

Termal Kamera Görüntülerinin Çoklu Sınıflandırılması İçin Derin Öğrenme Tabanlı Tekniklerin Performans Karşılaştırılması

Performance Comparison of Deep Learning Based Techniques for Multiclass Classification of Thermal Camera Images

Merve Kesim Önal ^{1*}, Halil Uslu ², Engin Avcı ², Derya Avcı ²

¹ Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Malatya, Türkiye

² Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye

Öz

Termal kameralar, cisimlerin sıcaklık farklılıklarını kızılötesi ışın değerlerine bağlı olarak renklendirdiği görüntüleme sistemleridir. Günümüzde başta savunma sanayi olmak üzere sağlık, ziraat, inşaat gibi birçok farklı alanda termal kameralar kullanılmaktadır. Özellikle savunma sanayi alanında kullanılan bu kameralardan elde edilen görüntüler, çeşitli nesnelerin ve canlıların tespiti için büyük önem arz etmektedir. Bu çalışmada termal kamera görüntülerinin sınıflandırması için derin öğrenme tabanlı tekniklerin kapsamlı bir karşılaştırması sunulmaktadır. Çalışmada 7 farklı Evrişimli Sinir Ağları mimarisi ile görüntülerin özellikleri çıkarılmış, 5 farklı sınıflandırma yöntemi ile sınıflandırılması sağlanmıştır. Performans değerlendirmesi için dengesiz çok sınıflı veri kümelerinin sınıflandırılmasına uygun metrikler olan dengeli doğruluk, makro ve mikro ortalama duyarlılık, makro ve mikro ortalama kesinlik, makro ve mikro ortalama F ölçütü metrik değerleri kullanılmıştır. Ayrıca tüm yapıların ayrı ayrı eğitim ve test süreleri karşılaştırılmıştır. Çalışmada en yüksek doğruluk değeri %95.24 ile Resnet101+Softmax ve Resnet50+DVM mimarilerinde elde edilmiştir. Sınıfların eşit ağırlıklı alındığı dengeli doğruluk değerinde ise en yüksek %95,17 ile Resnet101+Softmax mimarisinden elde edilmiştir. Resnet101+Softmax mimarisinde makro ortalama kesinlik 0.9579, makro ortalama F ölçütü 0.9543 ve mikro ortalama F ölçütü 0.9524 değerleri elde edilmiştir. Bu çalışma, küçük ve dengesiz termal görüntüler üzerinde, önceden eğitilmiş ESA ağlarının özellik çıkarımı ile makine öğrenimi sınıflandırıcılarının kullanımının, tamamen eğitilmiş ağlarla elde edilen performansa benzer sonuçlar sağlanabileceğini göstermiştir.

Anahtar Kelimeler: Termal Görüntü, Derin Öğrenme, Çok Sınıflı Sınıflandırma

Abstract

Thermal camera systems are imaging systems that color the temperature differences of objects depending on their infrared ray values. Nowadays, thermal cameras are used in many different areas such as defense industry, health, agriculture and construction. Detection of various objects and living creatures in the images taken by these cameras, which are used especially in the field of defense industry, is of great importance. This study presents a comprehensive comparison of deep learning-based techniques for classification of thermal camera images. In the study, the features of the images were extracted with 7 different Convolutional Neural Network architectures and they were classified with 5 different classifiers. For performance evaluation, balanced accuracy, macro and micro average sensitivity, macro and micro average precision, macro and micro average F criterion metric values, which are metrics suitable for classification of unbalanced multi-class data sets, were used. Additionally, the training and testing times of all structures separately were compared. In the study, the highest accuracy value of 95.24% was achieved with ResNet101+Softmax and ResNet50+DVM architectures. The highest balanced accuracy, where class weights were equally considered, was obtained as 95.17% with the ResNet101+Softmax architecture. The ResNet101+Softmax model yielded a macro-averaged precision of 0.9579, a macro-averaged F-measure of 0.9543, and a micro-averaged F-measure of 0.9524. This study demonstrates that, on small and imbalanced thermal images, the utilization of pre-trained ESA networks for feature extraction combined with machine learning classifiers can deliver performance comparable to that achieved with fully trained deep learning models

Keywords: Thermal Image, Deep Learning, Multi-Class Classification

* Sorumlu yazar e-posta (Corresponding e-mail): merve.kesim@ozal.edu.tr

Geliş Tarihi (Received): 25.07.2024, Kabul Tarihi (Accepted): 08.03.2025

1. Giriş

Günümüzde birçok görüntü alma sistemi bulunmaktadır. Bunlara; enerji yüklü röntgen ışınlarının farklı yapılardan dönmesiyle görüntü alan röntgen cihazları, ses dalgaları aracılığıyla görüntü oluşturabilen ultrason cihazları, elektromanyetik kuvvet radyo frekansları ile görüntü elde eden MR cihazları, radar kullanarak yer altındaki değerli maden, su kaynağı, yeraltı boşlukları gibi verileri 2 veya 3 boyutlu görüntüleyebilen çeşitli dedektörler, kızılötesi ışınlar ile ısıya bağlı görüntüleme yapabilen termal görüntüleme sistemleri örnek olarak verilebilir. Termal görüntüleme sistemleri, elektromanyetik spektrumda yer alan IR (kızılötesi) enerjiyi esas almaktadır. Termal kameralar ilk olarak güvenlik amaçlı, savunma alanında kullanılmaya başlanmış zamanla sağlık, ziraat, inşaat gibi birçok farklı alanda kullanılmıştır. Özellikle savunma sanayi alanında kullanılan hava araçları için termal kameralar spesifik bir öneme sahiptir. Termal kameralardan elde edilen görüntüler ile ateşleme sistemlerinin geliştirilmesi, otonom kullanım, karakol ve sınır güvenliğinin sağlanması, boru hatları ve pompa istasyonlarının güvenliğinin sağlanması gibi uygulamalar yapılmaktadır. Bu uygulamaların birçoğu görüntülerdeki canlı-cansız nesnelerin tespiti ile gerçekleştirilmektedir [1]. Termal görüntülerdeki nesne sınıflandırmasının insan gözüyle yapılması hem çok fazla insan gücü gerektirmekte hem de hata payını arttırmaktadır. Bu nedenle termal kamera sistemlerinden elde edilen görüntüler üzerinde makine öğrenmesi ve derin öğrenme gibi yapay zekâ teknikleri kullanılmaktadır. Bu çalışmada derin öğrenme tabanlı tekniklere çeşitli sınıflandırma algoritmaları dahil edilerek termal kamera görüntü sınıflandırmasının yapılması amaçlanmıştır.

