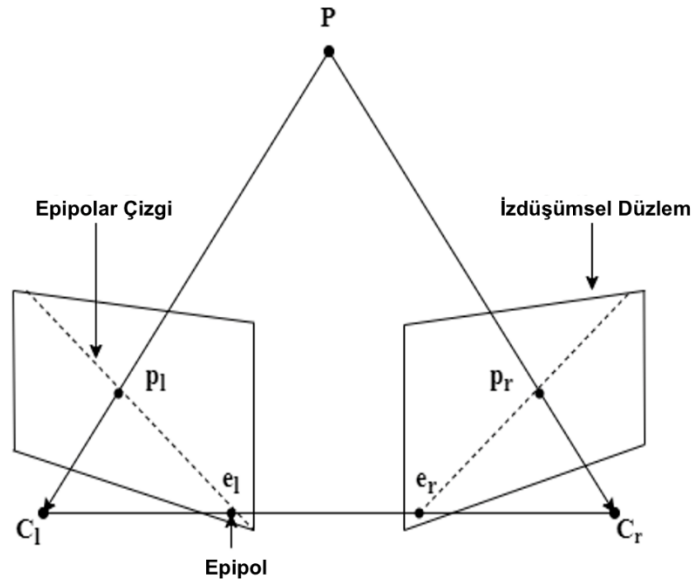
Denklemlerden de anlaşılacağı gibi, eşitsizlik değeri bilinerek nesnelerin uzaklıkları kolaylıkla belirlenebilir.

Tez çalışmasında; kameralar farklı açılarda ve konumlarda yerleştirildiği için Şekil 2.14'teki gibi durumlar ortaya çıkmaktadır. Bu nedenle ulaşmak istenilen matematiksel hizalamayı gerçekleştirebilmek için konunun daha detaylı incelenmesi gerekmektedir. Bu noktada öncelikle stereo görüş sisteminin temeli olan epipolar geometriye ait düzlem ve çizgi geometrisinin incelenmesi faydalı olacaktır.



Şekil 2.14 Kameralar arasındaki ötelenme (translation) ve döndürülme (rotation)

Stereo görüş kullanarak mesafe elde etmenin yaygın yöntemi, üçgenleme ve epipolar geometrinin kullanılmasıdır [126]. Epipolar geometri, iki perspektif kamera arasındaki geometrik ilişkidir [127]. Şekil 2.15'te görüldüğü gibi; epipolar geometri denklemine göre, p_l ve p_r görüntü düzleminde P noktasının görünüşleri ise P noktasının epipolar çizgi üzerinde olması gerekir. Bu şekilde epipolar geometri karşılık gelen özelliklerin aranmasını tek bir boyuta indirger, buna epipolar kısıtlama denir.



Şekil 2.15 Epipolar geometri yapısı

Epipolar geometri, iki görünüm arasındaki içsel projektif geometridir. Sahne yapısından bağımsızdır. Yalnızca kameraların dahili parametrelerine ve ilgili pozuna bağlıdır. Temel

matris (fundamental matrix) F bu içsel geometriyi kapsar. Temel matris, epipolar geometrinin matematiksel temsilidir [128]. F matrisini açıklamadan önce, gerekli (E) matrisinin (essential matrix) anlaşılması gerekir. E matrisi, kameraların fiziksel uzayda ötelenmesi (translation) ve döndürülmesi (rotation) hakkında bilgi içerir. E matrisinin içeriğine ek olarak, F matrisi kameraların içsel parametrelerini de içerir. Hesaplamaların detayları aşağıdaki gibidir:

İki görüntüde, p_l ve p_r 'de P 'nin gözlenen konumlarını birleştiren P noktasının bir ilişkisi elde edilmek istenmektedir. Bu ilişki, temel matrisin tanımı olarak hizmet edecektir.

Sol kameraya göre, C_l koordinat merkezi olacaktır. İncelenen noktanın konumu, p_l ve taban çizgisi (baseline) L 'dir. P noktası sağ kamerada p_r olarak görünür ve kamera koordinatları $p_r = R(p_l - L)$ şeklindedir. Düzlemdeki tüm x noktalarının n normal vektörü ile a noktasından geçtiği kabul edilirse denklem (2.6) yazılabilir.

$$x - a \cdot n = 0 \quad (2.6)$$

Epipolar düzleme, denklem (2.6) uygulandığında, denklem (2.7) elde edilir:

$$(p_l - L)^t (L \times p_l) = 0 \quad (2.7)$$

$p_r = R(p_l - L)$ denkleminin her iki tarafı da R^{-1} ile çarpıldığında denklem (2.8) elde edilir:

$$p_l - L = R^{-1} \cdot p_r \quad (2.8)$$

Bu değişimi yapmak ve bu $R^T = R^{-1}$ 'i kullanmak şu sonuçları verir:

$$(R^T \cdot p_r)^t (L \times p_l) = 0 \quad (2.9)$$

Bir çapraz çarpım, bir matris olarak yeniden yazılabilir. Böylece S matrisi şu şekilde tanımlanabilir:

$$(L \times p_l) = Sp_l \Rightarrow S = [0 \ -L_z \ L_y \ L_z \ 0 \ -L_x \ -L_y \ L_x \ 0] \quad (2.10)$$

Çapraz çarpımı değiştirerek:

$$(p_r)^t RSp_l = 0 \quad (2.11)$$

$E=RS$ denklemi kullanılarak aşağıdaki kompakt denkleme ulaşılır:

$$(p_r)^t Ep_l = 0 \quad (2.12)$$

Matris E , kameraların göreceli geometrisi hakkında tüm bilgileri içerir. Ancak, kameraların kendileri hakkında herhangi bir bilgi içermez. Bizim ilgilendiğimiz

parametre, görüntü üzerindeki piksel koordinatlarıdır. Görüntüdeki bir piksel ile diğer görüntüdeki eşleşen epipolar çizgiler arasındaki ilişkiyi bulmak için kameralar arasındaki içsel parametreler tanımlanır [125]. Bunu yapmak için, q değişkeni ve ilgili kameranın içsel parametreleri, p yerine piksel koordinatına dönüştürülür. K kamera içsel matrisi olarak atanırsa, q denklem (2.13)'deki gibi yazılır (K_l sol kamera içsel matrisidir, K_r sağ kamera içsel matrisidir)

$$q = Kp \quad (2.13)$$

Denklem (2.13) $p = K^{-1}q$ şeklinde de yazılabilir. Dolayısıyla E için denklem şöyle olur:

$$(p_r)^T (K_r^{-1})^T E K_l^{-1} q_l = 0 \quad (2.14)$$

F temel matrisi denklem (2.13)'den çözümlenirse denklem (2.14) elde edilir. Denklem (2.14) dikkatli bir şekilde incelenirse F temel matrisinin E temel matrisi ile aynı formda olduğu anlaşılacaktır. Ancak, temel matris F 'de kullanılan ifadeler piksel koordinatlarındayken, temel matris E 'de kullanılan ifadeler fiziksel koordinatlardadır.

