



Termal Görüntülerde Bulanıklık Türlerinin Sınıflandırılması: Derin Öğrenme Yaklaşımı

Classification of Blur Types in Thermal Images: A Deep Learning Approach

Emre Doğan^{1*}, Emre Sümer²

¹Türk Havacılık ve Uzay Sanayii (TUSAŞ), Ankara, Türkiye

²Başkent Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara, Türkiye

Bu makale, 10-11 Mayıs 2024 tarihleri arasında Karaelmas International Science and Engineering Symposium (KISES 2024) isimli sempozyumda sözlü olarak sunulan ve özet kitabında yayınlanan çalışmanın genişletilmiş versiyonudur (Sempozyum bildirisinin başlığı: "Classification of Blur Types in Thermal Images: A Deep Learning Approach").

Öz

Savunma teknolojilerinde kullanılan termal optik sistemler, görüntüleme sırasında çeşitli sorunlarla karşılaşır ve bu sorunlar, görüntülerin üzerinde farklı türlerde bulanıklık kusuru olarak ortaya çıkarlar. Bulanıklığın türünü belirlemek, görüntüyü iyileştirmenin ilk adımıdır. Bu çalışmada, çeşitli bulanıklık türleri (odaksızlık bulanıklığı, atmosferik türbülans bulanıklığı, görüntü titreme bulanıklığı, Gaussian bulanıklığı ve hareket bulanıklığı) modellenmiş ve 15000 FLIR termal görüntü içeren bir veri seti üzerinde Python programlama dili aracılığıyla rastgele değerlerle bulanıklıklar uygulanarak bir veri seti oluşturulmuştur. Daha sonra, ResNet50, InceptionV3, DenseNet201, VGG16 ve EfficientNetB0 gibi farklı Evrimsel Sinir Ağları bu termal görüntüleri sınıflandırmak için kullanılmıştır. Elde edilen sonuçlara göre en yüksek performans %98 doğruluk ile EfficientNetB0 mimarisi tarafından sağlanmıştır. Bu çalışma ile termal görüntülerdeki bulanıklık türlerini sınıflandırmada derin öğrenme yaklaşımının etkileri incelenmiş ve gelecekteki uygulamalar için umut verici sonuçlar elde edilmiştir.

Anahtar Kelimeler: Evrimsel sinir ağları, görüntü bulanıklığı, görüntü sınıflandırma, termal görüntüleme.

Abstract

Thermal optical systems used in defense technologies encounter various challenges during imaging, which manifest as different types of blurring artifacts on the images. Identifying the type of blur represents the first step in enhancing the image clarity. In this study, various types of blurs (defocus blur, atmospheric turbulence blur, image jitter blur, Gaussian blur, and motion blur) are modeled in Python, and a blurred dataset is created by applying these blurs with random values to a dataset containing 15000 FLIR thermal images. Subsequently, different Convolutional Neural Networks architectures such as ResNet50, InceptionV3, DenseNet201, VGG16, and EfficientNetB0 are used to classify these thermal images. This study represents a significant step for future applications by evaluating the effects of the deep learning approach in classifying blur types in thermal images. According to the results obtained, the highest performance is achieved with an accuracy of 98% using the EfficientNetB0 architecture. This study examines the effects of the deep learning approach in classifying blur types in thermal images and yields promising results for future applications.

Keywords: Convolutional neural networks, image blur, image classification, thermal imaging.

1. Giriş

Günümüzde hemen hemen her alanında ihtiyaç duyulan görüntüleme sistemlerinde çeşitli sebeplerden dolayı gö-

rüntü kusurları meydana gelmektedir. Gelişen teknolojiyle birlikte özellikle bilgisayarla görü alanında yapılan çalışmalarda görüntü kalitesinin iyileştirilmesi büyük önem taşımaktadır. Görüntülerdeki bulanıklık; kamera sarsıntısı, nesne hareketi, atmosferik etkiler, odaklama sorunları gibi çeşitli kaynaklardan oluşan yaygın bir sorundur. Bu sorunlar, görüntülerin kalitesini önemli ölçüde etkiler ve nesne tanıma gibi diğer görüntü işleme görevlerini engellemektedir (Zhang vd. 2022).

*Sorumlu yazarın e-posta adresi: emre.dogan@tai.com.tr

Emre Doğan orcid.org/0000-0002-2968-9994

Emre Sümer orcid.org/0000-0001-8502-9184



Bu eser "Creative Commons Atıf-GayriTicari-4.0 Uluslararası Lisansı" ile lisanslanmıştır.