Sınıflandırma algoritmalarının performansını değerlendirmenin çeşitli yolları bulunmaktadır. Performans ölçümü, doğruluk, duyarlılık ve özgüllük gibi farklı metriklerle yapılmaktadır. İki sınıflı sınıflandırma problemlerinde bu ölçümler, sınıflandırıcılar arasında karşılaştırma yapmayı kolaylaştırır da çok sınıflı sınıflandırma problemlerinde değerlendirme süreci daha karmaşık bir hale gelmektedir. Özellikle, dengesiz veri dağılımlarında bazı sınıfların yeterince temsil edilmemesi, belirli sınıfların performanslarının göz ardı edilmesine yol açabilmektedir. Bu durum, modelin gerçek dünya uygulamalarında etkili bir şekilde kullanılabilirliğini sınırlandırabilir. Dolayısıyla, çok sınıflı sınıflandırma problemlerinde kullanılan öğrenme algoritmalarının performanslarının kapsamlı bir şekilde değerlendirilmesi, analiz edilmesi ve elde edilen sonuçların doğru yorumlanması büyük önem taşımaktadır. Bu yaklaşımlar, sınıflandırma modellerinin adil ve dengeli bir şekilde geliştirilmesi için kritik bir ihtiyaçtır.

Bu çalışmada, termal kamera görüntüleri üzerinde temel ESA mimarilerinin ağırlıklarının güncellenmesi yoluyla gerçekleştirilen eğitim süreci ile önceden eğitilmiş ESA ağlarından özellik çıkarımı yapılarak makine öğrenimi sınıflandırıcılarının performansları karşılaştırılmıştır. Ayrıca, çok sınıflı sınıflandırmalarda kullanılan değerlendirme ölçütlerine yönelik ayrıntılı bir uygulama örneği sunulmuştur.

Literatürde araştırmacılar farklı alanlarda kullanılan termal görüntülerdeki nesnelerin tespiti için bazı yöntemler önermişlerdir. Youngjun Cho vd. [2] yaptıkları çalışmada, İnsanların her yerde bulunan teknolojileri kullanarak malzemelerin yakın mesafeden otomatik olarak tanınmasına yönelik yeni bir yaklaşım olan Derin Termal Görüntülemeyi önermişlerdir. Önerdikleri yöntem, bir akıllı telefona entegre edilmiş düşük maliyetli mobil termal kamera ile elde edilen termal doku görüntülerini derin bir sinir ağı kullanarak malzeme türlerine göre sınıflandırır. Sistemin performansı hem iç hem de dış ortamlarda 32 malzeme türünü tanıyacak şekilde eğitilerek değerlendirilmiştir. Çalışma sonucunda 15 iç mekân malzemesinin 98%'in üzerinde doğruluk ve 17 dış mekân malzemesinin de 89%'un üzerinde doğruluk ile sınıflandırması yapılmıştır. Furat Al-Obaidy vd. [3] yaptıkları çalışmada, bir Baskılı Devre Kartı (PCB) modelinin Tümüleşik Devre (IC) arıza algılaması için termal görüntü işleme kullanmışlardır. Çalışmada görüntü sınıflandırma ve algılama için çok katmanlı algılayıcı, destek vektör makinesi ve uyarlanabilir nöron-bulanık çıkarım sistemi olmak üzere üç yumuşak hesaplama tekniği kullanılmıştır. Modellerin etkinliği, sınıflandırmanın performansı ve doğruluğu karşılaştırılmıştır. Benzer bir çalışma da Akshay A.

Sarawade ve Nadir N. Charniya [4] tarafından gerçekleştirilmiştir. Çalışmada PCB'deki hatalı IC'lerin tespit edilmesi amacıyla Hızlandırılmış Sağlam Özellikler (SURF) algoritması kullanılarak görüntü eşleştirme gerçekleştirilmiştir. Jiang A. vd. [5] termal görüntüler aracılığıyla ağaç gövdesi tespiti için çeşitli derin öğrenme modellerini incelemiş ve farklı mimarilerin doğruluk ve hız performansları hakkında önemli bulgular sunmuştur. Bu tür karşılaştırmalı analizler, termal görüntüleme uygulamaları için en uygun modellerin belirlenmesinde önemli bir rol oynamaktadır. Memari M. vd. [6] tarafından yürütülen çalışmada termal ve RGB görüntüleme yöntemleri kullanılarak rüzgar türbini kanatlarının denetiminde %100 doğruluk oranına ulaşan bir topluluk modeli sunarak, daha yüksek performans elde etmek amacıyla farklı derin öğrenme tekniklerinin entegrasyonunun potansiyelini vurgulamışlardır.

