



# **Fotokapan Fotoğraflarında Bazı Hayvan Türlerinin Tespiti**

**Program Kodu: 1001**

**Proje No: 115E918**

Proje Yürütücüsü:

**Doç. Dr. Yalın BAŞTANLAR**

MAYIS 2018

İZMİR



## ÖNSÖZ

Projemizde, doğada hayvanlarla ilgili gözlem yapabilmek için kullanılan fotoğraf makineleri (fotokapan) ile alınan fotoğraflarda otomatik hayvan tespiti üzerine araştırma yapılmıştır. Fotokapan kullanımı son yıllarda dünya çapında önemli ölçüde artış göstermiştir. Düzgün çalışan bir fotokapandan ayda bine yakın fotoğraf alınabilmektedir. Tüm bu fotokapan görüntülerinin elden geçirilmesi ve içinde hayvan olup olmadığının ve hangi hayvan olduğunun belirlenmesi için gerekli işgücü de orantılı olarak artmaktadır. Projenin amacı, fotokapan fotoğraflarında belirli bir hayvan türünün bulunma potansiyelini büyük oranda tespit ederek doğa araştırmacılarına gözle kontrol etmeleri gereken çok daha az sayıda fotoğraf bırakmaktır.

Raporumuzda, hayvansız fotoğrafları eleme ve belirli hayvanları tespit için proje boyunca geliştirilen yöntemler açıklanarak deney sonuçları aktarılmıştır. Bu çalışma, TÜBİTAK ARDEB tarafından 115E918 nolu proje kapsamında desteklenmiştir.



## İÇİNDEKİLER

1. Giriş.....	8
2. Literatür Özeti.....	10
3. Aşırı Parlak, Aşırı Karanlık ve Bulanık İmgelerin Elenmesi .....	12
3.1. Aşırı Parlak ve Aşırı Karanlık İmgeler için Eleme Yöntemi.....	12
3.2. Bulanık İmgelerin Elenmesi için Yöntem.....	13
3.3. Deneyle.....	15
4. Hayvan İçermeyen İmgelerin Elenmesi .....	17
4.1. Derin Öğrenme ile Hayvanlı İmgelerin Tespiti .....	17
4.2. Arkaplan Çıkarımı ile Hayvanlı İmgelerin Tespiti .....	19
4.3. Deneyle .....	21
5. İmgelerde Belirli Hayvanların Tespiti .....	26
5.1 Motivasyon.....	26
5.2 Yöntem .....	26
5.3 Deneyle .....	29
6. Prototip Yazılım .....	33
7. Sonuçlar.....	34
Referanslar.....	36



## TABLO LİSTESİ

Tablo 1. Karanlık ve parlak imge deneylerinin hata matrisi .....	16
Tablo 2. Bulanık imge veriseti ile yapılan deneyin hata matrisi .....	16
Tablo 3. Faster R-CNN ve ResNet yapılarının Orman Bakanlığı veriseti üzerindeki doğrulukları (elenen ve korunan imgelerin ortalama yüzdeleri).....	18
Tablo 4. Derin Öğrenme ile Elenen ve Korunan İmge Oranları .....	22
Tablo 5. Orman Bakanlığı veriseti ile eğitilen modelin Missouri Üniversitesi veriseti üzerindeki başarısı.....	23
Tablo 6. Tek bir EYSA başarısı ile topluluk öğrenmesi (dört EYSA) başarısının karşılaştırılması.....	23
Tablo 7. Arkaplan Çıkarımı Yöntemi ile Elenen ve Korunan İmge Oranları .....	24
Tablo 8. Birleşik Yöntem ile Elenen ve Korunan İmge Oranları.....	25