Bulanıklık türünün sınıflandırması, görüntü restorasyonu için oldukça önemlidir (Wang vd. 2017). Hareket bulanıklığı, görüntüleme sisteminde sahne veya kameranın pozlama süresi boyunca hareket etmesiyle ortaya çıkan ve bulanık bir görüntüye yol açan yaygın bir problemdir. Hareket bulanıklığı iki ana hareket türünden kaynaklanır. Bunlardan ilki kamera hareketi, diğeri nesne hareketidir. Pozlama süresinin daha uzun kullanıldığı uygulamalarda hareket bulanıklığı daha belirgindir. Görüntünün bulanıklaşması, ayrıntıların ve netliğin kaybolmasına neden olmaktadır (Tiware 2020). Hareket bulanıklığı, yalnızca insanların görüntü algısını etkilemekle kalmayıp aynı zamanda bilgisayarla görü görevlerinde kullanılan görüntü sınıflandırma performansını da düşürebilmektedir (Pei vd. 2019). Bulanık görüntülere yol açan sorunlardan biri de elektro-optik sistemin tasarımından kaynaklanan odaklama eksikliği ve görüntüyü yakalama sırasındaki titreşimlerdir. Bir elektro-optik sistemin optik tasarımı, görüntü netliğinin belirlenmesinde kritik bir faktördür (Abramowitz ve Davidson Micheal 2018). Görüntüleme uydularında ve hava platformlarında sıralı görüntüleme çalışmaları yapılırken telafi edilemeyen titreşimlerde görüntü kalitesini büyük ölçüde düşürmektedir. Bu titreşimler geometrik deformasyona ve görüntü bulanıklığına neden olmaktadır (Liu vd. 2022). Bu bozulmaların dışında atmosfer koşulları da özellikle hava platformlarında görüntü kalitesini önemli ölçüde etkilemektedir. Örneğin, ısı bozulması mercekle sahne arasında yayılan ısı nedeniyle görüntünün bozulmasına neden olabilir ve bu da bir tür atmosferik bulanıklığa neden olur. Ayrıca sıcak atmosfer koşulları, odaklama hatalarına yol açarak görüntü netliğini olumsuz yönde etkileyebilir. Atmosferik türbülans ise atmosferin kırılma indisindeki dalgalanma nedeniyle görüntü üzerinde geometrik bozulmaya ve bulanıklığa sebep olarak ışık dalgalarının bozulmasına yol açar (Wu ve Su 2018).

Görüntüler üzerindeki bulanıklık türlerinin sınıflandırılmasıyla ilgili daha önce yapılan çalışmalarda, derin öğrenme tabanlı yöntemler ve öğrenimsiz (handcrafted) yöntemler karşılaştırılarak derin öğrenme tabanlı yöntemlerin daha başarılı olduğu görülmüştür (Wang vd. 2017). Yapılan derin öğrenme tabanlı çalışmalarda hem sentetik hem de gerçek hayattan elde edilen görüntüler kullanılmıştır. Sakthivel ve arkadaşların (2022) yapmış olduğu çalışmada, sualtından elde ettikleri odaksızlık ve hareket bulanıklığına sahip görüntülere net görüntüler de eklenerek üç sınıfa ait bir veri seti oluşturulmuş ve VGG-16 mimarisi kullanılarak %94 oranında başarıya ulaşılmıştır. Hareket bulanıklığı, odaksızlık bulanıklığı, Gaussian bulanıklığı modelleriyle bunların karışımı olarak karışık bulanıklık türlerini modellendiği

Tiware (2020)'nin çalışmasında, 2880 adet görüntüden oluşan bir veri seti oluşturmuş ve üç katmanlı Evrişimsel Sinir Ağları (ESA) ile sınıflandırarak %97 oranında başarı elde edilmiştir. Bir diğer çalışma (Fan vd. 2017), gerçek hayattan alınan, sentetik olmayan 1000 adet bulanık görüntü içeren veri setiyle yapılmıştır. Net görüntü, odaksızlık bulanıklığı ve hareket bulanıklığına sahip veri seti üç ara katmanlı ve üç çıkış katmanlı ESA mimarisiyle sınıflandırılmış ve %98 oranında başarı yakalanmıştır. Literatürde yapılan çalışmalarda genellikle odaksızlık, hareket ve Gaussian bulanıklıkları üzerine sınıflandırma çalışmaları yapılmıştır. Atmosferik etkilerin oluşturduğu bulanıklıklar ve yoğun titreşime sahip platformlara entegre olan görüntüleme sistemlerinde meydana gelen bulanıklık türleri için herhangi bir çalışma bulunmamaktadır. Bu çalışmada odaksızlık, hareket, Gaussian bulanıklıklara ilaveten LoS (Line of Sight- Bakış Hattı) titreşim bulanıklığı ve atmosferik türbülans bulanıklığı modellenerek altı sınıftan oluşan bir termal bulanık veri seti oluşturulmuştur. Literatürde bulunan popüler ESA mimarileri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışma ile hava platformlarında kullanılan elektro-optik sistemlerde oluşan bulanıklıkların restorasyonu için bir ön işleme adımı oluşturulmuştur.

2. Gereç ve Yöntem

2.1. Veri Seti

Bulanıklaştırma modellerinin uygulanması için orijinal veriler, Teledyne FLIR şirketinin termal başlangıç veri setinden alınmıştır (FLIR 2022). Bu veri seti, nesne algılamada kullanılan sinir ağlarının eğitimi ve doğrulaması için termal ve RGB görüntü setleri içermektedir (Şekil 1). FLIR veri seti, bir araca monte edilmiş RGB ve termal kameralar aracılığıyla elde edilmiştir. Toplamda 14452 termal görüntü içermektedir. Bu görüntülerin 10228'i kısa videolardan, 4224'ü ise 144 saniyelik tek bir videodan örneklenmiştir. Tüm videolar, genellikle açık gökyüzü koşullarında gündüz ve gece olmak üzere Santa Barbara, California, ABD'deki sokaklarda ve otoyollarda FLIR Tau2 marka termal kameralarla çekilmiştir. Oluşturulan veri setinde, 14,452 termal görüntü rastgele olarak eşit sayıda altı farklı sınıfa ayrılmış ve her sınıfa ait bulanıklık türü Python'da modellenerek bulanıklaştırılmış veri seti oluşturulmuştur.

2.1.1. Bulanıklaştırma Türleri

FLIR termal veri seti altı eşit parçaya rastgele ayrılarak türbülans bulanıklığı, odaksızlık bulanıklığı, Gaussian bulanıklığı, LoS titreşim bulanıklığı, hareket bulanıklığı etkileri görüntülere rastgele uygulanmıştır. Herhangi bir



Şekil 1. FLIR termal veri setinden örnek görüntüler.