Termal görüntü işleme yöntemleri ile ilgili sağlık alanında da farklı bir çok çalışma mevcuttur. R. Roslidar vd. [7] yaptıkları derleme çalışmasında, memedeki sıcaklık dağılımını gözlemleyerek Non-invaziv ve temassız bir kanser tarama yöntemi olan termografiden elde edilen görüntüler üzerinde uygulanmış derin öğrenme modellerinin incelemesini gerçekleştirmişlerdir. Çalışma, meme termogramı sınıflandırması için derin sinir ağlarının uygulanmasıyla ilgili çoğu araştırmayı ele almıştır. Yapılan incelemelerde sık katmanlara ve az parametreye sahip derin ağların, yüksek doğruluğu korurken simülasyon süresini azaltma yetenekleri sayesinde iyi performans gösterdiği saptanmıştır. Çalışma sonucunda mevcut sinir ağı modellerinin, özellikle sağlıklı ve kanserli vakaları ayırt etmede, meme kanseri termogram sınıflandırmasının doğruluğunda bir artışa yol açtığını göstermiştir. Termal görüntüler çeşitli yöntemler uygulanarak yüz tanıma için kullanılmıştır [8], [9]. G. Koukiou ve V. Anastassopoulos [10] yaptıkları çalışmada alkol almış kişilerin tanınması için termal görüntüler üzerinde derin öğrenme tekniklerini kullanmıştır.

Savunma alanında da termal görüntüler sıklıkla kullanılmıştır[11], [12]. Mayın tespit sistemleri için de termal görüntü tabanlı çeşitli yöntemler mevcuttur[13], [14].C.N. Naga Priya vd. [15] termal görüntülerdeki gömülü nesneleri tanımlamak için derin öğrenme bölgesi konvolüsyonuna dayalı sinir ağı yaklaşımını önermişlerdir. Çalışmada kapsamında gerçekleştirilen deneysel sonuçlardan, toprağın ısı taşıma kapasitesindeki değişime bağlı olarak gömülü nesnelerin termal görüntülerinde sıcaklık değişimi olduğu bulunmuştur. Bu değişimin tespiti için önerilen sinir ağı yöntemi ile termal görüntülerindeki gömülü nesnelerin konumları 90% doğruluk değeriyle tespit edilmiştir. Savunma alanında kullanılan termal görüntüleme yöntemlerden biri de otomatik hedef tespiti sistemleridir. A. d'Acremont vd. [16] otomatik hedef tespiti için cfCNN olarak adlandırılan, küresel ortalama havuzlama (GAP) ile kompakt ve evrişimli bir sinir ağı önermişlerdir.


Literatürde ayrıca bazı ESA mimarilerinin doğruluk, çıkarım zamanı, hafıza gibi faktörler yönünden karşılaştırmaları Canziani A. vd.[17] tarafından gerçekleştirilmiştir. Çalışmada, ImageNet yarışmasında sunulan Alexnet [18], Network in Network (NIN) [19], Enet [20], Googlenet [21], VGG-16 ve -19 [22], Resnet-18, -34, -50, -101 ve -152 [23], Inception-v3 [24] ve Inception-v4 [25] mimarileri karşılaştırılmıştır. Çalışmaya göre doğruluk açısından Resnet ve Inception mimarileri, diğer tüm mimarileri en az 7% gibi önemli bir farkla geride bırakmıştır.

Bu çalışmada, savunma sanayinde sıklıkla kullanılan termal kamera görüntülerindeki nesnelerin sınıflandırmasının hızlı ve doğru yapılabilmesi için derin öğrenme tabanlı teknikler önerilmiştir. Çalışmada kullanılan veri setine ait bilgiler 2. bölümde, uygulanan yöntem 3. bölümde, deneysel sonuçlar ile ilgili bilgiler ise 4. bölümde verilmiştir.

2. Materyal ve Metod


Çalışmada toplamda 4 kategoriden oluşan 836 termal görüntü kullanılmıştır. Veriler açık erişimi olan Kaggle platformunda bulunan "visible_thermal"[26], "HIT-UAV: A High-altitude Infrared Thermal Dataset"[27] ve "Thermal Mannequin Fall Image Dataset"[28] veri setlerinde bulunan görüntülerden 4 sınıf oluşturacak şekilde alınarak elde edilmiştir. Veri setinde içerisinde araba bulunan 198 termal kamera

görüntüsü, içerisinde ev bulunan 100 termal kamera görüntüsü, içerisinde çeşitli hayvanların bulunduğu 204 termal kamera görüntüsü, içerisinde 334 insan bulunan termal kamera görüntüsü bulunmaktadır. Şekil 1’de çalışmada kullanılan veri setindeki her bir sınıfın örnek görüntüleri verilmiştir.



Şekil 1. Veri setindeki kategorilere ait termal kamera görüntüleri örnekleri: (a) Araba içeren termal kamera görüntüleri (b) Ev içeren termal kamera görüntüleri (c) Hayvan içeren termal kamera görüntüleri (d) İnsan içeren termal kamera görüntüleri

Çalışmanın temel amacı, termal kamera görüntülerini insan, hayvan, ev ve araç olacak şekilde 4 sınıfta sınıflandırmanın hızlı ve yüksek doğrulukla yapılabilmesi için çeşitli derin öğrenme ve makine öğrenmesi tekniklerinin karşılaştırmalı olarak değerlendirilmesidir. Süreç dört aşamadan oluşmaktadır. İlk adımda veri setindeki tüm termal görüntülerin girişi yapılmıştır. İkinci adımda, literatürde yaygın olarak kullanılan evrişimli sinir ağı (ESA) mimarilerinde özellik çıkarma işlemi gerçekleştirilmiştir. Bu aşamada kullanılan tüm ESA mimarilerinin genel yapısı (konvolüsyon ve havuzlama katmanları) korunmuştur. Çıkarılan özellikler, holdout yöntemi ile %70 eğitim ve %30 test verisi olarak ayrılmıştır. Üçüncü adımda, iki farklı sınıflandırma yöntemi uygulanmıştır. İlk yöntemde, ESA mimarilerinin ağırlıkları güncellenerek Softmax sınıflandırıcı ile bir öğrenme süreci gerçekleştirilmiştir. İkinci yöntemde ise ESA mimarilerinin tam bağlantı katmanlarından çıkarılan öznitelikler, Destek Vektör Makineleri (DVM) [29], K En Yakın Komşuluk (KNN) [30], Navie Bayes [31] ve Diskriminant Analizi [32] gibi yaygın makine öğrenmesi sınıflandırma algoritmaları ile sınıflandırılmıştır. Son olarak, dördüncü adımda, test verileri üzerinde doğrulama işlemi gerçekleştirilmiş ve tüm sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Kullanılan ESA mimarilerinin genel yapısı Şekil 2’de verilmiştir.