## ŞEKİL LİSTESİ

- Şekil 1. Fotokapanlardan elde edilen imgelere bazı örnekler. Üst sıradakiler gündüz çekilen, alt sıradakiler ise gece çekilen fotoğraflar. ....8
- Şekil 2. Parlak ve karanlık imge örnekleri. Sol sütunda kullanılamaz olarak nitelendirilen imgeler yer alırken sağ tarafta kullanılabilir durumda imgeler yer almaktadır. ....12
- Şekil 3. Bulanık ve net olarak nitelendirilen imgeler ve bu imgelerin frekans haritaları ile kümülatif dağıtım değerleri. Sol tarafta bulanık imgenin verileri, sağda ise net imgenin verileri yer almaktadır. ....14
- Şekil 4. Örnek bir parçalı bulanık imge. Sistem tarafından elenmemesi gerekir çünkü hayvan türü açıkça ayırt edilebilmektedir. ....15
- Şekil 5. Faster R-CNN yapısı .....18
- Şekil 6. Ham verisetinde ardarda arkaplan çıkarma işlemine giren iki imge (her satırın solunda). Sağdaki imgeler önplan imgesini göstermektedir. (b) imgesi (a) imgesinden hemen sonra işleme girdiği için arkaplan öğrenme işlemi gerçekleşmemiş, imgede nesne yer almamasına rağmen (a)'ya göre neredeyse tüm piksellerde değişim olduğundan hatalı sonuç alınmıştır. ....19
- Şekil 7. Sıralanan imgelerin arkaplan sahnesine göre oluşturdukları kümeler. ....20
- Şekil 8. Farklı eşik değerleri için derin öğrenme deney sonuçları. ....22
- Şekil 9. Derin öğrenme yaklaşımı ile doğru tespit edilen hayvanlar (a)'da yer alırken, (b)'de sol imgede su birikintisi önünde bulunan domuz arkaplan dokusuna benzediği için ayırt edilmemiş, (b)'de sağdaki imgede ise hayvan dokusuna benzer dokudaki taşlar ve ağaçlar etiketlenmiştir. ....23
- Şekil 10. Parça tabanlı eğitim yöntemi için eğitim setinden bazı örnekler. Soldan sağa, leopar (iki tane), zebra, fil ve ayı örnekleri. ....27
- Şekil 11. Kapsayan kutuların tahminleme. ....28
- Şekil 12. Girdi imge örnekleri üst satırda, önerilen parça tabanlı yöntem ile elde edilen sıcaklık haritaları ise alt satırda verilmiştir. ....28
- Şekil 13. Parça tabanlı yöntemde eşik değeri arttıkça kapsayan kutuların küçülmesi. ....28
- Şekil 14. Faster R-CNN ve parça tabanlı yöntemi kıyaslamak üzere alan-kesinlik (area-precision) / area-recall (alan-anma) eğrileri. ....30
- Şekil 15. Parça tabanlı yöntem tarafından kötü tahminlenen bir ayı örneği. ....30
- Şekil 16. Faster R-CNN ve Birleşik Modeli karşılaştırmak üzere kesinlik-anma eğrileri. ....31



## ÖZET

Fotokapanlar doğada vahşi hayvanları gözlemlemek için kurulan hareket sensörlü kameralardır. Gelişen teknolojilerle birlikte fotokapan kullanımı ve dolayısıyla sahadan toplanan imge sayısı belirgin bir şekilde artmıştır. Tüm fotokapan görüntülerinin elden geçirilmesi ve içinde hayvan olup olmadığının ve hangi hayvan olduğunun tespit edilmesi için gerekli işgücü de orantılı olarak artmaktadır. Çalışmamızda amaç, bu tespitleri otomatik yaparak doğa araştırmacılarına gözle kontrol etmeleri gereken çok daha az sayıda fotoğraf bırakmaktır. Bu amaç doğrultusunda öncelikle aşırı parlak, karanlık ve bulanık fotoğrafların elenmesi için etkili teknikler araştırılmıştır. Bu kullanışsız fotoğrafların elenmesinin ardından birinci hedef hayvan içeren fotoğrafların tespitidir. Çalışmamızda, bunun için hem arkaplan çıkarımı ile nesne tespiti (fotokapanlar değişmeyen arkaplanı bulunan sahneden değişen zaman aralıkları ile imge topladığından) hem de evrişimli yapay sinir ağları (EYSA) ile nesne bulma teknikleri bir arada kullanılarak hayvan içermeyen imgeleri ayıklayan bir sistem önerilmiştir. Bir diğer hedef de fotoğraflarda belirli bir hayvan türünün tespitidir. Bunun için de evrişimli yapay sinir ağlarını (EYSA) belirli bir hayvan türünü bulmak için eğitmek üzerine araştırma yapılmış, parça-tabanlı eğitime dayalı özgün bir yöntem önerilmiştir. Ayrıca, geliştirilen eleme ve hayvan bulma yöntemlerin nasıl bir arayüz ile kullanıcıya aktarılması gerektiği ile ilgili de araştırma yapılmış, bir yazılım prototipi geliştirilmiştir.