Şekil 2. Odaksızlık bulanıklığına örnekler.

bozulmaya uğramamış görüntü sınıfı da net görüntü sınıfı olarak veri setine eklenmiştir.

2.1.1.1. Odaksızlık bulanıklığı

Bir nesneden gelen ışığın sensör düzlemine yeterli miktarda düşmediği durumlarda yakalanan görüntüler, odak dışı veya defokus bulanıklığı olarak bilinen durumu oluşturur. Odaksızlık bulanıklığı, bir görüntü üzerindeki piksel yoğunluklarının komşu pikseller etrafında dairesel bir şekilde dağılmasıyla görülür (Şekil 2). Görüntü üzerinde (x,y) koordinatlarındaki dairesel açıklığa sahip bir sistem tarafından oluşturulan odak dışı bulanıklık, R yarıçaplı bir düzgün disk olarak Denklem 1’de modellenmiştir (Liu vd. 2008).

$$h_d(x,y) = \begin{cases} \frac{1}{\pi R^2}, & \text{eğer } \sqrt{x^2 + y^2} \leq R \\ 0, & \text{diğer} \end{cases} \quad (1)$$

Frekans domaininde karşılığı ise aşağıdaki şekilde gösterilmiş olup, (u,v) koordinatlarındaki J_1 birinci dereceden Bessel fonksiyonu olarak modeldeki diskin yarıçapını temsil etmektedir (Denklem 2).

$$H(u,v) = \left[\frac{J_1(R\sqrt{u^2 + v^2})}{R\sqrt{u^2 + v^2}} \right] \quad (2)$$

2.1.1.2. Atmosferik türbülans bulanıklığı

Atmosferik türbülans bulanıklığı, türbülans etkilerinden kaynaklanan bozulmaları göstermek için bir dizi degradasyondan oluşur. Atmosferik türbülans modeli, atmosferik türbülansın etkisi nedeniyle oluşan bozulmaları hesaba katan bir MTF (Modülasyon Transfer Fonksiyonu) ekler (Şekil 3). Bu modelde, sensöre görünen türbülansın ortalama yoğunluğunu karakterize etmek için kırılma indeks yapı parametresi C_n^2 kullanılmıştır.

Türbülans MTF’nin hesaplanmasında Kopeika temelli aşağıdaki formül kullanılmıştır (Denklem 4). Bu formül içinde, uzay frekansı, indeks yapı parametresi, ilgi dalga boyu, menzil ve sensör açıklık çapı parametrelerine yer verilmektedir.

Modelin çıktıları arasında, her bir bileşenin toplam kombinasyon MTF’sini temsil eden MTF sinyalleri ve her bir görüntü kaynağının bağımsız olarak güç spektral yoğunlukları (PSD) olarak temsil edildiği Kök Gürültü PSD’si bulunur. Bu çıktılar, atmosferik türbülans bulanıklığı modeli içinde bulunan tüm gürültü kaynaklarını içerir.

Etkin C_n^2 değerini elde etmek için öncelikle Fried parametresi hesaplanır (Denklem 3).

$$r_0 = 2.1 \left[1.46k^2 \int_0^L \left(\frac{L-z}{L} \right)^{\frac{5}{3}} C_n^2(z) dz \right]^{\frac{3}{5}} \quad (3)$$

Bu denklemde z metre cinsinden yol uzunluğu boyunca konumu ifade eder, L ise yine metre cinsinden yol uzunluğunu temsil eder. $k = \frac{2\pi}{\lambda}$ ve λ ise kırınım dalga boyunu gösterir. Belirli bir konumdaki C_n^2 değeri bu denklem ile hesaplanır (Denklem 4).

$$C_n^2(z) = \begin{cases} C_n^2(h_0) \left(\frac{AL - Az}{Lh_0} \right)^{-\frac{4}{3}}, & \text{aşağı bakış} \\ C_n^2(h_0) \left(\frac{Az}{Lh_0} \right)^{-\frac{4}{3}}, & \text{yukarı bakış} \end{cases} \quad (4)$$

$C_n^2(h_0)$ değeri h_0 yüksekliğindeki C_n^2 değerini gösterir. A metre cinsinden yüksekliği, L metre cinsinden yol uzunluğu ve z ise metre cinsinden yol boyunca geçerli konumu temsil eder (Lawson ve Carrano 2006). Belirli bir konumdaki etkili C_n^2 değeri ise aşağıdaki denklem ile hesaplanır (Denklem 5).

$$(C_n^2)_{\text{eff}} = \frac{0.16r_0^{-\frac{5}{3}}\lambda^2}{L} \quad (5)$$

2.1.1.3. Görüş hattı (LoS) titreşim bulanıklığı

Görüş hattının (LoS) titremesi, Gaussian MTF bileşeni-

nin özel bir uygulamasıdır (Şekil 4). LoS titremesi, belirli bir mekansal frekans birimini, miliradyan başına döngüler cinsinden temsil ettiği için farklı bir uygulamadır. Bu, genel Gaussian MTF'nin etkisinden farklı olarak, LoS titremesi MTF'nin her zaman nesne alanında miliradyanlar cinsinden girişler gerektireceği anlamına gelmektedir. Bu çalışmada görüş hattının titreşiminden oluşacak degradasyon modeli için yatay ve dikey titreşim hareketleri titreşimin eşik değerine göre modellenmiştir (Denklem 6).

$$\xi_c = \frac{1}{G\sqrt{2\pi}} \quad (6)$$

Bu eşitlikte G titreşim değerinin derecesini belirtirken ξ_c ise hesaplanan titreşimin eşik değeridir. Belirlenen eşik değerine göre hem yatay hem de dikey titreşim degradasyonu miliradyan başına uzaysal frekans (ξ) olarak aşağıdaki gibi hesaplanır (Denklem 7).

$$MTF(f) = \exp\left(-\pi\left(\frac{\xi}{\xi_c}\right)^2\right) \quad (7)$$

2.1.1.4. Gaussian bulanıklığı

Gaussian bulanıklığı, görüntüleme sistemi üzerinde çeşitli gürültü kaynaklarından dolayı görüntü üzerinde oluşan bu-



Şekil 3. Atmosferik türbülans bulanıklığına örnekler.