$$F = (K_r^{-1})^T E K_l^{-1} \quad (2.15)$$

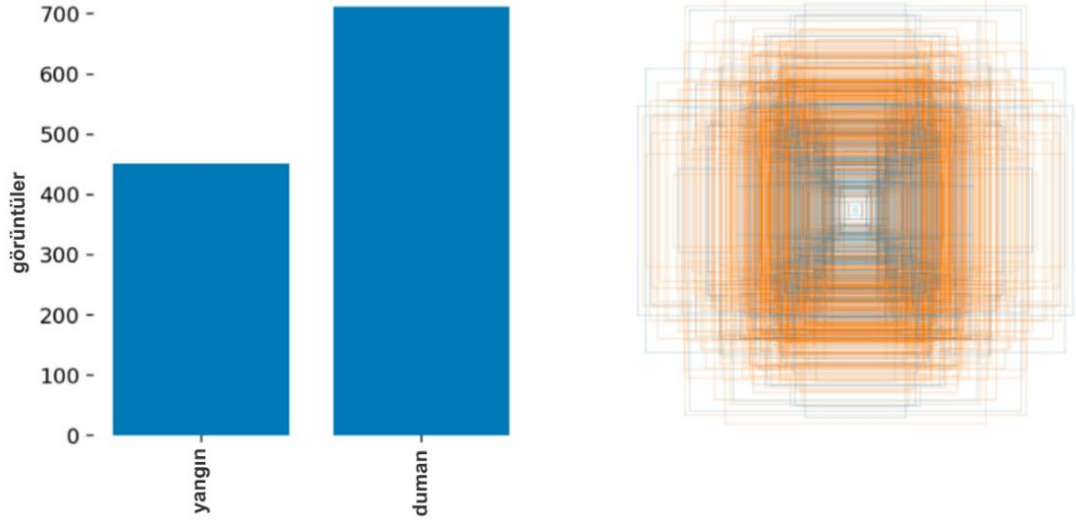
$$(q_r)^T F q_l = 0 \quad (2.16)$$

3.1 Uygulama ve İstanbul Örneđi

Bu bölümde uygulama aşamaları ve bu aşamalarda yapılan çalışmalar ele alınacaktır. İlk aşamada veri seti tanıtılacak, ardından YOLO algoritmasının eğitimi hakkında bilgi verilecektir. Bir sonraki adım olarak kamera kalibrasyon işlemi anlatılacaktır. Son aşamada ise yapılan uygulama genel olarak sunulacaktır.

3.1.1 Veri Seti

Veri seti, Türkiye'deki çeşitli itfaiye istasyonlarından ve açık kaynaklardan elde edilen 1200 farklı görüntüden oluşmaktadır. Şekil 3.1, görüntülerin sınıfsal ve boyutsal dağılımını göstermektedir. Şekil 3.2'de örneklem olarak seçilmiş, yangın ve duman sahneleri içeren bazı görüntüler gösterilmiştir. Ayrıca, labelImg uygulaması ile görüntüler sınıflandırılarak, ilgili sahneler kutucuk içerisine alınmıştır (annotation işlemi).



Şekil 3.1 (a) Veri setindeki görüntü sayısı (b) Görüntülere göre sınırlayıcı kutu boyut dağılımı



Şekil 3.2 Veri setinden örneklem olarak seçilmiş görüntüler

3.1.2 Sınıflandırıcı Modifikasyonu ve Eğitim Süreci

YOLO mimarisi COCO veri setine göre optimize edilmiştir. COCO veri kümesi 80 sınıf içerdiğinden, YOLO mimarisinin çıkış tensörünü kendi veri kümemizdeki sınıf sayısına göre ayarlamamız gerekmektedir. Bu noktada kabul edilen temel hesaplama $B \times A + C$ 'dir. B , her ızgara tahmini için üç şablon kutusunu temsil eder. A , beş sınırlayıcı kutu niteliğini (merkez koordinatları (b_x, b_y) , yükseklik (b_h) , genişlik (b_w) ve güven skoru) ifade eder ve C , sınıfların sayısıdır. Bu çalışmada önerilen yangın tespit algoritmasında, sırasıyla duman, yangın ve normal durum olmak üzere üç sınıf bulunmaktadır. Bu nedenle

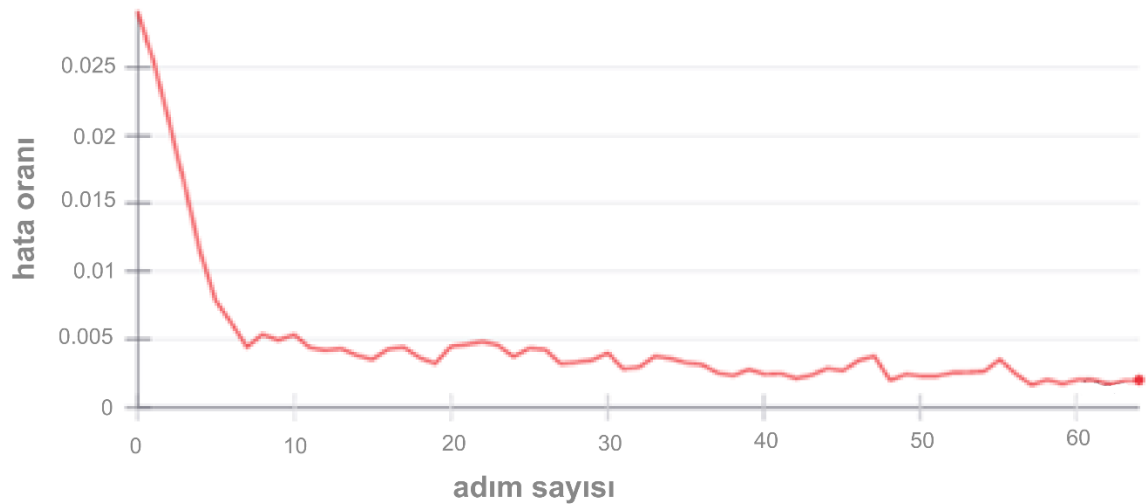
YOLOv5s sınıflandırıcısını, sınıf sayısına göre uyarlamak gerekmektedir. Bu hesaplama ile çıktı boyutu $3 \times (5 + 3) = 45$ olacaktır. Bu işlem ile ağ parametre miktarı azaltılarak hesaplama yükü azaltılabilir, algılama doğruluğu ve hızı artırılabilir.

Sınıflandırıcı ayarlarını yaptıktan sonra modelin eğitim aşamasına geçilir. Bu aşamada standart YOLOv5s mimarisi ile Tablo 3.1'deki parametreler kullanılarak eğitime başlanmıştır ve kayıp seviyesi stabilize olana kadar iterasyonlara devam edilmiştir.

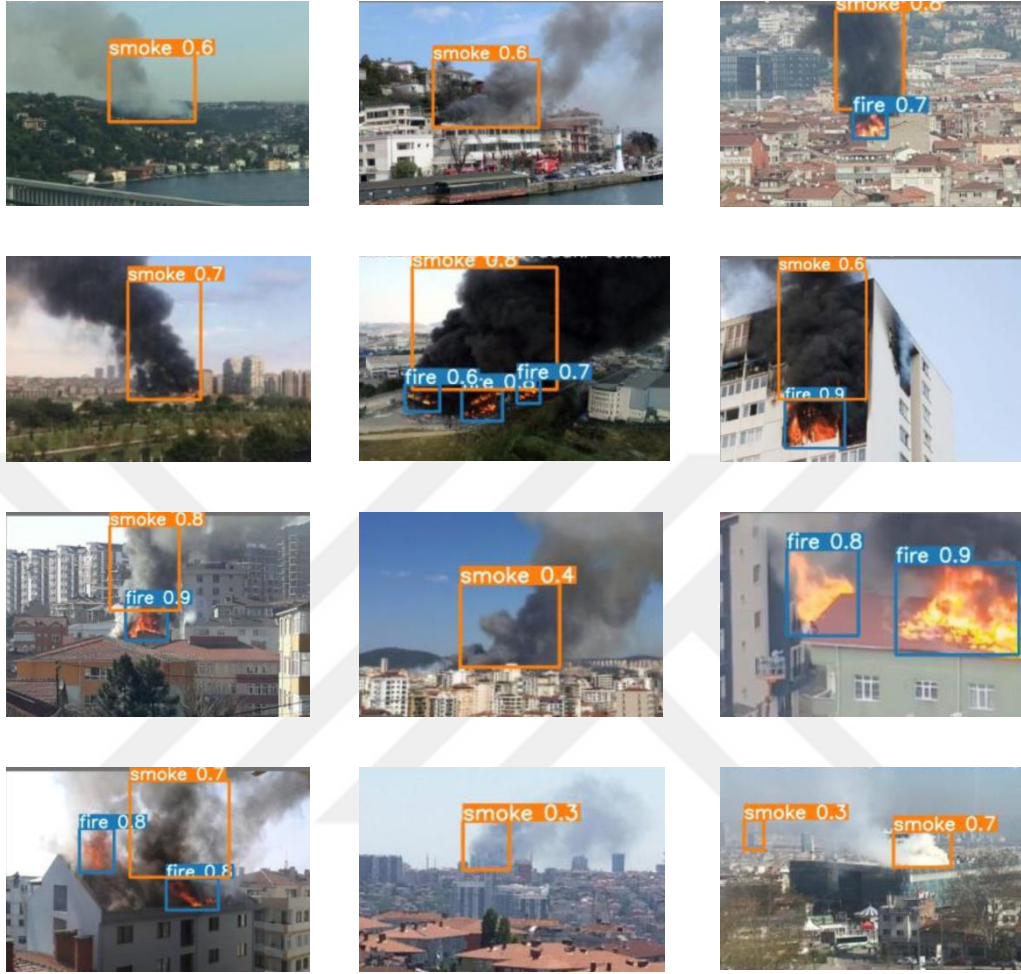
Tablo 3.1 Eğitim için kullanılan parametreler