Anahtar Kelimeler: Görüntü işleme, örüntü tanıma, fotokapan, nesne tespiti, hayvan tespiti, derin öğrenme, evrişimli yapay sinir ağları



## ABSTRACT

Camera-traps are motion triggered cameras that are used to observe animals in nature. The number of images collected from camera-traps has increased significantly with developing technologies. A great workload is required for researchers to group and label this great amount of images. In this work, we aimed to automatically eliminate useless photos and leave respectively little amount of photos to be examined by the researchers to check if there exists an animal in the image (and which animal if any exists). To this aim, we first investigated efficient techniques to eliminate completely dark, white or blurred images. An objective for the remaining part is to eliminate the images that do not contain any animals since they are useless. In our work, we developed a system employing both background subtraction (since camera-trap photos are taken from scenes with static background) and convolutional neural networks (CNNs). Another objective is detecting a certain animal species in photos. To accomplish this task, we worked on different techniques to train convolutional neural networks (CNNs) and we proposed a patch-based training method that increases the detection performance. Moreover, we developed a software prototype that includes the modules of eliminating dark, white, blurred or other useless photos and the modules of detecting a certain animal species.

Keywords: Image processing, pattern recognition, camera-trap, object detection, animal detection, deep learning, convolutional neural networks

## 1. Giriş

Fotokapanlar doğadaki hayvanların geçiş yolları üzerine yerleştirilen hareket sensörlü kameralardır. Fotokapan kullanımı son yıllarda dünya çapında önemli ölçüde artış göstermiştir. Düzgün çalışan bir fotokapandan ayda bine yakın fotoğraf alınabilmektedir. Bu kameralardan alınan bazı örnek imgeler Şekil 1’de verilmiştir. Tüm bu fotokapan görüntülerinin elden geçirilmesi ve içinde hayvan olup olmadığının ve hangi hayvan olduğunun belirlenmesi için gerekli işgücü de orantılı olarak artmaktadır.



Şekil 1. Fotokapanlardan elde edilen imgelere bazı örnekler. Üst sıradakiler gündüz çekilen, alt sıradakiler ise gece çekilen fotoğraflardır.

Literatürde, doğa araştırmacılarının ihtiyaçlarına yönelik yapılmış çalışmalar mevcuttur. Örneğin [1] ve [2]'de kullanıcı dostu bir arayüzle, imgeleri etiketleme ve dosyaları düzenleme işlevleri olan yazılımlar sunulmuştur. Ancak, bu araçlar araştırmacıların tüm imgeleri gözle inceleme zorunluluğunu ortadan kaldırmaz. Bizim ele aldığımız yaklaşım ise incelenecek fotoğraf sayısını azaltmaktır. Ham fotoğraf kümesinde herhangi bir hayvan veya



belirli bir hayvan içeren fotoğrafları otomatik olarak tespit ederek doğa araştırmacılarına gözle kontrol etmeleri gereken çok daha az sayıda fotoğraf bırakmaktır.

Bu amaç doğrultusunda öncelikle aşırı parlak, karanlık ve bulanık fotoğrafların elenmesi için etkili teknikler araştırılmıştır. Aşırı parlak ve aşırı karanlık imgelerin ayıklanmasında histogram bazlı bir analiz kullanılmıştır. Bulanık imgeler ise Fourier dönüşüm imgelerinde yüksek frekansların oranına dayalı bir yöntem ile tespit edilmiştir. Bir kısmı bulanık olan imgelerin elenmemesi için önlemler alınmıştır.

Bu kullanışsız fotoğrafların elenmesi sonrasındaki hedef hayvan içermeyen fotoğrafların elenmesidir. Çalışmamızda, bunun için hem arkaplan çıkarımı ile nesne tespiti (fotokapanlar değişmeyen arkaplanı bulunan sahneden değişen zaman aralıkları ile imge topladığından) hem de evrişimli yapay sinir ağları (EYSA) ile nesne bulma teknikleri bir arada kullanılarak hayvan içermeyen imgeleri ayıklayan bir sistem önerilmiştir.