Şekil 4. Görüş hattı titreşim bulanıklığına örnekler.

lanıklığın modellenmesi amacıyla çalışmaya dahil edilmiştir (Şekil 5). Bu bulanıklık modeli, Gaussian dağılımı ile rastgele modellenmiştir (Liu vd. 2008) (Denklem 8).

$$\eta(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (8)$$

Model üzerinde (x, y) bulanıklığın görüntü üzerindeki koordinatlarını, σ ise Gaussian dağılımının standart sapmasını gösterir. Çalışmada orjinal görüntülere eklenen Gaussian bulanıklığın varyansı Bulanık Sinyal-Gürültü Oranı (BSNR) metriği kullanılarak tanımlanmıştır. Bu denklemde σ_b^2 bulanık görüntünün varyansını, σ_n^2 ise gürültünün varyansını göstermektedir. (Tiwari 2018) (Denklem 9).

$$BSNR = 10 \log_{10} \left(\frac{\sigma_b^2}{\sigma_n^2} \right) \quad (9)$$

2.1.1.5. Hareket bulanıklığı

Hareket bulanıklığı, genellikle bir nesnenin hareketi sırasında kamera sensörüne düşen ışığın, pozlama süresi boyunca yayılması sonucunda meydana gelir (Şekil 6). Bu durum, hareketin yönüne ve hızına bağlı olarak, nesnelerin görüntü üzerinde izler bırakmasına yol açar. Görüntüleme yaparken kaydedilecek sahne, pozlama süresi $[0, t]$ boyunca yata

eksene θ derece açıyla ve sabit bir hızda (v) kameraya göre hareket ederse, bozulma tek boyutlu olacağından hareketin uzunluğu $L = v \times t$ olarak hesaplanır ve sabit hareket bulanıklığı için nokta yayılım fonksiyonu (PSF) olarak tanımlanır (Chong ve Tanaka 2009) (Denklem 10).

$$h_m(x, y) = \begin{cases} \frac{1}{L} & \text{eğer } 0 \leq |x| \leq \cos \theta, \quad y = L \sin \theta \\ 0, & \text{diğer} \end{cases} \quad (10)$$

h_m 'in frekans yanıtı aşağıda gösterildiği gibi bir SINC fonksiyonudur. Görüntü üzerinde PSF değeri hesaplanan (x, y) koordinatlarının frekans uzayındaki karşılığı (u, v) olarak gösterilmektedir. (Denklem 11). PSF'nin frekans yanıtına Optik Transfer Fonksiyonu (OTF) adı verilir (Tiwari 2018).

$$H(u, v) = \text{sinc}(\pi L(u \cos \theta + v \sin \theta)) \quad (11)$$

2.2. Derin Öğrenme ve Öğrenim Transferi

Derin öğrenme, gelişmiş veri yapıları üzerinde model oluşturma ve analiz yapma kapasitesi ile seçkin bir yapay zeka disiplini. Bu metodoloji, çok katmanlı sinir ağlarını kullanarak, girdi verilerinde bulunan özelliklerin otomatik öğrenim yeteneğine sahiptir. ESA, özellikle görüntü sınıflandırma ve nesne belirleme alanlarında etkili bir derin öğrenme



Şekil 5. Gaussian bulanıklığına örnekler.



Şekil 6. Hareket bulanıklığına örnekler.

yapısına sahiptir. ESA'lar, insan beyindeki biyolojik sinir ağlarının yapısını, öğrenme, hatırlama ve genelleme kabiliyetlerini taklit eder. Yapay sinir ağlarında öğrenme işlemi örnekler kullanılarak gerçekleştirilir. Öğrenme esnasında giriş bilgisi, ağırlık çeşitli katmanlarından geçer ve her katmanda belirli bir işleme tabi tutulur. Bu işlemler, genellikle konvolüsyon (convolution), aktivasyon (ReLU, sigmoid vb.), pooling (max, average vb.) ve tam bağlantı (fully connected) işlemlerini içerir (Hussein vd. 2024).


Öğrenim transferi ise modelin bir işlem için öğrendiği bilgiyi, genellikle benzer özelliklere sahip diğer bir işlem için kullanabilme kabiliyetini temsil eder. Öğrenim transferi eğitim süresini kısaltmayı ve performansı artırmayı amaçlayan bir makine öğrenme tekniğidir. Önceden eğitilmiş modellerin ağırlıkları, yeni görevler için bir başlangıç noktası sağlar ve bu sayede daha az veri ile daha hızlı ve yüksek başarı sağlanabilmektedir. Bu çalışmada ResNet50, DenseNet201, EfficientNetB0, InceptionV3 ve VGG16 ön eğitilmiş modelleri kullanılmıştır.