Sınıflandırma	Parametre
İterasyon	800
Yığın (Batch)	16
Öğrenme Oranı	0.001
DOP	0.0005

Eğitim sürecinin kayıp eğrisinin gösterildiği Şekil 3.3'te görüldüğü gibi, kayıp, eğitimin ilk aşamalarında hızlı bir şekilde azalmıştır ve daha sonra iterasyon sayısı arttıkça ve sabit olma eğilimindeyken kademeli olarak aşağı doğru salınmıştır. Nihai eğitim sonuçları beklentileri karşılamıştır. Şekil 3.4, elde edilen ağırlıklara göre test edilen görüntülerin bazı sonuçlarını göstermektedir.



Şekil 3.3 Eğitim süreci kayıp eğrisi



Şekil 3.4 Veri kümesinde yangın tespit sonuçları

3.1.3 Kamera Kalibrasyonu

Kamera kalibrasyonu, genel anlamda bir kameranın parametrelerini tahmin etme işlemidir. Böylece, gerçek dünya 3D noktasını ve kalibre edilmiş kamera tarafından çekilen görüntüdeki karşılık gelen 2D projeksiyonunu düzgün bir şekilde ilişkilendirmek için gereken kamera için tüm parametreler elde edilir. Bu noktada, iki tür parametreye ulaşılır: (1) *Kamera/lens sisteminin temel parametreleri*. Örneğin, merceğin odak uzaklığı, optik merkez ve radyal bozulma katsayıları, (2) *Dışsal parametreler*, kameranın bazı dünya koordinat sistemlerine göre yönelimini (orientation) yani döndürmeyi (rotation) ve ötelemeyi (translation) ifade eder.


Döndürme (R) ve öteleme (t) dışsal parametrelerini kullanarak noktayı dünya koordinat sisteminden kamera koordinat sistemine dönüştürerek, görüntü düzleminde bir 3D noktanın izdüşümü bulunabilir.

İlk olarak, 3×3 K matrisi, 3×3 döndürme matrisi R ve 3×1 öteleme vektörü t , halihazırda bilinen bir dizi 3D koordinat noktası (X_w, Y_w, Z_w) kullanılarak bulunur. Daha sonra bunlara karşılık gelen görüntü piksel koordinatları (p_l, p_r) bulunur ve böylece kalibrasyon işleminin amacına ulaşılır. İçsel ve dışsal parametrelerin değerleri alındığında kameranın kalibre edildiği söylenebilir.

Özetlemek gerekirse, bir kamera kalibrasyon algoritmasının girdileri ve çıktıları aşağıdaki gibidir:

- (1) *Girdiler*: 2D görüntü koordinatları ve 3D gerçek koordinatları bilinen noktalara sahip bir görüntü havuzu,
- (2) *Çıktılar*: 3×3 kamera içsel matris, her görüntünün döndürme ve ötelenmesi.

Çalışmada; OpenCV kütüphanesi kullanılarak kalibrasyon yapılmıştır. Kalibrasyon için kullanılan görüntüler Şekil 3.5'te gösterilmiştir.



Şekil 3.5 Satranç tahtaları ile kalibrasyon

3.1.4 Deneysel Test Uygulaması

Bu çalışmanın amacı, önerilen çerçeveyi akıllı şehirlerde gerçek zamanlı olarak hayata geçirmektir. Bu amaca ulaşmak için iki aşamalı bir uygulama süreci tasarlanmıştır. İlk aşamada kalibre edilmiş kameraların yangın ve duman tespit başarı oranları ideal koşullar altında test edilmiştir. İkinci aşamada ise, önerilen çerçevenin birçok özelliği gerçek hayat uygulaması olarak, İstanbul'da seçilmiş bir bölgede test edilmiştir.

Deneysel uygulamanın her iki aşamasında da 16 GB RAM, Intel i7-6700HQ işlemci ve NVIDIA GeForce GTX 950M ekran kartına sahip kişisel bilgisayar kullanılmıştır. YOLOv5s algoritması, CUDA araç setini cuDNN kütüphanesiyle (library) çalıştırarak GPU desteği sağlamak için NVIDIA grafik kartında uygulanmıştır.

Bu deneysel testin ilk aşamasında, paralel olarak yerleştirilmiş ve kalibre edilmiş kameralar, önerilen çerçevede tasarlandığı gibi YOLOv5s mimarisi ile yangını tespit etmiştir. Ardından stereo görüş eşleştirmesinden sonra alevin kameraya olan mesafesi hesaplanmıştır. Yangınların mesafeleri, değerlendirme amacıyla önceden manuel olarak ölçülmüştür. Bu aşama, tüm gerekli koşulların karşılandığı, yani ideal koşullar altında, algoritmanın doğru sonuçlar verdiğini göstermek için uygulanmıştır. Deneyimizden elde edilen çıktıları artırmak ve sağlamasını yapmak için kameralar arasındaki taban çizgisi değiştirilmiş ve sonuçlar gözlemlenmiştir. Böylece kameraların şehirlere optimum açı ve mesafede konumlandırılabilmesi için ihtiyaç duyulacak parametreler üzerinde de bir ön bilgi sahibi olunmuştur. Sonuçlar Tablo 3.2'de sunulmuştur.

Tablo 3.2 Mesafe ölçüm test sonuçları

Test	Gerçek Mesafe (cm)	Kısa Taban Çizgisi (30 cm)		Uzun Taban Çizgisi (90 cm)	
		Ölçülen Mesafe (cm)	Hata (%)	Ölçülen Mesafe (cm)	Hata (%)
1	50	53.02	6.04	51.11	2.22
2	100	101.98	1.98	99.17	-0.83
3	150	156.15	4.1	153.89	2.59
4	200	207.68	3.84	205.24	2.62
5	250	259.92	3.96	258.41	3.36
6	300	311.32	3.77	290.83	3.05
7	350	348.69	-0.37	359.34	2.67
8	400	416.37	4.09	414.73	3.68
9	450	469.64	4.36	431.36	4.14
10	500	491.27	-1.74	518.41	3.68
11	550	523.06	-4.89	563.49	2.45
12	600	622.99	3.83	579.37	3.44
13	650	678.31	4.36	674.92	3.83
14	700	673.83	3.74	724.46	3.49
15	750	790.73	5.43	719.51	4.07
16	800	756.63	-5.4	826.35	3.29
17	850	901.44	6.05	883.74	3.96
18	900	859.48	-4.5	946.37	5.15
19	950	1014.32	6.77	989.69	4.17
20	1000	1076.98	7.69	1057.35	5.73

Uygulamanın ikinci aşamasında, bir pilot bölge seçilmiş ve bu bölgede önerilen çerçevenin işleyişini görmek için gerçek hayat uygulaması icra edilmiştir. Test, gerçek dünya ortamında algoritmanın çıktılarını ve performansını değerlendirmek için tatbik edilmiştir.

Bu noktada gerçek hayat uygulaması için İstanbul'u tercih etmemizin birçok nedeni bulunmaktadır.