Bir diğer hedef de fotoğraflarda belirli bir hayvan türünün tespitidir. Bunun için de evrişimli yapay sinir ağlarını (EYSA) belirli bir hayvan türünü bulmak için eğitmek üzerine araştırma yapılmış, parça-tabanlı eğitime dayalı özgün bir yöntem önerilmiştir. Ayrıca, geliştirilen eleme ve hayvan bulma yöntemlerin nasıl bir arayüz ile kullanıcıya aktarılması gerektiği ile ilgili de araştırma yapılmış, bir yazılım prototipi geliştirilmiştir.

Bu raporda, Bölüm 2’de detaylı literatür özeti verilerek araştırmamızın katkıları önceki çalışmalar ile ilişkilendirilmiştir. Bölüm 3’te aşırı parlak, karanlık ve bulanık imgelerin ayıklanması için önerilen yöntemler ve deney sonuçları, Bölüm 4’te hayvansız imgelerin elenmesi için önerilen yöntemler ve deney sonuçları, Bölüm 5’te ise belirli bir hayvan türünün tespiti için önerilen yöntemler ve deney sonuçları aktarılmıştır. Geliştirilen yazılım prototipi Bölüm 6’da tanıtılmış, Bölüm 7’de ise proje çalışmalarından elde edilen sonuçlar özetlenmiştir.

## 2. Literatür Özeti

Doğada alınan görüntülerde otomatik hayvan tespit ve sınıflandırmasına ilişkin çalışmaları incelediğimizde, bu konuda kapsamlı bir çalışma Boom vd. [3] tarafından yapılmıştır. Sualtı video kameraları ile kaydedilen bir video veriseti oluşturulmuş, hareketli nesnelerin arkaplandan ayrılması sonucu elde edilen bölgelerde renk, şekil, doku ve momentlerin dahil olduğu çok sayıda öznitelik ile balık sınıflandırması yapılmıştır. Tür ayırt etmeye yönelik başka çalışmalara baktığımızda, [4]'te görüntülenecek hayvanların arkasına mavi bez çekilerek fotoğraflar toplandığını ve [5]'te müze veritabanından fotoğraflar kullanıldığını, dolayısıyla canlıların arkaplandan kolayca ayırt edildiğini görüyoruz.

Doğa araştırmacılarının işini azaltmaya yönelik bir araştırma Song ve Xu [6] tarafından yapılmıştır. Bu çalışmada çok sayıda video içerisinde kuş tespiti yapılmış, böylece uzmanların sadece kuş içermeye potansiyeli yüksek videoları izlemeleri sağlanmıştır. Standart Kalman filtresi, daha iyi kuş takibi için kuşun karenin neresinde ve hangi hızda olabileceği ile ilgili kısıtları hesaba katacak şekilde uyarlanmıştır. Benzer bir hedefle Weinstein [7], doğada kaydedilmiş videolardan hareketli nesnelere tespit edip, ilgili kareleri kullanıcıya veren bir sistem önermiştir.

Fotokapan fotoğraflarından tür ayırt eden bir çalışmada 18 tür içeren 7000 fotoğraflık bir veriseti kullanılmıştır [12]. SIFT, LBP gibi öznitelikler ve SVM sınıflandırıcı kullanılmış %82'lik bir başarı elde edilmiştir. Chen vd. [9] fotokapan fotoğraflarından tür ayırt etmeyi ilk defa Evrişimli Yapay Sinir Ağları (EYSA) ile denemiş, Missouri Üniversitesi'nin 19 hayvan sınıfı içeren verisetini kullanmıştır. Aslında EYSA'ların potansiyeli daha yüksek olmakla birlikte 2014'te yapıldığından sadece %38 başarı gözlenmiştir. 2017 yılında Gomez-Villa vd. [10] yine EYSA ile ama bu sefer daha büyük bir veriseti (Snapshot Serengeti, 26 sınıf, 780 bin fotoğraf) ile çalışarak farklı EYSA mimarilerini test etmişler, başarının %60'lara kadar çıktığını rapor etmişlerdir. Serengeti verisetinde başka bir çalışma Norouzzadeh vd. [8] tarafından yapılmış ve EYSA modelleri baştan eğitilmiştir. ResNet-152 ile sınıflandırma başarısında %92'ye çıkmıştır. Bu çalışmada aynı zamanda hayvanlı-hayvansız fotoğraf ayrımı da çalışılmış, %96 doğruluğa ulaşıldığı (eğer resimlerin en emin olunan %73'ü için karar verilirse doğruluğun %99.7'ye çıktığı) rapor edilmiştir. Bu sistemin insan vaktini kazanmak için kullanılabileceği belirtilmiştir. Yine 2017'de ama bu sefer 3 ila 6 sınıf içeren başka bir çalışmada [11] EYSA ile %90'a yakın sınıflandırma başarısı %95 de hayvanlı-hayvansız sınıflandırma doğruluğu elde edilmiştir.