2.3. Performans Değerlendirme Metrikleri

Öğrenim transferi ile sınıflandırma performanslarının değerlendirilmesi için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve f1 skoru metrikleri kullanılmıştır. Bütün metrikler, her ön eğitilmiş modelin en başarılı modelinin test verisiyle test edilmesinden elde edilen karmaşıklık matrislerine (confusion matrix) göre hesaplanmıştır. Karmaşıklık matrisi, modelin sınıflar için verdiği doğru ve yanlış tahminleri, gerçek etiketleri ile birlikte gösteren tablodur. Şekil 7'de ikili (A ve B sınıfı) bir sınıflandırma problemi için karmaşıklık matrisi verilmiştir. TP (True Positive, Doğru Pozitif), gerçekte A sınıfına (pozitif) ait olan ve doğru bir şekilde tahmin edilen örneklerin sayısını ve TN (True Negative, Doğru Negatif) ise gerçekte B sınıfından (negatif) olan ve doğru tahminlenen örneklerin sayısını ifade etmektedir. B sınıfı olarak yanlış tahmin edilen ve gerçekte A sınıfından olan örneklerin sayısı, FN (False Negative, Yanlış Negatif) ve yanlış bir şekilde A olarak tahmin edilen B sınıfı örneklerin sayısı ise FP (False Positive, Yanlış Pozitif) ile belirtilmiştir (Kılıç ve Yalçın 2024).

Transfer öğrenme modellerinin performansını ölçmek için çalışmada doğruluk metriği tercih edilmiştir. Doğruluk (accuracy), tüm örnekler arasında doğru bir şekilde sınıflandırılanların oranını belirtir ve bu oran aşağıdaki formül ile hesaplanabilir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$



Şekil 7. Karmaşıklık matrisi örneği (Kılıç ve Yalçın 2024).

Kesinlik (precision) metriği ise pozitif olarak tahminlenen örneklerin gerçekte kaçının pozitif olduğunu belirtir ve şu şekilde hesaplanır.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (13)$$

Duyarlılık (Recall) ise pozitif olarak tahmin etmemiz gereken örneklerin ne kadarını pozitif olarak tahmin ettiğimizi gösteren bir metriktir (Burduk 2020).

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (14)$$

F1 skoru, modelin kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasını olarak hesaplanır (Christen vd. 2023).

$$F \text{ Skoru} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (15)$$

Destek (support) ise doğrudan bir modelin performansını ölçmez. Her bir sınıfın veri setindeki gerçek örnek sayısını ifade ederek bir sınıfın ne kadar sık görüldüğünü belirtir. Makro ortalama, her bir sınıfın performansını eşit olarak değerlendiren bir metriktir. Bu metrik, her bir sınıf için hesaplanan performans metriklerinin basit aritmetik ortalamasını alır. Ağırlıklı ortalama ise her bir sınıfın veri setindeki örnek sayısını dikkate alınarak hesaplanan bir metriktir. Bu metrik, her bir sınıfın performans metriklerini, o sınıfa ait örnek sayısı ile çarpar ve bu değerleri toplar. Sonra bu toplamı, tüm sınıfların örnek sayılarının toplamına böler. Çalışma kapsamında test verisinden elde edilen karmaşıklık matrisine göre bütün metrikler hesaplanmıştır.

2.4. Sınıflandırma

Kullanılan bütün ESA mimarilerinde, hem aşırı öğrenmeyi engellemek hemde modelin performansını daha doğru bir şekilde değerlendirmek için k-fold çapraz doğrulama tekniği kullanılmıştır. Veri setinin %95'lik kısmı (kat)her itersasyonda %80 eğitim ve %20 doğrulama verisi olmak üzere beşer kez eğitilmiştir. Termal veri setinin %5'i eğitim aşamalarından sonra modeli test etmek için ayrılmıştır. Her mimaride en başarılı katta bulunan model kaydedilerek diğer mimarilerle karşılaştırılmış ve test verileriyle test edilmiştir. Bütün mimarilerde eğitim aşağıdaki konfigürasyona göre yapılmıştır (Çizelge 1).

Çizelge 1. Eğitim parametreleri

Parametre	Değer
Optimizasyon algoritması	Adam
Maksimum devir sayısı (Epoch)	50
Veri seti karıştırma (K-fold cross validation)	5
Öğrenme oranı (Learning Rate)	0.0001
Yığın büyüklüğü (Batch size)	32
Nöron düşürme oranı (Dropout)	0.5

3. Bulgular ve Tartışma

Oluşturulan veri seti ResNet50, DenseNet201, EfficientNetB0, InceptionV3 ve VGG16 ESA mimarileriyle sınıflandırılmıştır. Yapılan çalışmada VGG16 modelinin diğer modellere göre daha düşük bir başarıya sahip olduğu görülmüştür, özellikle Gaussian bulanıklık türünün sınıflandırılmasında “odaksızlık bulanıklığı” sınıfıyla karıştırılmıştır. Odaksızlık bulanıklık modeli sabit çaplı bir disk olarak modellendiğinden ve VGG16 modelinin bütün konvolüs-

yon katmanları sabit 3×3 konvolüsyon çekirdeklerinden oluştuğundan dolayı VGG16 modelinin başarısının diğerlerinden daha düşük olduğu düşünülmektedir. ResNet50, DenseNet201 ve InceptionV3 modelleri, farklı boyutlardaki konvolüsyon çekirdekleriyle, her katmanda önceki tüm katmanlardaki özellik haritasını kullanarak geniş bir özellik yelpazesi yakaladığından dolayı test verisi üzerinde birbirlerine yakın başarı göstermişlerdir. Yapılan çalışmada EfficientNetB0 modeli hem farklı boyutlarda konvolüsyon çekirdeklerine sahip olması hem de diğer kullanılan modellerde bulunmayan MBConv (Mobile Inverted Bottleneck Convolution) katmanı sayesinde tekdüze dağılıma sahip bulanıklık desenlerinin sınıflandırılmasında en yüksek başarıyı gösteren model olmuştur.