Şekil 2. Kullanılan yöntemlerin genel yapısı

2.1. Kullanılan Sinir Ağları Mimarileri

Çalışma kapsamında literatürde en sık kullanılan Evrişimsel Sinir Ağları mimarilerinden AlexNet, GoogLeNet, ResNet-18,-50,-101, Inceptionv3, Densenet201 [33] kullanılmıştır. Bu mimariler MATLAB'da M-file kodları aracılığıyla doğrudan yapılandırılmıştır. Çalışmada, termal kamera görüntüleri üzerinde iki farklı yöntem uygulanmıştır. İlk yöntemde, her bir ESA mimarisi, ImageNet veri seti üzerinde önceden eğitilmiş ağırlıklarla kullanılmış ve bu modellerin tam bağlantı katmanları, son özellik çıkarımı katmanı olarak değerlendirilmiştir. Bu özellikler, Destek Vektör Makineleri (SVM), K-En Yakın Komşuluk (KNN), Naive Bayes ve Diskriminant Analizi gibi farklı makine öğrenimi sınıflandırıcıları ile sınıflandırılmıştır. İkinci yöntemde ise ESA mimarilerinin ağırlıkları güncellenerek, Softmax sınıflandırıcı ile tam bir eğitim süreci gerçekleştirilmiş ve kullanılan tüm mimari yapıların performansları karşılaştırılmıştır. Kullanılan ESA mimarileri hakkında genel bilgiler Çizelge 1'de verilmiştir.

Çizelge 1. Kullanılan ESA Mimarilerine Genel Bakış

Mimari	Yıl	Derinlik	Parametre Sayısı	Görüntü Giriş Boyutu	Toplam Katman Sayısı	Öznitelik Elde Katmanı
Alexnet	2012	8	61 M	227*227	25	fc8
Googlenet	2014	22	7 M	224*224	144	loss3-classifier
Resnet18	2015	18	11,7 M	224*224	71	fc1000
Resnet50	2015	50	25,6 M	224*224	177	fc1000
Resnet101	2015	101	44,6 M	224*224	347	fc1000
Inceptionv3	2015	48	23,9 M	299*299	315	predictions
Densenet201	2017	201	20 M	224*224	708	fc1000

2.2. Performans Değerlendirme Metrikleri

Bir makine öğrenimi algoritmasında kurulan modeli değerlendirmek için, performansın nicel ölçütleri bulunmaktadır. Birçok yaygın sınıflandırma metriğini hesaplanması karmaşıklık matrisi kullanılır. Hedef

değişkenlerinin sınıflarına ait gerçek ve tahmin edilen değerlerinin gösterildiği matrise karmaşıklık matrisi adı verilir. Sadece iki sınıfın olduğu ikili sınıflandırma ve sınıf sayısının ikiden fazla olduğu çok sınıflı sınıflandırma için kullanılan karmaşıklık matrisleri Çizelge 2 ve Çizelge 3'te verilmiştir [34].

Çizelge 2. İki Sınıflı Karmaşıklık Matrisi.

		Tahmin		
		Pozitif	Negatif	Toplam
Gerçek	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)	DP+YN
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)	YP+DN
	Toplam	DP+YP	YP+DN	m

İki sınıflı sınıflandırma problemlerinde sınıflandırıcılarının performansını karşılaştırmak için Doğruluk (Accuracy, Acc), Duyarlılık (Recall, R), Kesinlik (Precision, P) ve F Ölçütü (F1-Score) gibi ölçütler hesaplanmaktadır. Bu metriklerin Çizelge 2'ye göre hesaplanan matematiksel ifadeleri Eşitlik 1-4' de verilmiştir [35], [36].

$$Acc = \frac{DP+DN}{DP+YP+YN+DN} \quad (1)$$

$$R = \frac{DP}{DP + YN} \quad (2)$$

$$P = \frac{DP}{DP+YP} \quad (3)$$

$$F1 = \frac{2 \cdot P \cdot R}{P+R} \quad (4)$$

Çok sınıflı sınıflandırma problemlerinde (özellikle sınıflar eşit dağılmadığında) değerlendirme metrikleri için tüm sınıfları eşit temsil edecek ölçümlere ihtiyaç duyulmaktadır. Dengeli Doğruluk hem ikili hem de çok sınıflı sınıflandırma için iyi bilinen bir ölçüdür. Dengeli Doğruluk, her sınıfın duyarlılığının aritmetik ortalamasından oluşmaktadır. Bu her sınıfın aynı ağırlığa ve aynı öneme sahip olmasını sağlar. Böylelikle daha az birimi olan küçük sınıfların sonuç üzerinde orantısız etkiden daha fazla etki etmesi sağlanır[35]. Dengeli doğruluk değerinin yanı sıra çok sınıflı sınıflandırma söz konusu olduğunda, özellikle F ölçütü tüm sınıfları içermelidir. Bu bağlamda çok sınıflı F ölçütünün hesabı için iki tür ölçüm vardır: Makro Ortalamalı F Ölçütü ve Mikro Ortalamalı F Ölçütü. Makro ortalama F ölçütü, sınıflar üzerinden F ölçütlerinin ortalamasını hesaplar. Mikro ortalama F ölçütü ise sınıflar arasında örnek başına düşen sınıflandırmaları bir araya toplar ve genel F ölçütünü hesaplar.

Makro ortalama, her sınıfa eşit ağırlık verirken, mikro ortalama, birim başına her bir sınıflandırma kararına eşit ağırlık verir [35], [37]. Çok sınıflı bir sınıflandırma problemi için ihtiyaç duyulan karışıklık matrisi Çizelge 3'te verilmiştir.

Çizelge 3. Çok sınıflı karmaşıklık matrisi.