Bizim çalışmamızın bulanık, aşırı parlak ve aşırı karanlık fotoğraf eleme sonrasındaki kısmı literatürdeki hayvanlı-hayvansız fotoğraf ayırt etme ile ilişkilendirilebilir. Orman Bakanlığı'ndan elde edilen ve literatürdeki örneklere göre daha zorlayıcı verisetleri ile çalıştık. Sonuçlarını daha sonra detaylı aktaracağımız üzere hayvanlı-hayvansız imge ayırt



etme görevinde veride eğitim ve test sahneleri karıştırılmadığında ResNet [24] imge sınıflandırma ile sadece %80 başarı sağlanmıştır. İmge sınıflandırma değil de Faster R-CNN [22] ile hayvan bulma ve içerisinde hayvan tespit edilmeyen fotoğrafları elemek suretiyle başarıyı %90'a çıkardık. Ayrıca sadece EYSA ile elde edilen bu başarıyı arka plan çıkarımı ile daha da yukarıya çekebilen bir yöntem önerdik. Birleşik yöntemde hayvanlı fotoğrafları korumada %99 doğruluğa ulaşılmıştır. Bunun yanında elenmesi gereken fotoğrafların yarısından fazlası elenmiştir. Bildiğimiz kadarıyla çalışmamız fotokapan fotoğrafları elemek için EYSA ile arkaplan çıkarımını birleştiren ilk çalışmadır.

Projemizde hayvan içermeyen fotoğrafların elenmesinin yanısıra belirli tür ayırt etmek için de özgün bir yöntem geliştirilmiştir. Önerdiğimiz yöntemde imgeden nesneye ait bölgelerden alınan parçalar (pozitif örnekler) ve nesneye ait olmayan bölgelerden alınan parçalar (negatif örnekler) ile model eğitilmiştir. Bu parça tabanlı yöntemin, Faster R-CNN'e göre özellikle gövdesinde ayırt edici desene sahip hayvanlar için daha yüksek başarı gösterdiği görülmüştür.

### 3. Aşırı Parlak, Aşırı Karanlık ve Bulanık İmgelerin Elenmesi

#### 3.1. Aşırı Parlak ve Aşırı Karanlık İmgeler için Eleme Yöntemi

Aşırı parlak ve aşırı karanlık imgelerin ayıklanmasında histogram bazlı bir analiz kullanılmıştır. Aşırı parlak ve karanlık imgeleri elerken yanlış-eksi tespitleri (hayvan içerdiği halde elenen fotoğraflar) azaltmak için parçalı parlak ve parçalı karanlık imgeler kullanışsız olarak nitelendirilmemiştir. Şekil 2'de karanlık, aydınlık ve kullanılabilir olarak nitelendirilen imgelere örnek verilmiştir.



(a)



(b)

Şekil 2. Parlak (a) ve karanlık (b) imge örnekleri. Sol sütunda kullanılamaz olarak nitelendirilen imgeler yer alırken sağ tarafta kullanılabilir durumda imgeler yer almaktadır.

Hesaplamalar yapılırken gri tonlamalı imgelerin histogram bilgilerinden faydalanılır. Karanlık ve parlaklık ölçülürken kullanılan parametreler olan  $p_k$  karanlık piksel oranını ve  $p_p$  parlak piksel oranını temsil eder. Denklem (1)'de bu oranların hesaplamaları ifade edilmiştir.

$$p_k = \left( \frac{\sum_{i=0}^{n_k} hist(i)}{\sum_{i=0}^{255} hist(i)} \right)^2 \quad p_p = \left( \frac{\sum_{i=n_p}^{255} hist(i)}{\sum_{i=0}^{255} hist(i)} \right)^2 \quad (1)$$

$n_k$  karanlık bir pikseli ifade etmek için üst sınır,  $n_p$  ise parlak bir pikseli ifade etmek için alt sınır olup [0-255] aralığındadır. Yapılan denemeler sonucunda çalışmamızda maksimum kazanımı sağlayan eşik değerleri kullanılmıştır.  $n_k$  değeri 20,  $n_p$  değeri 220 olarak alınmıştır.  $p_k$  ve  $p_p$  için eşik değerleri ise sırasıyla 0.94 ve 0.84 olarak kullanılmıştır.