Aşağıda her mimariye ait katlamaların (fold) başarıları, karmaşıklık matrisleri ve sınıflandırma raporları verilmiştir.

3.1. ResNet50


Çizelge 2. ResNet50 eğitim ve test doğruluğu

ResNet50 Eğitim Doğruluğu					ResNet50 Test Doğruluğu
1.Kat	2.Kat	3.Kat	4.Kat	5.Kat	%95
%86	%69	%98	%36	%82	

ResNet50 modelinin eğitim aşamalarında 3.kat modeli %98 oranında başarı göstermiştir (Çizelge 2). Eğitim aşamalarında 4.kat modeli veri seti içerisinde diğer katlara göre en kötü eğitim verisini tercih ettiğinden, doğrulama verisiyle %36 oranında başarı yakalanmıştır. Toplamda 726 adet görüntüye sahip test verisi, 3.katta eğitilen modelde test edilerek %95 oranında başarı sergilemiştir (Çizelge 3). Şekil 8'de gösterildiği üzere ResNet50 modeli, oluşturduğumuz veri

Çizelge 3. ResNet50 sınıflandırma raporu.

	Kesinlik (Precision)	Duyarlılık (Recall)	F1- Skoru	Örnek Sayısı (Support)
Türbülans bulanıklığı	1.00	0.93	0.97	121
Net görüntü	0.91	1.00	0.95	121
Odaksızlık bulanıklığı	0.92	0.91	0.91	121
Gaussian bulanıklığı	1.00	1.00	1.00	121
LoS titreşim bulanıklığı	0.90	0.94	0.92	121
Hareket bulanıklığı	0.98	0.92	0.95	121
Doğruluk (accuracy)			0.95	726
Makro ortalama	0.95	0.95	0.95	726
Ağırlıklı ortalama	0.95	0.95	0.95	726



Şekil 8. ResNet50 karmaşıklık matrisi.

seti içerisindeki “Gaussian Bulanıklığı” ve “Net Görüntü” sınıflarına ait bütün görüntüleri doğru tahmin etmiştir.

Çizelge 4. DenseNet201 eğitim ve test doğruluğu.


DenseNet201 Eğitim Doğruluğu					DenseNet201 Test Doğruluğu
1.Kat	2.Kat	3.Kat	4.Kat	5.Kat	%94
%84	%97	%95	%98	%98	

3.2. DenseNet201


DenseNet201 mimarisiyle yapılan çalışmanın neticesinde, eğitim aşamalarında 1.kat’ın dışındaki bütün eğitim sonuçlarında %90’ın üzerinde başarı yakalanmıştır (Çizelge 4). ResNet50 mimarisinin sonuçlarında görüldüğü gibi bu mimaride de “Odaksızlık Bulanıklığı” ve “Net Görüntü” sınıflarına ait bütün test verisi doğru tahmin edilmiştir (Şekil 9, Çizelge 5).

Çizelge 5. DenseNet201 sınıflandırma raporu.

	Kesinlik (Precision)	Duyarlılık (Recall)	F1- Skoru	Örnek Sayısı (Support)
Turbulans bulanıklığı	1.00	0.87	0.93	121
Net görüntü	0.83	1.00	0.91	121
Odaksızlık bulanıklığı	0.94	0.93	0.93	121
Gaussian bulanıklığı	0.99	1.00	1.00	121
LoS titreşim bulanıklığı	0.92	0.94	0.93	121
Hareket bulanıklığı	0.99	0.91	0.95	121
Doğruluk (accuracy)			0.94	726
Makro ortalama	0.95	0.94	0.94	726
Ağırlıklı ortalama	0.95	0.94	0.94	726



Şekil 9. DenseNet201 karmaşıklık matrisi.



Şekil 10. EfficientNetB0 karmaşıklık matrisi

3.3. EfficientNetB


Çizelge 6. EfficientNetB0 eğitim ve test doğruluğu

EfficientNetB0 Eğitim Doğruluğu					EfficientNetB0 Test Doğruluğu
1.Kat	2.Kat	3.Kat	4.Kat	5.Kat	%97
%98	%97	%98	%99	%99	

EfficientNetB0 mimarisinde Çizelge 6'da görüldüğü üzere hem eğitim hem de test aşamalarında çok yüksek başarı oranları göstermiştir. EfficientNetB0 modeli çalışmanın en başarılı modeli olmasına rağmen sadece "Net Görüntü" sınıfına ait test görüntülerinin tamamını doğru tahmin edebilmiştir (Şekil 10, Çizelge 7). Çalışmanın en başarılı modeli EfficientNetB0 olsada, bulanıklık türlerine göre farklı ESA mimarilerinin daha başarılı olabileceği gözlemlenmiştir.