		Tahmin				
		Sınıf ₁	Sınıf ₂	...	Sınıf _n	Toplam
Gerçek	Sınıf ₁	DP ₁	H ₁₂	...	H _{1n}	T _{satır₁}
	Sınıf ₂	H ₂₁	DP ₂	...	H _{2n}	T _{satır₂}
	...	...	...	...	...	...
	Sınıf _n	H _{n1}	H _{n2}	...	DP _n	T _{satır_n}
	Toplam	T _{sütun₁}	T _{sütun₂}	...	T _{sütun_n}	m

Çok sınıflı sınıflandırma problemlerinde (özellikle sınıflar eşit dağılmadığında) değerlendirme metrikleri için tüm sınıfları eşit temsil edecek ölçümlere ihtiyaç duyulmaktadır. Dengeli Doğruluk hem ikili hem de çok sınıflı sınıflandırmada iyi bilinen bir ölçüdür. Dengeli Doğruluk, her sınıfın duyarlılığının aritmetik ortalamasından oluşmaktadır. Bu her sınıfın aynı ağırlığa ve aynı öneme sahip olmasını sağlar. Böylelikle daha az birimi olan küçük sınıfların sonuç üzerinde orantısız etkiden daha fazla etki etmesi sağlanır.

Dengeli doğruluk değerinin yanı sıra çok sınıflı sınıflandırma söz konusu olduğunda, özellikle F ölçütü tüm sınıfları içermelidir. Bu bağlamda çok sınıflı F ölçütünün hesabı için iki tür ölçüm vardır: Makro Ortalamalı F Ölçütü ve Mikro Ortalamalı F Ölçütü. Makro ortalama F ölçütü, sınıflar üzerinden F ölçütlerinin ortalamasını hesaplar. Mikro ortalama F ölçütü ise sınıflar arasında örnek başına düşen sınıflandırmaları bir araya toplar ve genel F ölçütünü hesaplar. Makro ortalama, her sınıfa eşit ağırlık verirken, mikro ortalama, birim başına her bir sınıflandırma kararına eşit ağırlık verir [35], [37].

Çok sınıflı sınıflandırma problemlerinde Çizelge 3 yardımıyla hesaplanan değerlendirme metrikleri Dengeli Doğruluk ($Acc_{balanced}$), Makro Ortalamalı Duyarlılık (R_{Macro}), Makro Ortalamalı Kesinlik (P_{Macro}), Makro Ortalamalı F Ölçütü ($F1_{Macro}$), Mikro Ortalamalı Duyarlılık (R_{Micro}), Mikro Ortalamalı Kesinlik (P_{Micro}), Mikro Ortalamalı F Ölçütü ($F1_{Micro}$), Eşitlik 5-11’de verilmiştir. Eşitliklerde verilen K değeri sınıf sayısını temsil etmektedir.

$$Acc_{balanced} = \frac{\sum_{k=1}^K \frac{DP_k}{T_{satır_k}}}{K} \quad (5)$$

$$R_{Macro} = \frac{\sum_{k=1}^K Rec_k}{K} \quad (6)$$

$$P_{Macro} = \frac{\sum_{k=1}^K Pre_k}{K} \quad (7)$$

$$F1_{Macro} = 2 * \left(\frac{\text{Makro Avg Pre} * \text{Makro Avg Rec}}{\text{Makro Avg Pre} + \text{Makro Avg Rec}} \right) \quad (8)$$

$$R_{Micro} = \frac{\sum_{k=1}^K DP_k}{\sum_{k=1}^K T_{satır_k}} \quad (9)$$

$$P_{Micro} = \frac{\sum_{k=1}^K DP_k}{\sum_{k=1}^K T_{sütun_k}} \quad (10)$$

$$F1_{Micro} = \frac{\sum_{k=1}^K DP_k}{m} \quad (11)$$

Eşitlik 1 ve Eşitlik 9-11’den de görüleceği üzere doğruluk, Mikro Ortalamalı Duyarlılık ve Mikro Ortalamalı Kesinlik ölçümleri birbirine eşittir. Buradan yola çıkarak Mikro Ortalamalı Duyarlılık ve Mikro Ortalamalı Kesinlik ölçülerinin harmonik ortalaması olan Mikro Ortalama F ölçütü de Doğruluk formülüne eşit çıkmaktadır [35]. Aynı şekilde Dengeli doğruluk ile Makro Ortalamalı Duyarlılık ölçümleri de birbirine eşittir. Bu nedenle bu çalışmada Makro ve Mikro ölçümler arasından yalnızca makro ortalama Kesinlik ve F ölçütü sonuçları verilmiştir.

3. Araştırma Bulguları

Çalışmada termal görüntülerde nesne tespitinde özellik çıkarımı için en başarılı ESA mimarisinin hangisi olduğu ve sık kullanılan çeşitli ESA mimarileri ile çeşitli sınıflandırıcılar arasında en iyi kombinasyonun hangisi olduğunun tespiti için karşılaştırmalar yapılmıştır. Deney sonuçları Çizelge 4’te verilmiştir.


Yapılan tüm çalışmalar, 12. Nesil Intel Core i7 3.50 GHz işlemci, 16GB DDR4 RAM ve 8GB NVIDIA GeForce RTX 3070 ekran kartına sahip bilgisayarda gerçekleştirilmiştir. Tüm çalışmalar, 64 bitlik Windows 11 işletim sistemi üzerinde kurulu Matlab R2021a üzerinde derlenmiştir. Özellik çıkarımı sırasında batch size 32 olarak tüm makine öğrenmesi yöntemleri kullanan mimariler için aynı kullanılmış özellikler satır halinde sınıflandırıcılara verilmiştir. Softmax kullanılan mimarilerde ise 0.001 başlangıç öğrenme oranı, sgdm optimizasyonu, 20 epoch, 32 batch size parametreleri kullanılmıştır.

Çizelge 4. Kullanılan mimari ve sınıflandırıcıların sınıflandırma sonuçları.