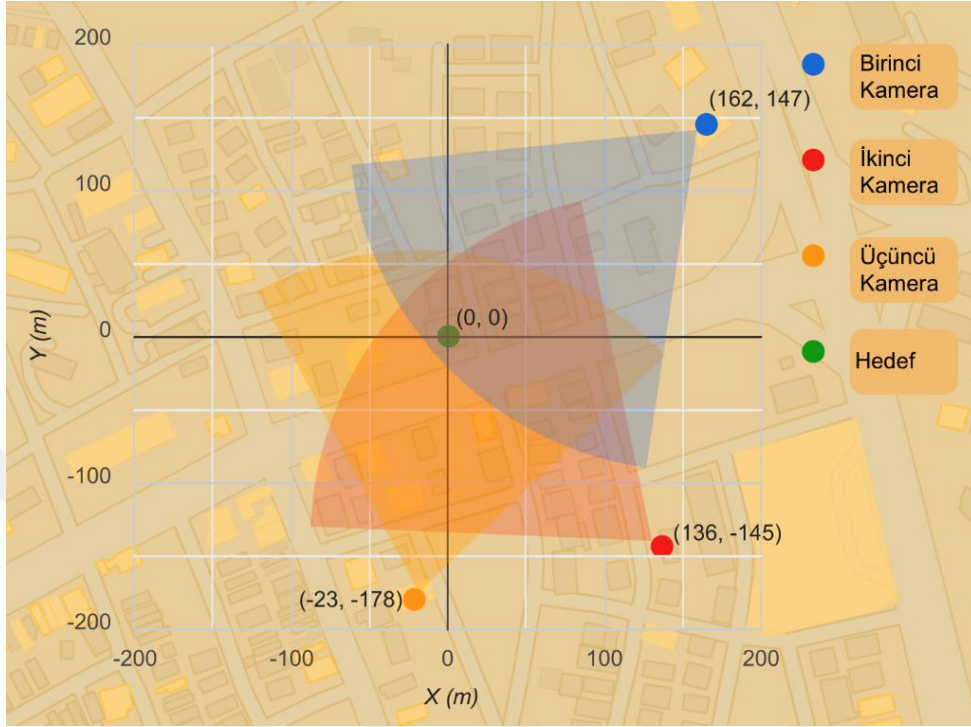
Birinci neden İstanbul'un jeopolitik ve ekonomik önemidir. İstanbul, Türkiye'nin en büyük şehridir. Ülke nüfusunun yaklaşık beşte biri olan 15 milyondan fazla insan İstanbul'da yaşamaktadır. Ayrıca İstanbul, Karadeniz'i Marmara Denizi'ne bağlayan ve Asya ile Avrupa'yı ayıran İstanbul Boğazı'na da ev sahipliği yapmaktadır. Ülkedeki toplam ithalatın yarısından fazlası İstanbul'da yapıldığından; jeopolitik avantajlarının da yardımıyla ülkenin ekonomik başkenti olmuştur. İstanbul'un bu siyasi ve ekonomik bağlamı, kentin risk ortamını anlamak açısından önemlidir. Çünkü bu, ulusal ve küresel sermaye döngülerindeki konumu ile oldukça ilişkilidir [129].

İkinci sebep ise İstanbul'un büyük nüfusu ve ekonomik dinamizmi ile Kuzey Anadolu Fay Hattı üzerinde yer almasıdır. Çalışmamızdaki motivasyon, bu fay hattında beklenen $MW=7,5$ büyüklüğündeki depremin yol açacağı hasarları azaltmak için katkıda bulunabilmek olmuştur.

Üçüncü neden; İstanbul'un akıllı şehir uygulamalarına yatırım yapan, dünyanın önde gelen şehirlerden birisi olmasıdır. Dördüncü neden ise İstanbul şehir hayatında; sanayi ve yaşam alanlarının iç içe geçmesi nedeniyle deprem sonrası yangınlara son derece açık olmasıdır. Diğer nedenler; yangın tespit sistemlerinin yaşam alanlarında yaygın olarak kullanılmaması ve küçük depremlerden sonra bile iletişim hatlarında yaşanan problemlerdir. Bu nedenler, İstanbul'da deprem sonrası yangınlara karşı önlem alınmasını zorunlu kılmış ve bizler için ana motivasyon kaynağını oluşturmuştur.


Daha önce de bahsedildiği gibi kameralar depreme dayanıklı telekomünikasyon kuleleri üzerine yerleştirilecek şekilde tasarlanmıştır. Böylece, geniş görüş açılına da sahip olmaktadır. Ancak, bölgede kullanılan depreme dayanıklı telekomünikasyon kulelerinin tam konum bilgisi güvenlik nedeniyle verilememektedir. Bu nedenle telekomünikasyon kulelerinin yer seçiminde kullanılan bilindik parametreler yardımıyla kulelerin yerleşimine uygun bir senaryo oluşturulmuştur. Senaryo verileri doğrultusunda, ortak yangın bölgesini farklı yatay açılarla algılamak için üç kamera yerleştirilmiş ve en

yakın açığa sahip iki kameranın değerleri seçilerek yangının coğrafi konumu belirlenmiştir. Oluşturduğumuz senaryoya uygun olarak yerleştirilen kameraların açıları ve gözlem alanları Şekil 3.6'de gösterilmektedir.



Şekil 3.6 Senaryoya göre yerleştirilen kamera konumları

Kameraların yerleştirilmesinin ardından planlanan bir binanın çatısında güvenlik önlemi alınarak yangın başlatılmıştır. Daha sonra önerilen çerçeve çalıştırılarak gerçek hayatta yangın tespiti ve yangın yerinin konumunun belirlenmesindeki işlevselliği gözlemlenmiştir. Önerilen çerçevenin, gerçek hayattaki test uygulamasının görüntüleri Şekil 3.7'de gösterilmektedir:



4.1 Deneysel Sonuçlar

Önerilen çerçevenin performansı iki ayrı senaryo kapsamında değerlendirilmiştir. Birincisi, ideal koşullar altında kamera mesafesi arttıkça ve taban çizgisi değişikçe doğruluk oranını belirlemek için oluşturulan senaryodur. İkincisi ise gerçek hayat şartlarına benzer bir şekilde oluşturduğumuz bir yangın ortamında çerçevenin doğruluğunun test edildiği senaryodur.

4.1.1 İdeal Koşullar Altındaki Sonuçlar

Bu senaryo, algoritmanın ideal koşullar altında tüm ön koşullarının yerine getirilmesiyle doğru sonuçlar verdiğini doğrulamak için oluşturulmuştur. Bu senaryonun test sonuçları değerlendirildiğinde, önerilen çerçevenin performansının beklentileri karşıladığı görülmüştür. YOLOv5s, mesafe tahmini sağlayan kesin sınır kutuları oluşturmuştur. Hassas sınırlayıcı kutulardan elde edilen değerler ve başarıyla kalibre edilmiş kameraların parametreleri ile stereo görüş hesaplamaları mesafe tahmininde çok doğru sonuçlar vermiştir.

Senaryo kapsamında kalibre edilmiş kameralar paralel olarak yerleştirilmiştir ve sistem başlatılmıştır. Ardından kameraların görüş alanına giren bir ateş yakılmıştır. Yangının kameralara olan mesafesi değiştirilerek mesafeye göre başarı oranları tespit edilmiştir. Tablo 3.1'den anlaşılacağı üzere, mesafe arttıkça algoritmanın ortalama mesafe algılama hata oranı artmaktadır. Ancak, hata oranının ivmesinin azaldığı bir ilerleme gözlemlenmektedir.

Bu senaryo kapsamında elde edilen bir diğer parametre de taban çizgisinin, mesafe belirleme doğruluk oranı üzerindeki etkisidir. Tablo 3.1'de görüldüğü gibi, diğer tüm değişkenler sabit tutulduğunda ve taban çizgisi 30 cm'den 90 cm'ye çıkarıldığında doğruluğun arttığı görülmektedir. Taban çizgisindeki artışla belirli bir mesafeye kadar doğruluk artışının gerçekleşeceği düşünülmektedir. Ancak belli bir mesafeden sonra görüntü çakışma alanlarında problemler olacaktır.