Çizelge 7. EfficientNetB0 sınıflandırma raporu

	Kesinlik (Precision)	Duyarlılık (Recall)	F1- Skoru	Örnek Sayısı (Support)
Türbülans bulanıklığı	1.00	0.99	1.00	121
Net görüntü	0.97	1.00	0.98	121
Odaksızlık bulanıklığı	0.93	0.98	0.96	121
Gaussian bulanıklığı	1.00	0.99	1.00	121
LoS titreşim bulanıklığı	0.98	0.94	0.96	121
Hareket bulanıklığı	1.00	0.97	0.98	121
Doğruluk (accuracy)			0.98	726
Makro ortalama	0.98	0.98	0.98	726
Ağırlıklı ortalama	0.98	0.98	0.98	726

**Şekil 11.** InceptionV3 karmaşıklık matrisi.**Çizelge 8.** InceptionV3 eğitim ve test doğruluğu

InceptionV3 Eğitim Doğruluğu					InceptionV3 Test Doğruluğu
1.Kat	2.Kat	3.Kat	4.Kat	5.Kat	%94
%95	%98	%98	%98	%95	

3.4. InceptionV3

InceptionV3 modelinin eğitim aşamalarında bütün katlarda neredeyse aynı başarı oranı yakalanmıştır (Çizelge 8). Model, özellikle karmaşık bir bulanıklık modeli olan “Türbülans Bulanıklığı”na ait bütün test verisini doğru tahmin


edebilmiştir (Şekil 11). Fakat “Gaussian Bulanıklığı” sınıfına ait 121 adet test görüntüsünün yaklaşık %20’sini “Odaksızlık Bulanıklığı” olarak tahmin etmiştir. Ayrıca InceptionV3 modeli “Hareket Bulanıklığı” sınıfında da diğer modellerin hepsinden daha başarılı olduğu gözlemlenmiştir (Çizelge 9).

3.5. VGG16

VGG16 modelinde, eğitim aşamalarında bütün katlarda %90’nın üzerinde başarı elde edilmesine rağmen test verisinde başarı oranı %83 olmuştur (Çizelge 10). Çalışma kapsamında diğer modeller arasında en düşük başarıyı gösteren model olmuştur. Özellikle “Gaussian Bulanıklığı” sınıfına ait 121 adet görüntünün yarısından fazlasını “Odaksızlık Bulanıklığı” olarak tahmin etmiştir (Şekil 12, Çizelge 11).

Çizelge 9. InceptionV3 sınıflandırma raporu

	Kesinlik (Precision)	Duyarlılık (Recall)	F1- Skoru	Örnek Sayısı (Support)
Türbülans bulanıklığı	1.00	1.00	1.00	121
Net görüntü	0.96	0.99	0.98	121
Odaksızlık bulanıklığı	0.82	0.92	0.87	121
Gaussian bulanıklığı	1.00	0.81	0.89	121
LoS titreşim bulanıklığı	0.91	0.94	0.93	121
Hareket bulanıklığı	0.98	0.99	0.99	121
Doğruluk (accuracy)			0.94	726
Makro ortalama	0.95	0.94	0.94	726
Ağırlıklı ortalama	0.95	0.94	0.94	726

**Şekil 12.** VGG16 karmaşıklık matrisi.**Çizelge 10.** VGG16 eğitim ve test doğruluğu

VGG16 Eğitim Doğruluğu					VGG16 Test Doğruluğu
1.Kat	2.Kat	3.Kat	4.Kat	5.Kat	
%91	%94	%96	%97	%95	%83

4. Sonuç ve Değerlendirme

Yürütülen çalışmanın sonucunda, termal görüntülerde tek bir kaynaktan ortaya çıkan tezdüze (uniform) dağılıma sahip bozulmaların sınıflandırılmasında EfficientNetB0 mimarisi kullanılarak %98 oranında başarı elde edilmiştir. Bulanıklık

türlerinin sınıflandırılmasında derin öğrenme tabanlı yöntemlerin çok yüksek başarılı sonuçlar ortaya koyduğu gözlemlenmiştir. Çalışmada başarı oranı en düşük mimari olan VGG16 mimarisiyle 2022 yılında Sakthivel ve arkadaşlarının yaptığı çalışmada sualtı görüntülerinde %94 oranında yüksek bir başarı yakalanmıştır. Bulanıklık türlerinin sınıflandırılmasında aynı ESA mimarilerinin çalışma ortamına göre farklı sonuçlar ortaya koyabileceği görülmüştür.

Bulanıklık etkileri, optik sistemlerin odak bozulması veya görüş hattı titreşimi gibi nedenlerle meydana geldiğinde genellikle tekdüze dağılıma sahip bir bulanıklık oluşturmaktadır. Ancak, atmosferik türbülans etkileri veya hareket

Çizelge 11. VGG16 sınıflandırma raporu

	Kesinlik (Precision)	Duyarlılık (Recall)	F1-Skoru	Örnek Sayısı (Support)
Türbülans bulanıklığı	1.00	0.92	0.96	121
Net görüntü	0.87	0.97	0.92	121
Odaksızlık bulanıklığı	0.58	0.88	0.70	121
Gaussian bulanıklığı	1.00	0.46	0.63	121
LoS titreşim bulanıklığı	0.85	0.91	0.88	121
Hareket bulanıklığı	0.94	0.88	0.91	121
Doğruluk (accuracy)			0.83	726
Makro ortalama	0.87	0.83	0.83	726
Ağırlıklı ortalama	0.87	0.83	0.83	726

bulanıklıkları genellikle tekdüze dağılıma sahip olmayan bir etki yaratmaktadır. Daha önce yapılan çalışmalarda genellikle hareket bulanıklılığı, odak bozulması bulanıklılığı ve rastgele Gaussian bulanıklık türleri üzerine çalışmalar yapılmıştır, bu çalışmada hava-yer platformlarında görüntüleme sistemlerinin atmosfer ve LoS titreşim hareketlerinden dolayı oluşan bozulmalar eklenerek araştırma alanı genişletilmiştir.