### 3.2. Bulanık İmgelerin Elenmesi için Yöntem


Son 25 yılda imgelerde bulanıklık tespiti için birçok yöntem önerilmiştir. Pavlovic ve Tekalp [13], bulanıklığı tespit etmek için uzamsal alanda maksimum olabilirlik yöntemine başvurmuştur. Narvekar ve Karam [14] aynı amaçla kümülatif olasılık ölçütü oluşturup, öznel puanlamalarda keskinlik ölçütlerine göre daha başarılı sonuçlar elde etmiştir. Tong vd. [15] ise kenar biçimlerine ve keskinliklerine dayalı dalgacık dönüşümü kullanarak bulanıklık tespiti yapmıştır. Yaygınca kullanılan yöntemlerden birisi de Fourier Dönüşümüdür. Fourier Dönüşümü sonrası elde edilen frekans haritasının merkezinde düşük frekanslı değişkenler yer tutarken merkezden uzaklaştıkça yüksek frekanslar yer alır. Bulanık imgelerde pikseller arası değişim oldukça düşük olacağı için merkezde düşük frekansların oluşturduğu bir yoğunluk görülecektir. Dosselmann ve Yang [16] Fourier dönüşüm imgelerine merkezi imge merkezi olmak üzere daireler oturtmuş ve bu daireleri kümülatif dağıtım fonksiyonuna sokarak elde edilen normalize değer ile bulanıklık tespiti yapmıştır.

Bulanık ve net olarak nitelenen iki imge Şekil 3a'da, aynı imgelerin Fourier dönüşüm imgeleri de Şekil 3b'de yer almaktadır. Önerdiğimiz sistemde [16]'da anlatılan yöntem esas alınarak bulanık imgeler elenmiştir. Fourier dönüşüm imgelerine, merkezi imge merkezi olmak üzere önceden belirlenmiş sayıda ve aralıklarla daireler oturtulur. Dairelerin oluşturduğu dilimlerin içerisinde yer alan piksellerin değerleri toplanarak kaydedilir. Daha sonra toplanan değerler kümülatif dağıtım fonksiyonuna sokulur. Fonksiyon sonrası her dairenin aldığı değerler grafik üzerinde bir eğride gösterilir (Şekil 3c'de örnekleri olduğu gibi). Grafiğe frekans dağılımının eşit olduğu bir imgeyi temsil eden varsayımsal bir doğru eklenir. Her daire için eğrinin değerinden varsayımsal doğrunun değeri çıkarılır. Bu farkların toplamı varsayımsal doğrunun değer toplamlarına bölünerek  $\phi$  değeri elde edilir.  $\phi$  değeri belirlenen eşik değerinin altında kalan imgeler bulanık kabul edilir.