Ayrıca, bazı durumlarda, iki görüntüde de aynı anda yangın algılanmadığında, algoritma mesafeyi tahmin edememekte ve çıktı üretmemektedir. Stereo görüş mesafe tahmin algoritmasını başlatmak için yangınların en az iki kamerada, aynı anda, tespit edilmesi gerekmektedir.

4.1.2 Gerçek Hayat Uygulamasının Sonuçları

Bu test senaryosunun amacı, gerçek ortamda algoritma performansını değerlendirmektir. Senaryo tasarımında, gerçek deprem sonrası yangın koşulları dikkate alınmıştır. Bu senaryonun icrası için, bir evin çatısında kontrollü olarak yangın çıkarılmıştır. Yangını tespit etmek için farklı mesafelere üç kamera yerleştirilmiş ve sistem çalıştırılmıştır. Yangın en az iki kamera tarafından tespit edilir edilmez yangın yerinin konumu hesaplanmıştır. İkili kamera kombinasyonları sonucunda elde edilen yangın tespitine ait coğrafi konum çıktıları, gerçek coğrafi konum ile karşılaştırılmıştır. Bu karşılaştırma Tablo 4.1'te gösterilmiştir.

Tablo 4.1 Test sonuçlarının farklı kamera kombinasyonlarına göre karşılaştırılması

Hesaplama Kullanılan Kameralar	Taban Çizgisi(m)	Taban Çizgisinden Hedefe Olan Mesafe(m)	Kameralar Arası Aralık Açısı	Hata (m)
1-2	293.16	149	89.06 °	16
1-3	372.97	71.2	139.58°	15
2-3	162.39	171.1	50.53°	22

Bilindiği gibi, taban çizgisi (stereo kameralar arasındaki mesafe) ne kadar uzunsa, stereo görüşten elde edilen çıktı o kadar doğru olur [131]. Çalışmamızın sonuçları da bu varsayımı doğrulamaktadır. Başka bir deyişle, temel uzunluk arttıkça hata azalır. Ancak;

temel mesafe ile hatadaki azalmanın korelatif şekilde olmadığı da görülmektedir. Bunun sebeplerinden birinin kameraların aralık açısı olabileceği değerlendirilmiştir.

Test senaryosuna dayalı olarak, coğrafi konum belirlemede kabul edilebilir aralıkta hatalar tespit edilmiştir. Bu hata oranıyla önerilen çerçevenin yangına müdahale ekiplerini büyük ölçüde doğru bir şekilde yönlendirebileceği değerlendirilmektedir.

4.2 Öneriler

Deprem sonrası oluşabilecek yangınlar toplum için büyük bir tehdit oluşturmaktadır. Deprem sonrası kaotik bir ortamda oluşabilecek yangın olaylarının tespiti, aşılması gereken önemli bir problem olarak görülmektedir.

Bu çalışmada, deprem sonrası yangınların hızlı ve yüksek doğrulukta tespit edilmesini sağlayan, neredeyse insandan bağımsız, stereo ve YOLO tabanlı bir çerçeve önerilmiştir. Algoritmada, YOLOv5s mimarisine dayalı olarak farklı lokasyonlara yerleştirilen kameralar ile yangın tespiti gerçekleştirilmektedir. Yangın birden fazla kamera ile tespit edildiğinde, yangın görüntülerinin parametreleri stereo görüş teknikleri ile değerlendirilerek yangının coğrafi konumu elde edilir. Elde edilen coğrafi konum bilgisi WSN üzerinden afet yönetim merkezine iletilir ve yangına en kısa sürede müdahale edilmesi sağlanır.

Bu çalışmanın yaygın etkileri şu şekilde ifade edilebilir: (1) Önerilen çerçeve ile deprem sonrası yangınların görsel tabanlı sistemlerle gerçek zamanlı tespiti sağlanmaktadır. (2) Yangının coğrafi konumunun elde edilmesi ve afet yönetim merkezine bildirilmesi ile yangına hızlı müdahale imkânı yaratılmıştır. (3) Tüm bu işlemler, insan faktörlerinden bağımsız olarak ve deprem sonrası oluşabilecek iletişim kesintilerinden etkilenmeden gerçekleştirilebilecektir. (4) Bildiğimiz kadarıyla, deprem sonrası yangın tespitinde YOLOv5s mimarisi ilk kez kullanılmıştır. (5) Görüntü tabanlı yangın tespit sistemi kullanılarak diğer yangın tespit sistemlerinin dezavantajları aşılmıştır. (6) Stereo görüş tekniğini kullanarak, düşük maliyet ve yüksek doğrulukla, yangının coğrafi konumu elde edilmektedir. Önerilen çerçeve tüm bu yönleriyle literatürdeki boşluğu doldurmaktadır.

Gelecekte icra edilecek çalışmalarda, daha doğru tahminler elde etmek için sunulan çözümün nasıl geliştirilebileceğine dair fikirlerimiz ve yaklaşımlarımız bulunmaktadır:

(1) Ana hata kaynağı, YOLO mimarisinin çıkardığı sınır kutularını algılamadaki sapmalardır. YOLO'nun neden olduğu sorunlar, YOLO mimarisinin geliştirilmesi veya birleştirilmiş yöntemleri kullanılarak ortadan kaldırılabilir.

(2) Kullanılan sisteme LIDAR ve termal kameralar eklenerek çoklu kamera değerlendirme yöntemleri ile daha doğru sonuçlar alınabilir. Ancak bu durum, fazladan maliyet yaratabilir.

(3) Önerilen görsel yangın tespit sistemi çerçevesi, akıllı şehirlerde kullanılan diğer yangın tespit sistemleri ile entegre edilebilir. Böylece sistemler birbirini destekleyerek çalışabilir.

(4) İki kiden fazla kamerayla arama yaparken, en düşük aralık açısına sahip iki kameranın parametreleri kullanılmıştır. Ancak, tüm kamera parametreleri de kullanılabilir.

(5) Veri setindeki, karanlık ortamlarda elde edilmiş yangın ve duman görüntü sayısı artırılarak, önerilen görsel yangın tespit sisteminin gece elde edeceği başarı oranı artırılabilir. Böylece, insanların daha pasif durumda olduğu gece şartlarında, deprem sonrası yangın tespiti yüksek doğruluk oranıyla tespit edilebilir.

(6) Önerilen sistem, ormanlık alanlarda test edilerek, aktif yangın sistemlerinin kullanılmadığı ormanlık alanlarda kullanılmak suretiyle, geniş alanlarda nispeten az kamera sayısı ile yangın tespitinde kullanılabilir.

(7) Senaryolarda oluşan kabul edilebilir hatalar dikkate alınarak yanlış uyarıların olabileceği değerlendirilmiştir. Bu durumun önüne geçebilmek için afet yönetim merkezine gönderilen yangın uyarıları insan gözü ile teyit edilip kontrol edilebilir.

Sonuç olarak, kapsamlı testler, algoritma önerisinin deprem sonrası yangın tespiti için yararlı olabileceğini doğrulamıştır. Önerilen çerçeve, uygun maliyetli ve kolayca uyarlanabilir olacak şekilde tasarlanmıştır. Bu kapsamda önerilen çerçeve akıllı şehirlerin mevcut altyapısına kolayca entegre edilerek olası afetlerin önüne geçilebilecektir.