Mimari	Sınıflandırıcı	Doğruluk (%)	Dengeli Doğruluk (%)	P_{Macro}	$F1_{Macro}$	$F1_{Micro}$	Toplam Eğitim ve Test Süresi (sn)
Alexnet	Softmax	92,06%	91,33%	0,9144	0,9128	0,9206	61,37
	DVM	89,68%	89,75%	0,8945	0,8950	0,8968	2,23
	KNN	86,51%	82,25%	0,8722	0,8391	0,8651	2,03
	Navie Bayes	84,13%	84,69%	0,8287	0,8355	0,8413	3,15
	Diskr. Analizi	92,86%	92,33%	0,9404	0,9285	0,9286	3,18
ResNet18	Softmax	93,65%	92,33%	0,9494	0,9340	0,9365	61,13
	DVM	90,48%	90,97%	0,8967	0,9021	0,9048	4,28
	KNN	89,68%	87,44%	0,8973	0,8846	0,8968	4,04
	Navie Bayes	86,51%	88,44%	0,8668	0,8734	0,8651	4,43
	Diskr. Analizi	89,68%	89,11%	0,8858	0,8846	0,8968	3,33
ResNet50	Softmax	94,44%	92,00%	0,9422	0,9294	0,9444	213,96
	DVM	95,24%	94,86%	0,9651	0,9562	0,9524	7,13
	KNN	89,68%	90,97%	0,9036	0,9050	0,8968	6,79
	Navie Bayes	86,51%	88,72%	0,8724	0,8754	0,8651	6,52
	Diskr. Analizi	93,65%	93,53%	0,9319	0,9332	0,9365	4,00
ResNet101	Softmax	95,24%	95,17%	0,9579	0,9543	0,9524	235,35
	DVM	91,27%	91,39%	0,9102	0,9115	0,9127	4,57
	KNN	86,51%	84,16%	0,8602	0,8477	0,8651	4,35
	Navie Bayes	80,95%	80,08%	0,8287	0,8131	0,8095	5,82
	Diskr. Analizi	93,65%	94,36%	0,9374	0,9394	0,9365	5,57
Inceptionv3	Softmax	92,06%	91,58%	0,9338	0,9260	0,9206	390,51
	DVM	89,68%	89,75%	0,9070	0,9008	0,8968	10,07
	KNN	88,89%	86,55%	0,8842	0,8731	0,8889	4,39
	Navie Bayes	88,10%	89,03%	0,8908	0,8858	0,8810	6,27
	Diskr. Analizi	88,89%	86,77%	0,8979	0,8794	0,8889	5,21
Googlenet	Softmax	92,86%	92,72%	0,9397	0,9330	0,9286	202,98
	DVM	92,06%	93,11%	0,9375	0,9341	0,9206	3,29
	KNN	87,30%	83,97%	0,8937	0,8574	0,8730	3,10
	Navie Bayes	84,13%	84,80%	0,8396	0,8429	0,8413	6,59
	Diskr. Analizi	91,27%	89,05%	0,9444	0,9126	0,9127	9,03
DenseNet201	Softmax	90,48%	89,05%	0,9235	0,9044	0,9048	1,53*103
	DVM	92,86%	92,75%	0,9395	0,9331	0,9286	11,62
	KNN	91,27%	91,58%	0,9201	0,9145	0,9127	11,73
	Navie Bayes	82,54%	83,58%	0,8303	0,8280	0,8254	11,71
	Diskr. Analizi	93,65%	92,39%	0,9514	0,9362	0,9365	18,29

Her bir ESA mimarisine entegre edilen beş sınıflandırıcının sınıflandırma sonuçları Çizelge 4'te karşılaştırılmıştır. Tüm sınıflandırıcıların doğruluk değerleri karşılaştırıldığında Resnet101+Softmax ve Resnet50+DVM mimarileri 95,24% doğruluk değeri ile elde edilen tüm sınıflandırmalardan daha yüksek bir başarımla elde etmişlerdir. Sınıfları eşit ağırlıklı olarak alan dengeli doğruluk değerine göre 95,17% ile en yüksek başarımla olan mimari Resnet101+Softmax mimarisidir. Doğruluk değerinde yüksek başarımla olan Resnet101+Softmax mimarisinin makro ortalama kesinlik değeri 0,9579 ile en yüksek kesinlik değerleri arasındadır. Bunun yanında yine Resnet50+DVM ve Resnet101+Softmax mimarileri için sınıfların eşit temsil edildiği Makro ortalama F ölçütü sırasıyla 0,9562 ve 0,9543 değerleri ile diğer sınıflandırmalara göre daha yüksek bulunmuştur. Bu da modellerin hem doğru pozitif değerlerini hem de doğru negatif değerlerini iyi tahmin ettiğini göstermektedir. Çizelgede verilen toplam eğitim ve test süresi, eğitim verilerinin özellik çıkarımı ve sınıflandırması aşamalarında geçen toplam süreyi ifade etmektedir. Buna göre Alexnet mimarisinde katmanların daha az olması nedeni ile bu mimari ile yapılan sınıflandırmalar diğerlerine göre çok daha kısa sürede gerçekleşmiştir.

En yüksek doğruluk ve dengeli doğruluk değeri bulunan Resnet101+Softmax ve Resnet50+DVM yöntemlerindeki sınıflandırma sonuçlarının karmaşıklık matrisleri Şekil 3'te verilmiştir.



a) Resnet101+Softmax yönteminin karmaşıklık matrisi



b) Resnet50+DVM yönteminin karmaşıklık matrisi

Şekil 3. Resnet101+Softmax ve Resnet50+DVM yöntemlerinin karmaşıklık matrisleri

Çizelge 5. Sınıflandırıcıların ortalama başarımları sonuçları.