Gerçek hayat problemlerinde, tek bir görüntü üzerinde birden fazla türde bulanıklık oluşabileceği gibi her bulanıklık türü tekdüze bir dağılıma sahip olmayabilir. Bu nedenle gelecekteki çalışmalarda, bu çalışmada eğitilen EfficientNetB0 modelinin sentetik olarak üretilmemiş (gerçek) bulanık görüntülerle test edilip tekdüze dağılıma sahip olmayan bulanıklıklar için de uyarlanması hedeflenmektedir. Ayrıca, birden fazla türde bulanıklığa sahip görüntülerle yeni bir model oluşturulması ve görüntülerdeki bulanıklığın derin öğrenme teknikleri kullanarak iyileştirilmesi planlanmaktadır.

Yazar katkısı: Emre Doğan: Çalışmayı planlamış, veri setini düzenlemiş, deneyleri gerçekleştirmiş, sonuçları analiz etmiş ve makaleyi yazmıştır, Emre Sümer: Çalışmayı planlamış, sonuçları değerlendirmiş ve makaleyi yazmıştır.

5. Kaynaklar

- Abramowitz, M., Davidson, M. W. 2018.** Troubleshooting microscope configuration and other common errors. Olympus Microscopy Resource Center, 1-14.
- Burduk, R. 2020.** Classification performance metric for imbalance data based on recall and selectivity normalized in class labels.

Chong, RM., Tanaka, T. 2009. Image extrema analysis and blur detection with identification. 2008 IEEE International Conference on Signal Image Technology and Internet Based Systems, pp. 320 – 326, Bali, Indonesia. Doi: 10.1109/SITIS.2008.38

Christen, P., Hand, D., Kirielle, N. 2023. A review of the F-Measure: Its History, properties, criticism, and alternatives. ACM Computing Surveys, 56(3):1-24. Doi: 10.1145/3606367.

Fan, M., Huang, R., Feng, W., Sun, J. 2017. Image blur classification and blur usefulness assessment. 2017 IEEE International Conference on Multimedia & Expo Workshops (ICMEW), pp. 531-536, Hong Kong. Doi: 10.1109/ICMEW.2017.8026291

FLIR ADAS Dataset v2.0.0. 2022. FREE Teledyne FLIR Thermal Dataset for Algorithm Training. <https://www.flir.com/oem/adas/adas-dataset-form/>

Hussein, A., Garba Sharifai, A., Alia, O., Abualigah, L., Almotairi, K., Abujayyab, S., Gandomi, A. 2024. Auto-detection of the coronavirus disease by using deep convolutional neural networks and X-ray photographs. Scientific Reports, 14(1):534. Doi: 10.1038/s41598-023-47038-3

Kılıç, İ., Yalçın, N. 2024. Transfer öğrenme teknikleri kullanarak nohut çeşidi sınıflandırma. Karaelmas Fen Ve Mühendislik Dergisi, 14(1):48-58. DOI: 10.7212/karaelmasfen.1427715

Lawson, JK., Carrano, CJ. 2006. Using historic models of Cn2 to predict r0 and regimes affected by atmospheric turbulence for horizontal, slant, and topological paths. Atmospheric Optical Modeling, Measurement, and Simulation II, SPIE, 6303:38-49. Doi: 10.1117/12.679108

Liu, R., Li, Z., Jia, J. 2008. Image partial blur detection and classification. IEEE International Conference on Computer Vision Pattern Recognition, pp. 1-8, Anchorage, AK. Doi: 10.1109/CVPR.2008.4587465

- Liu, S., Lin, F., Tong, X., Zhang, H., Lin, H., Xie, H., Ye, Z., Zheng, S. 2022.** Dynamic PSF-based jitter compensation and quality improvement for push-broom optical images considering terrain relief and the TDI effect. *Applied Optics*, 61(16):4655-4662. Doi: 10.1364/AO.453163
- Pei, Y., Huang, Y., Zou, Q., Xy, Z., Wang, S. 2019.** Effects of image degradation and degradation removal to CNN-based image classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43(4):1239-1253. Doi: 10.1109/TPAMI.2019.2950923
- Shivel, S., Akash, K., Sidarth, B., Ganesh, C. 2022.** Blur classification and estimation of motion blur parameters using OLR. *International Conference on Electronic Systems and Intelligent Computing (ICESIC)*, pp. 323-328, Chennai, India. Doi: 10.1109/ICESIC53714.2022.9783566
- Tiwari, S. 2018.** Blur classification using segmentation based fractal texture analysis. *Indonesian Journal of Electrical Engineering and Informatics*. 6(4):373-384. Doi: 10.11591/ijeeci.v6i4.463
- Tiwari, S. 2020.** A blur classification approach using deep convolution neural network. *International Journal of Information System Modeling and Design*. 11(1): 93-111. Doi: 10.4018/IJISMD.2020010106
- Wang, R., Li, W., Qin, R., Wu, J. 2017.** Blur image classification based on deep learning. *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, pp. 1-6, Beijing, China. Doi: 10.1109/IST.2017.8261503
- Wu, J., Su, X. 2018.** Method of image quality improvement for atmospheric turbulence degradation sequence based on graph Laplacian filter and nonrigid registration. *Mathematical Problems in Engineering*. 2018(1): 4970907. Doi: 10.1155/2018/4970907
- Zhang, K., Ren, W., Luo, W., Lai, W., Stenger, B., Yang, MH., Li, H. 2022.** Deep image deblurring: A Survey. *International Journal of Computer Vision*. 130:1-28. Doi: 10.1007/s11263-022-01633-5