KAYNAKÇA

- [1] Petkova, E.P.; Vink, J.K.; Horton, R.M.; Gasparrini, A.; Bader, D.A.; Francis, J.D.; Kinney, P.L. Towards More Comprehensive Projections of Urban Heat-Related Mortality: Estimates for New York City under Multiple Population, Adaptation, and Climate Scenarios. *Environ. Health Perspect.* 2017, 125, 47–55.
- [2] Nations, U. *World Urbanization Prospects: The 2018 Revision*; United Nations: New York, NY, USA, 2019; pp. 1–126.
- [3] S. Yildiz, H. Karaman. Post-earthquake ignition vulnerability assessment of Küçükçekmece District. *Nat. Hazards Earth Syst. Sci.*, 13, 3357–3368, 2013.
- [4] S. Zhao, L. Xiong, R. Aizhu. Risk Assessment of Potential Urban Post-Earthquake Fire Based on UGIS Grid Abstract. *Fifth Annu. IIASA-DPRI Meet.* (2005) 1–14.
- [5] G. Hou, Q. Li. Firefighting capacity evaluation of water distribution system subjected to multi-ignitions of post-earthquake fires. *Structural Safety*, Volume 88, January 2021, 102035.
- [6] Jeon SS, O'Rourke TD. Northridge earthquake effects on pipelines and residential buildings. *Bull Seismol Soc Am* 2005;95(1):294–318
- [7] Sekizawa AI. Post-earthquake fires and performance of firefighting activity in the early stage in the 1995 Great Hanshin-Awaji earthquake. In: *IFAC Workshop on Control in Natural Disasters*; 1998 Sep 21-22; Tokyo, Japan. Japan. Oxford: Pergamon; 1999. p. 1999.
- [8] C. Scawthron, G.S. Johnson, 2000-Preliminary report Kocaeli (Izmit) earthquake of 17 August 1999. *Engineering Structures* 22 (2000) 727–745.
- [9] Fire and Disaster Management Agency. Report on the 2011 Tohoku Earthquake (Great East Japan Earthquake Disaster) 2018. *Journal of Systems and Software*, Volume 83, Issue 10, October 2010, Pages 1701-1714.
- [10] Smart Cities Council. 2019. "Smart cities readiness guide®." Son erişim: 17Kasım 2020. Erişim adresi: <https://rg.smartcitiescouncil.com/readiness-guide/article/definition-definition-smart-city>.
- [11] A. Sharma, P.K. Singh, Y. Kumar. An integrated fire detection system using IoT and image processing technique for smart cities. *Sustainable Cities and Society*, Volume 61, October 2020, 102332.

- [12] S. Hanif, A.M. Khedr, Z. Aghbari, D. P. Agrawal. Opportunistically exploiting internet of things for wireless sensor network routing in smart cities. *J. Sens. Actuator Netw.* 2018, 7, 46.
- [13] D.N. Ford, C.M. Wolf. Smart Cities with Digital Twin Systems for Disaster Management. *J. Manage. Eng.*, 2020, 36(4): 04020027.
- [14] Caragliu A, Del Bo C, Nijkamp P. Smart cities in Europe. *J Urban Technol.* 2011;18(2):65-82.
- [15] Ferrara R. The Smart City and the green economy in Europe: a critical approach. *Energies.* 2015;8(6):4724-4734.
- [16] J.H. Lee, M.G. Hancock, M. Hu. Towards an effective framework for building smart cities: Lessons from Seoul and San Francisco. *Technological Forecasting & Social Change* 89 (2014) 80–99
- [17] Neirotti P, De Marco A, Cagliano AC, et al. Current trends in Smart City initiatives: some stylised facts. *Cities.* 2014;38:25-36.
- [18] Su K, Li J, Fu H. Smart city and the applications. *International Conference on Electronics, Communications and Control (ICECC)IEEE.* 2011; 2011:1028-1031
- [19] Nam T, Pardo TA. Conceptualizing Smart City with Dimensions of Technology, People, and Institutions. *Proceedings of the 12th Annual International Conference on Digital Government Research, DG.O 2011, College Park, MD, USA, 2011:282–291.*
- [20] Kloeckl K, Senn O, Ratti C. Enabling the real-Time City: LIVE Singapore. *J Urban Technol.* 2012;19(19):89-1
- [21] Cerchecci M, Luti F, Mecocci A, Parrino S, Peruzzi G, Pozzebon A. A low power IoT sensor node architecture for waste management within smart cities context. *Sensors.* 2018;18(4):1282.
- [22] Kitchin R. The real-time city? Big data and smart urbanism. *Geojournal.* 2014;79(1):1-14.
- [23] Sanchez L, Muñoz L, Galache JA, et al. SmartSantander: IoT experimentation over a smart city testbed. *Computer Networks.* 2014;61(6): 217-238
- [24] Yamagata Y, Seya H. Simulating a future smart city: an integrated land use-energy model. *Appl Energy.* 2013;112(4):1466-1474.
- [25] E. Çaktı, E. Şafak, U. Hancılar, K. Şeşetyan: İstanbul İli Olası Deprem Kayıp Tahminlerinin Güncellenmesi Projesi. Son erişim: 31 Ocak 2022. Erişim adresi: <https://depremezemin.ibb.istanbul/calismalarimiz/tamamlanmis-calismalar/istanbul-ili-olasi-deprem-kayip-tahminlerinin-guncellenmesi-projesi/>.
- [26] İstanbul Büyükşehir Belediyesi Afet Koordinasyon Merkezi Risk Planlama Çalışmaları. Son erişim: 21 Kasım 2022. Erişim adresi: <https://akom.ibb.istanbul/hazirlik-planlama-calismalari/>.
- [27] Manfreda, S.; McCabe, M.F.; Miller, P.E.; Lucas, R.; Madrigal, V.P.; Mallinis, G.; Dor, E.B.; Helman, D.; Estes, L.; Ciraolo, G.; et al. On the use of unmanned aerial systems for environmental monitoring. *Remote Sens.* 2018, 10, 641.
- [28] Hakala, T.; Honkavaara, E.; Saari, H.; Mäkynen, J.; Kaivosoja, J.; Pesonen, L.; Pölonen, I. Spectral Imaging From Uavs Under Varying Illumination Conditions.

- ISPRS Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. 2013, XL-1/W2, 189–194.
- [29] Pádua, L.; Vanko, J.; Hruška, J.; Adão, T.; Sousa, J.J.; Peres, E.; Morais, R. UAS, sensors, and data processing in agroforestry: A review towards practical applications. *Int. J. Remote Sens.* 2017, 38, 2349–2391.
- [30] Chuang, S. W., D. D. Woods, C. A. Lee, C. H. Cheng, and H. C. Chen. 2018. “Coping with communication challenges after the Formosa Fun Coast Dust Explosion.” In *Proc., Resilience Week 2018*, 5–10. New York: Institute of Electrical and Electronics Engineers.
- [31] Cheng, S. S. 2013. “Crisis communication failure: A case study of Typhoon Morakot.” *Asian Soc. Sci.* 9 (3): 13–32. <https://doi.org/10.5539/ass.v9n3p18>
- [32] C.-B. Liu, N. Ahuja, Vision based fire detection, in: *Proceedings of the 17th International Conference on Pattern Recognition, ICPR 2004*, 2004, pp. 134–13
- [33] P.V.K. Borges, E. Izquierdo, A probabilistic approach for vision-based fire detection in videos, *IEEE Trans. Circuits Syst. Video Technol.* 20 (2010) 721–731.
- [34] Z. Zhang, J. Zhao, D. Zhang, C. Qu, Y. Ke, B. Cai, Contour based forest fire detection using FFT and wavelet, in: *Proceedings of International Conference on Computer Science and Software Engineering*, 2008, pp. 760–763.
- [35] W. Phillips Iii, M. Shah, N.da Vitoria Lobo, Flame recognition in video, *Pattern Recogn. Lett.* 23 (2002) 319–327.
- [36] D. Han, B. Lee, Development of early tunnel fire detection algorithm using the image processing, in: *Proceedings of International Symposium on Visual Computing*, 2006, pp. 39–48.
- [37] Fujiwara N, Terada K (2004) Extraction of a smoke region using fractal coding. In: *International symposium on communications and information technology*, Sapporo, Japan, pp 659–662
- [38] Gubbi J, Marusic S, Palaniswami M (2009) Smoke detection in video using wavelets and support vector machines. *Fire Saf J* 44:1110–1115
- [39] Polednik BcT. (2015) Detection of fire in images and videos. *Excel@FIT* 1–11
- [40] Horng WB, Peng JW, Chen CY (2005) A new image-based real-time flame detection method using color analysis. In: *Proceedings of the 2005 IEEE networking, sensing and control*, Tucson, AZ. pp 100–105
- [41] Marbach G, Loepfe M, Brupbacher T (2006) An image processing technique for fire detection in video images. *Fire Saf J* 41:285–289
- [42] Borges PVK, Izquierdo E (2010) A probabilistic approach for vision-based fire detection in videos. *IEEE Trans Circuit Syst Video Technol* 20(5):721–731
- [43] Horng WB, Peng JW (2008) A fast image-based fire flame detection method using color analysis. *Tamkang J Sci Eng* 11(3):273–285
- [44] Qi X, Ebert J (2009) A computer vision based method for fire detection in color videos. *Int J Imaging* 2(9):22–34
- [45] Gunay O et al (2010) Fire detection in video using LMS based active learning. *Fire Technol* 46:551–577