	Ortalama Doğruluk (%)	Ortalama Dengeli Doğruluk (%)	Ortalama Eğitim ve Test Süresi (sn)
Softmax	92,97%	92,03%	385,04
DVM	91,61%	91,80%	6,17
KNN	88,55%	86,70%	5,20
Navie Bayes	84,70%	85,62%	6,36
Diskr. Analizi	91,95%	91,08%	6,94

Temel ESA mimarilerinde Softmax sınıflandırıcısının diğer sınıflandırıcılara göre yüksek doğruluklara sahip olduğu gözlenmiştir. Fakat aynı zamanda diğer sınıflandırıcılara göre eğitim ve test aşamasını daha fazla sürede gerçekleştirmiştir. Çizelge 5’de tüm sınıflandırıcıların ortalama başarımları sonuçları verilmiştir. Tüm mimarilerde kullanılan Softmax sınıflandırıcılarının ortalama dengeli doğruluk değeri 92,03%’dir. Bu sonuca en yakın ortalama dengeli doğruluk değerleri 91,80% ile Destek Vektör Makineleri ve 91,08% ile Diskriminant Analizi sonucunda elde edilmiştir. DVM, KNN Navie Bayes ve Diskriminant Analizi sınıflandırıcılarının eğitim ve test süresi süreleri birbirlerine çok yakın olduğu gözlenmiş iken Softmax sınıflandırma ile eğitim ve test süresinin diğer sınıflandırma yöntemlerine göre çok daha fazla olduğu (385 sn) gözlenmiştir.

Çizelge 6. ESA mimarilerinin ortalama başarımları sonuçları.

	Ortalama Doğruluk (%)	Ortalama Dengeli Doğruluk (%)	Ortalama Eğitim ve Test Süresi (sn)
Alexnet	89,05%	88,07%	14,39
ResNet18	90,00%	89,66%	15,44
ResNet50	91,90%	92,02%	47,68
ResNet101	89,52%	89,03%	51,13
Inceptionv3	89,52%	88,74%	83,29
Googlenet	89,52%	88,73%	45,00
DenseNet201	90,16%	89,87%	316,67

Çizelge 6’da tüm mimarilerin ortalama başarımları sonuçları verilmiştir. Genel olarak tüm sınıflandırıcılar ile sınıflandırma başarımına bakıldığında en başarılı mimari 91,90% ortalama doğruluk ve 92,02% ortalama dengeli doğruluk değeri ile Resnet50 mimarisidir. Mimariler arasında en yavaş sonuca ulaşan mimari toplam katman sayısı ve derinlik bakımından en yüksek değerlere sahip Densenet201 mimarisidir.

4. Sonuçlar

Çalışmada farklı derin öğrenme modellerinin, termal görüntülerin çok sınıflı sınıflandırma performansları kıyaslanmıştır. Kullanılan veri seti ev, araba, insan ve hayvandan oluşan 4 sınıftan oluşmuştur. İlk olarak veri setindeki görüntülerin Alexnet, Googlenet, Resnet-18, Resnet-50, Resnet -101, Inceptionv3, Densenet201 mimarileri ile özellikleri çıkarılmıştır. Ardından Softmax, Destek Vektör Makineleri (DVM), K En Yakın Komşuluk (KNN), Navie Bayes ve Diskriminant Analizi yöntemleri ile sınıflandırma performansları ölçülmüştür. Performans ölçümleri çok sınıflı sınıflandırma performans metriklerine göre gerçekleştirilmiştir. Böylelikle ölçümlerde her sınıfa aynı ağırlığı verilmiş ve sınıf dağılımına duyarsızlık sağlanmıştır. Az veriye sahip yeterince temsil edilmeyen sınıfların da olası tahminlerde temsil edilmesi sağlanmıştır.

Deney sonuçları eşit ağırlıklı olmayan çok sınıflı termal verilerde ESA mimarilerinden Resnet50 mimarisinin daha başarılı olduğu sonucuna ulaşılmıştır. Mimarilerde Softmax kullanımının başarımları arttırdığı fakat eğitim ve test süresini diğer sınıflandırma yöntemlerine göre 60 kat daha fazla sürede

gerçekleştirdiği görülmüştür. Ayrıca sınıflardaki veriler dengesiz olsa da kurulan derin öğrenme modellerinin hem doğru pozitif değerlerini hem de doğru negatif değerlerinin iyi tahmin edildiği sonucuna ulaşılmıştır.

Bu çalışma ESA mimarilerinde ağırlıkların güncellenmesiyle Softmax sınıflandırması kullanılarak gerçekleştirilen eğitim süreçlerinin, işlem süresi ve hesaplama kaynakları açısından oldukça maliyetli olduğu belirlenmiştir. Buna karşılık, önceden eğitilmiş ESA ağlarından özellik çıkarımı yapılarak makine öğrenimi sınıflandırıcılarının kullanılması durumunda, özellikle ResNet-50 mimarisi ile tamamen eğitilmiş bir ağın doğruluğu ile aynı performans elde edildiği gözlemlenmiştir. Bu bulgu, küçük ve dengesiz verisetlerinde, önceden eğitilmiş ağların kullanımının zaman ve kaynak tasarrufu sağlayan etkili bir alternatif olduğunu ortaya koymaktadır.