- [46] Gunay O, Tasdemir K, Toreyin BU, Cetin AE (2009) Video based wildfire detection at night. *Fire Saf J* 44:860–868
- [47] Han D, Lee B (2009) Flame and smoke detection method for early real-time detection of a tunnel fire. *Fire Saf J* 44:251–261
- [48] Ko BC, Cheong KH, Nam JY (2009) Fire detection based on vision sensor and support vector machines. *Fire Saf J* 44:322–329
- [49] Zhu T, Jeong-Hyun K, Dong-Joong K (2010) Fire detection based on hidden Markov models. *Int Control Autom Syst* 8(4):822–830
- [50] Chen J, He Y, Wang J (2010) Multi-feature fusion based fast video flame detection. *Build Environ* 45:1113–1122
- [51] Ko BC, Cheong KH, Nam JY (2010) Early fire detection algorithm based on irregular patterns of flames and hierarchical Bayesian Networks. *Fire Saf J* 45:262–270
- [52] Ko BC, Ham SJ, Nam JY (2011) Modeling and formalization of fuzzy finite automata for detection of irregular fire flames. *IEEE Trans Circuits Syst Video Technol* 21(12):1903–1912
- [53] Rossi L, Akhloufi M, Tison Y (2010) On the use of stereovision to develop a novel instrumentation system to extract geometric fire fronts characteristics. *Fire Saf J* 46:9–20
- [54] Yunyang Y, Shangbing G, Hongyan W, Zhibo G (2012) Contour extraction of flame for fire detection. *Adv Mater Res* 383–390:1106–1110
- [55] Qiu T, Yan Y, Lu G (2012) An auto-adaptive edge detection algorithm for flame and fire image processing. *IEEE Trans Instrum Meas* 61(5):1486–1493
- [56] Mueller M, Karasev P, Kolesov I, Tannenbaum A (2013) Optical flow estimation for flame detection in videos. *IEEE Trans Image Process* 22(7):2786–2797
- [57] Rong J et al (2013) Fire flame detection based on GICA and target tracking. *Opt Laser Technol* 47:283–291
- [58] Wang DC et al (2013) Adaptive flame detection using randomness testing and robust features. *Fire Saf J* 55:116–125
- [59] Ko BC, Jung JH, Nam JY (2014) Fire detection and 3D surface reconstruction based on stereoscopic pictures and probabilistic fuzzy logic. *Fire Saf J* 68:61–70
- [60] Schroder T, Kruger K, Kummerlen F (2014) Image processing based deflagration detection using fuzzy logic classification. *Fire Saf J* 65:1–10
- [61] Stadler A, Windisch T, Diepold K (2014) Comparison of intensity flickering features for video based flame detection algorithm. *Fire Saf J* 66:1–7
- [62] Zhang Z (2014) An improved probabilistic approach for fire detection in videos. *Fire Technol* 50:745–752
- [63] Foggia P, Saggese A, Vento M (2015) Real-time fire detection for video surveillance applications using a combination of experts based on color, shape, and motion. *IEEE Trans Circuits Syst Video Technol* 25(9):1545–1556

- [64] Dimitropoulos K, Barmpoutis P, Grammalidis N (2015) Spatio-temporal flame modelling and dynamic texture analysis for automatic video-based fire detection. *IEEE Trans Circuits Syst Video Technol* 25(2):339–351
- [65] Qureshi WS et al (2016) QuickBlaze: early fire detection using a combined video processing approach. *Fire Technol* 52:1293–1317
- [66] Rui C, Zhe-Ming L, Qing-Ge J (2017) Real-time multi-feature based fire flame detection in video. *IET Image Process* 11(1):31–37
- [67] Han XF et al (2017) Video fire detection based on Gaussian mixture model and multi-color features. *Signal Image Video Process* 11(8):1419–1425
- [68] Gong F et al (2019) A real-time fire detection method from video with multifeature fusion. *Comput Intell Neurosci* 2019, Article ID 1939171, pp 1–17
- [69] Muhammad K., Ahmad J., Baik S.V.: Early fire detection using convolutional neural networks during surveillance for effective disaster management. *Neurocomputing* 288 (2018) 30–42.
- [70] Cun YL, Bengio Y, Hinton G (2015) Deep learning. *Nat Int J Sci* 521:436–444
- [71] A. Gaur, A. Singh, A. Kumar, A. Kumar. Video Flame and Smoke Based Fire Detection Algorithms: A Literature Review. *Fire Technology*, 56, 1943–1980, 2020.
- [72] Frizzi, S., Kaabi, R., Bouchouicha, M., Ginoux, J.M., Moreau, E., Fnaiech, F., 2016. Convolutional neural network for video fire and smoke detection. *IECON Proceedings (Industrial Electronics Conference)*, 877–882, <http://dx.doi.org/10.1109/IECON.2016.7793196>.
- [73] Zhang, Q., Xu, J., Xu, L., Guo, H., 2016. Deep convolutional neural networks for forest fire detection. *2016 Int. Forum Manag. Educ. Inf. Technol. Appl* 47, 568–575, <http://dx.doi.org/10.2991/ifmeita-16.2016.105>.
- [74] Kim S et al (2016) Forest fire monitoring system based on aerial image. In: *2016 3rd International conference on information and communication technology for disaster management*, Vienna, pp 1–6
- [75] Wang, Z., Wang, Z., Zhang, H., Guo, X., 2017. A novel fire detection approach based on CNN-SVM using tensorflow. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 10363., pp. 682–693, http://dx.doi.org/10.1007/978-3-319-63315-2_60.
- [76] Huttner V, Steffens CR, Silva da Costa Botelho S (2017) First response fire combat: deep learning based visible fire detection. In: *2017 Latin American robotics symposium and 2017 Brazilian symposium on robotics*, Curitiba, pp 1–6
- [77] Muhammad K et al (2018) Convolutional neural networks based fire detection in surveillance videos. *IEEE Access* 6:18174–18183
- [78] Shen D, Chen X, Nguyen M, Yan WQ (2018) Flame detection using deep learning. In: *Proceedings of the 2018 4th international conference on control automation and robotics*, Auckland. pp 416–420
- [79] Zhao Y, Ma J, Li X, Zhang J (2018) Saliency detection and deep learning-based wildfire identification in UAV imagery. *Sensors* 18:1–19