Kaynaklar

- [1] Aslan S. Mühendislik uygulamalarında termal kamera kullanımı. Yüksek lisans tezi. Hatay: İskenderun Teknik Üniversitesi; 2016.
- [2] Cho Y, Bianchi-Berthouze N, Marquardt N, Julier SJ. Deep thermal imaging. In: Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems, New York, NY, USA; 2018. p. 1–13. doi: 10.1145/3173574.3173576.
- [3] Al-Obaidy F, Yazdani F, Mohammadi FA. Fault detection using thermal image based on soft computing methods: Comparative study. *Microelectronics Reliability* 2017;71:56–64. doi: 10.1016/j.microrel.2017.02.013.
- [4] Sarawade AA, Charniya NN. Detection of faulty integrated circuits in PCB with thermal image processing. In: 2019 International Conference on Nascent Technologies in Engineering (ICNTE), IEEE; 2019. p. 1–6. doi: 10.1109/ICNTE44896.2019.8946061.
- [5] Jiang A, Noguchi R, Ahamed T. Tree trunk recognition in orchard autonomous operations under different light conditions using a thermal camera and Faster R-CNN. *Sensors* 2022;22(5). doi: 10.3390/s22052065.
- [6] Memari M, Shekaramiz M, Masoum MAS, Seibi AC. Data fusion and ensemble learning for advanced anomaly detection using multi-spectral RGB and thermal imaging of small wind turbine blades. *Energies (Basel)* 2024;17(3). doi: 10.3390/en17030673.
- [7] Roslidar R, et al. A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection. *IEEE Access* 2020;8:116176–116194. doi: 10.1109/ACCESS.2020.3004056.
- [8] Bauer J, Mazurkiewicz J. Neural network and optical correlators for infrared imaging based face recognition. In: 5th International Conference on Intelligent Systems Design and Applications (ISDA'05), IEEE; 2005. p. 234–238. doi: 10.1109/ISDA.2005.70.
- [9] Yoshitomi Y, Miyawaki N, Tomita S, Kimura S. Facial expression recognition using thermal image processing and neural network. In: Proceedings 6th IEEE International Workshop on Robot and Human Communication (RO-MAN'97 SENDAI), IEEE; p. 380–385. doi: 10.1109/ROMAN.1997.647016.
- [10] Koukiou G, Anastassopoulos V. Drunk person identification using thermal infrared images. *International Journal of Electronic Security and Digital Forensics* 2012;4(4). doi: 10.1504/IJESDF.2012.049747.
- [11] Hou F, Zhang Y, Zhou Y, Zhang M, Lv B, Wu J. Review on infrared imaging technology. *Sustainability* 2022;14(18):11161. doi: 10.3390/su141811161.
- [12] Akula A, Ghosh R, Sardana HK, Predeep P, Thakur M, Varma MKR. Thermal imaging and its application in defence systems. In: AIP Conference Proceedings; 2011. p. 333–335. doi: 10.1063/1.3643540.
- [13] Kaya S, Leloglul UM. Buried and surface mine detection from thermal image time series. *IEEE J Sel Top Appl Earth Obs Remote Sens* 2017;10(10):4544–4552. doi: 10.1109/JSTARS.2016.2639037.

- [14] Thnh NT, Sahli H, Ho DN. Finite-difference methods and validity of a thermal model for landmine detection with soil property estimation. *IEEE Transactions on Geoscience and Remote Sensing* 2007;45(3):656–674. doi: 10.1109/TGRS.2006.888862.
- [15] Naga Priya CN, Ashok SD, Maji B, Kumaran KS. Deep learning based thermal image processing approach for detection of buried objects and mines. *Engineering Journal* 2021;25(3):61–67. doi: 10.4186/ej.2021.25.3.61.
- [16] d’Acremont A, Fablet R, Baussard A, Quin G. CNN-based target recognition and identification for infrared imaging in defense systems. *Sensors* 2019;19(9):2040. doi: 10.3390/s19092040.
- [17] Canziani A, Paszke A, Culurciello E. An analysis of deep neural network models for practical applications. May 2016.
- [18] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Commun ACM* 2017;60(6):84–90. doi: 10.1145/3065386.
- [19] Lin M, Chen Q, Yan S. Network in network. Dec. 2013.
- [20] Paszke A, Chaurasia A, Kim S, Culurciello E. ENet: A deep neural network architecture for real-time semantic segmentation. Jun. 2016.
- [21] Szegedy C, et al. Going deeper with convolutions. Sep. 2014.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. Sep. 2014.
- [23] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. Dec. 2015.
- [24] Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. Dec. 2015.
- [25] Szegedy C, Ioffe S, Vanhoucke V, Alemi A. Inception-v4, Inception-ResNet and the impact of residual connections on learning. Feb. 2016.
- [26] visible_thermal. Kaggle. Available from: <https://www.kaggle.com/datasets/nikhilrajput1112/visible-thermal>
- [27] HIT-UAV: A high-altitude infrared thermal dataset. Kaggle. Available from: <https://www.kaggle.com/datasets/pandrii000/hituav-a-highaltitude-infrared-thermal-dataset>
- [28] Thermal mannequin fall image dataset. Kaggle. Available from: <https://www.kaggle.com/datasets/ivannikolov/thermal-mannequin-fall-image-dataset>
- [29] Cortes C, Vapnik V. Support-vector networks. *Mach Learn* 1995;20(3). doi: 10.1023/A:1022627411411.
- [30] Cover TM, Hart PE. Nearest neighbor pattern classification. *IEEE Trans Inf Theory* 1967;13(1). doi: 10.1109/TIT.1967.1053964.
- [31] Clarke MRB, Duda RO, Hart PE. Pattern classification and scene analysis. *J R Stat Soc Ser A* 1974;137(3). doi: 10.2307/2344977.
- [32] Fisher RA. The use of multiple measurements in taxonomic problems. *Ann Eugen* 1936;7(2). doi: 10.1111/j.1469-1809.1936.tb02137.x.
- [33] Huang G, Liu Z, van der Maaten L, Weinberger KQ. Densely connected convolutional networks. Aug. 2016.
- [34] Tharwat A. Classification assessment methods. *Applied Computing and Informatics* 2021;17(1):168–192. doi: 10.1016/j.aci.2018.08.003.
- [35] Grandini M, Bagli E, Visani G. Metrics for multi-class classification: an overview. Aug. 2020.
- [36] Aslan E. LSTM-ESA hibrit modeli ile MR görüntülerinden beyin tümörünün sınıflandırılması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi* 2024;11(22):63–81. doi: 10.54365/adyumbd.1391157.
- [37] Takahashi K, Yamamoto K, Kuchiba A, Koyama T. Confidence interval for micro-averaged F1 and macro-averaged F1 scores. *Applied Intelligence* 2022;52(5):4961–4972. doi: 10.1007/s10489-021-02635-5.