- [80] Aslan S, Gudukbay U, Toreyin BU, Cetin AE (2019) Deep convolutional generative adversarial networks based flame detection in Video. arXiv preprint arXiv: 1902.01824
- [81] Muhammad K et al (2019) Efficient deep CNN based fire detection and localization in video surveillance applications. *IEEE Trans Syst Man Cybern Syst* 49(7):1419–1434
- [82] Kim B, Lee J (2019) A video-based fire detection using deep learning models. *Appl Sci* 9(2862):1–19
- [83] Yin Z et al (2017) A deep normalization and convolutional neural network for image smoke detection. *IEEE Access* 5:18429–18438
- [84] Xu G, Zhang Q, Liu D, Lin G, Wang J, Zhang Y (2019) Adversarial adaptation from synthesis to reality in fast detector for smoke detection. *IEEE Access* 7:29471–29483
- [85] Xu G et al (2019) Video smoke detection based on deep saliency Network. *Fire Saf J* 105:277–285
- [86] Namozov A, Cho YI (2018) An efficient deep learning algorithm for fire and smoke detection with limited data. *Adv Electr Comput Eng* 18(4):121–128
- [87] Hu Y, Lu X (2018) Real-time video fire smoke detection by utilizing spatial-temporal ConvNet features. *Multimed Tools Appl* 77:29283–29301
- [88] Gaohua L, Yongming Z, Gao X, Qixing Z (2019) Smoke detection on video sequences using 3D convolutional neural networks. *Fire Technol* 55:1827–1847
- [89] Jadon A et al (2019) FireNet: a specialized lightweight fire and smoke detection model for real-time IoT applications. arXiv preprint arXiv: 1905.11922
- [90] Jadon, A., Varshney, A., & Ansari, M. S. (2020). Low-complexity high-performance deep learning model for real-time low-cost embedded fire detection systems. *Procedia Computer Science*, 171, 418-426.
- [91] Sun, K., Zhao, Q., & Wang, X. (2021). Using knowledge inference to suppress the lamp disturbance for fire detection. *Journal of Safety Science and Resilience*, 2(3), 124-130.
- [92] Huang, L., Liu, G., Wang, Y., Yuan, H., & Chen, T. (2022). Fire detection in video surveillances using convolutional neural networks and wavelet transform. *Engineering Applications of Artificial Intelligence*, 110, 104737.
- [93] Lowe, D. G. (2004). Distinctive Image Features from Scale-Invariant Keypoints, *International Journal of Computer Vision*, 60(2), 91-110.
- [94] Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded Up Robust Features (SURF), *Computer Vision and Image Understanding*, 110(3), 346-359.
- [95] Dalal, N., & Triggs, B. (2005). Histograms of Oriented Gradients for Human Detection, 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, CA, USA: June 20-25.
- [96] Lecun, Y., Bottou, L., Bengio, Y. & Haffner, P. (1998). Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.
- [97] Hinton, G. E. (2006). Reducing the Dimensionality of Data with Neural Networks, *Science*, 313(5786), 504-507.

- [98] Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 84- 90.
- [99] Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). Implementation of Training Convolutional Neural Networks. Retrieved December 10, 2020 from <https://arxiv.org/abs/1506.01195>.
- [100] F. Zhou, H. Zhao, Z. Nie. Safety Helmet Detection Based on YOLOv5. 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA).
- [101] Tan, M., Pang, R., Le, Q.V.: Efcientdet: Scalable and efcient object detection. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 10781–10790 (2020)
- [102] Ren, S., He, K., Girshick, R., Sun, J.: Faster R-CNN: towards realtime object detection with region proposal networks. *Advances in neural information processing systems*, pp. 91–99 (2015)
- [103] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., Berg, A.C.: SSD: single shot multibox detector. In: *European Conference on Computer Vision*, pp. 21–37. Springer (2016)
- [104] Lin, T.-Y., Goyal, P., Girshick, R., He, K., Dollár, P.: Focal loss for dense object detection. In: *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2980–2988 (2017)
- [105] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [106] Joseph Redmon Ali Farhad. Yolov3: An incremental improvement. arXiv:1804.02767v1 [cs.CV] 8 Apr 2018
- [107] YOLOv5. Son erişim: 24 Şubat 2021. Erişim linki: <https://github.com/ultralytics/yolov5>.
- [108]Bochkovskiy, A., Wang, C.Y., Liao, H.Y.M.: YOLOv4: optimal speed and accuracy of object detection. arXiv preprint 2004.10934 (2020)
- [109] Redmon, J., Ali, F.: YOLO9000: better, faster, stronger. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7263–7271 (2017)
- [110] Du, L., Zhang, R., Wang, X. (2020). Overview of two-stage object detection algorithms. In *Journal of Physics: Conference Series* (Vol. 1544, No. 1, p. 012033). IOP Publishing.
- [111] Girshick, R., Donahue, J., Darrell, T., Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- [112] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [113] Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28, 91-99.

- [114] He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017). Mask r-cnn. In Proceedings of the IEEE international conference on computer vision (pp. 2961-2969).
- [115] Dai, J., Li, Y., He, K., Sun, J. (2016). R-fcn: Object detection via region-based fully convolutional networks. In Advances in neural information processing systems (pp. 379-387).
- [116] Uijlings, J. R., Van De Sande, K. E., Gevers, T., Smeulders, A. W. (2013). Selective search for object recognition. *International journal of computer vision*, 104(2), 154-171.
- [117] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., Berg, A. C. (2016). Ssd: Single shot multibox detector. In European conference on computer vision (pp. 21-37). Springer, Cham.
- [118] Law, H., ve Deng, J. (2018). Cornernet: Detecting objects as paired keypoints. In Proceedings of the European conference on computer vision (ECCV) (pp. 734-750).
- [119] Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., Zitnick, C.L.: Microsoft coco: Common objects in context. In: European Conference on Computer Vision, pp. 740–755. Springer, Cham (2014)
- [120] B. Gaikwad, A. Karmakar. Smart surveillance system for real-time multi-person multi-camera tracking at the edge. *Journal of Real-Time Image Processing* <https://doi.org/10.1007/s11554-020-01066-8>
- [121] G. Yang, W. Feng, J. Jin, Q. Lei, X. Li, G. Gui, W. Wang. Face Mask Recognition System with YOLOV5 Based on Image Recognition. 2020 IEEE 6th International Conference on Computer and Communications.
- [122] Z. Song , J. Yang, D. Zhang, S. Wang, Z. Li. Semi-Supervised Dim and Small Infrared Ship Detection Network Based on Haar Wavelet. *Digital Object Identifier* 10.1109/ACCESS.2021.3058526
- [123] Zhao, M., Mammeri, A., & Boukerche, A. Distance measurement system for smart vehicles. In 2015 7th International Conference on New Technologies, Mobility and Security (NTMS) (pp. 1–5). IEEE.
- [124] Kumar, G. A., Lee, J. H., Hwang, J., Park, J., Youn, S. H., & Kwon, S. LiDAR and camera fusion approach for object distance estimation in self-driving vehicles. *Symmetry*, 12(2), 324.
- [125] Bradski G, Kaehler A (2008) Learning OpenCV: computer vision with the OpenCV library. O'Reilly Media, Sebastopol
- [126] B. Bhowmick, S. Bhadra, A. Sinharay. Stereo Vision Based Pedestrians Detection and Distance Measurement for Automotive Application. 2011 Second International Conference on Intelligent Systems, Modelling and Simulation.
- [127] Fisher R. B., Breckon T. P., Dawson-Howe K., Fitzgibbon A., Robertson C., Trucco E., Williams C. K., Dictionary of Computer Vision and Image Processing. (John Wiley & Sons, 2013).
- [128] R. Hartley, A. Zisserman. Multiple View Geometry in Computer Vision. Cambridge University Press 2000, 2003.
- [129] Mills, A. 2014. "Cultures of Assemblage, Resituating Urban Theory: A Response to the Papers on 'Assembling Istanbul'." *City* 18 (6): 691–697.

- [130] Convolutional neural network (CNN). Son erişim: 24 Ekim 2022, Erişim linki: <https://developersbreach.com/convolution-neural-network-deep-learning/>.
- [131] Faugeras, O., & Faugeras, O. A. (1993). Three-dimensional computer vision: a geometric viewpoint. MIT press.
- [132] Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., ... & Ghayvat, H. (2021). CNN variants for computer vision: history, architecture, application, challenges and future scope. *Electronics*, 10(20), 2470.
- [133] Alzubaidi, L. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* 8 (1), 1–74 (2021).
- [134] Özkan, İ. N. İ. K., & Ülker, E. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.



TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

1. A. Taşkın, T. Küstü, “Akıllı Şehirlerde Afet Yönetimi Kapsamında Derin Öğrenme Temelli Yangın Tespiti”, 5. *Uluslararası Akademik Araştırmalar Kongresi (ICAR)*, 19-21 Nisan 2021.