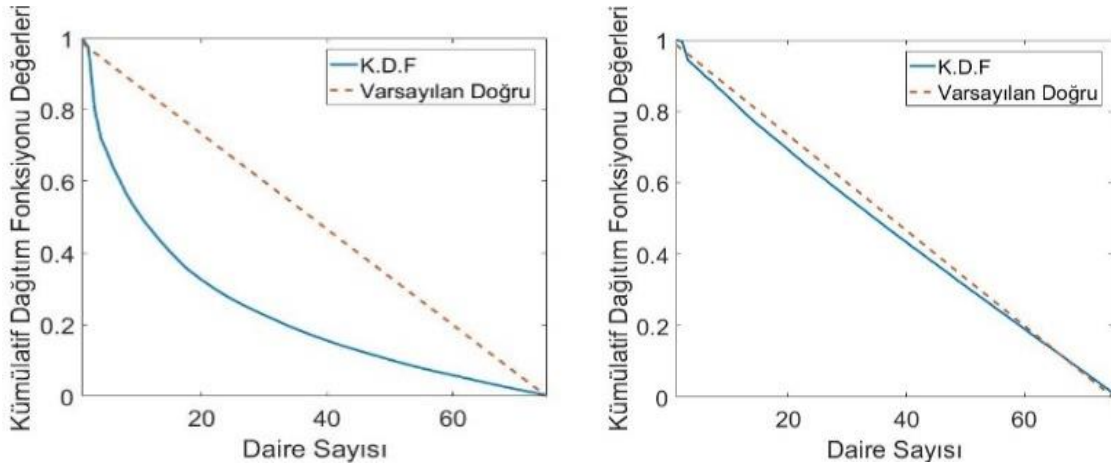
Kullanışsız imgeleri mümkün olduğunca elerken yanlış-eksi tespitleri en aza indirmek istemekteyiz. Bulanık ve net imgelerin yanısıra fotokapan verisi incelerken karşılaştığımız ve parçalı bulanık olarak sınıflandırdığımız imgelerin (örnek Şekil 4'te verilmiştir) bulanık olmayan kısımlarında hayvan tespit edilebileceği için bu imgelerin elenmemesi gerekir. Yukarıdaki algoritmada parçalı bulanık imgeler için bir eşik değeri vermek mümkün olmadığından, algoritmada bir takım değişiklikler yapılmıştır.



(a)



(b)



(c)

Şekil 3. Bulanık ve net olarak nitelendirilen imgeler ve bu imgelerin frekans haritaları ile kümülatif dağıtım değerleri. Sol tarafta bulanık imgenin verileri, sağda ise net imgenin verileri yer almaktadır. a) Orijinal imgeler. b) Soldaki imgede merkezde yoğunlaşma bulanıklığa işaret eder. c) Soldaki grafikte varsayılan doğru ve eğrinin arasında kalan büyük alan bulanıklığa işaret eder.

İmgeler önceden belirlenmiş sayıda alt-imgeye ayrılır. Her alt-imge kendi içerisinde bulanıklık testine girdikten sonra, pozitif sonuç veren alt-imge sayısı toplam alt-imge sayısına bölünür. Bulanıklık yüzdesi olarak da adlandırabileceğimiz bu değer için atanan eşik değerine üzerine çıkan imgeler bulanık olarak nitelendirilirken, eşik değerinin altında kalan imgeler sıradaki işlemler için kullanılabilir özelliği kazanır. Deneylerde imgeler 16 alt-imgeye ayrılmış ve 12'den fazla alt-imagesi bulanık özelliği gösteren imgeler bulanık olarak ayırt edilmiştir. İşleme sokulan alt-imagelerin boyutları küçük olduğundan tüm imgede 120 olarak kullanılan daire sayısı 35'e indirilmiştir. Daireler arasındaki mesafe 1 piksel olarak ayarlanmıştır. Tüm imgede  $\phi$  için eşik değeri -0.035 olarak kullanılırken, alt-imgede -0.030 olarak kullanılmıştır.



Şekil 4. Örnek bir parçalı bulanık imge. Sistem tarafından elenmemesi gerekir çünkü hayvan türü açıkça ayırt edilebilmektedir.

### 3.3. Deneyler

T.C. Orman ve Su İşleri Bakanlığı'ndan elde edilen fotokapan imgeleri taranarak, müdahale edilmemiş (ham) klasörlerden veriseti oluşturuldu. 40000'e yakın imgeden bir kısmı 'bulanık', 'aşırı karanlık', 'aşırı parlak' ve 'hayvan içeren' etiketleriyle etiketlendi. Etiketlenen imgelerden deneylerde kullanılacak test grupları hazırlandı. Deneylere başlamadan imgelerin üst ve alt kısmında yer alıp kamera bilgileri içeren başlıklar bulanık tespit yöntemi için kullanılan frekans haritasında, karanlık ve parlaklık tespiti için kullanılan histogramlarda ve önplan nesne tespiti için yapılacak morfolojik işlemlerde parazit oluşturduğu için imgeler kırıldı.

Aşırı karanlık ve aşırı parlak imgelerin tespiti için 1017 karanlık, 7 parlak ve 2250 kullanışlı imgeden oluşan veriseti hazırlandı. Veriseti hazırlanırken karanlık ve parlak sınırında olan

imgelerin seçilmesine özen gösterildi. Kullanılan örnek sayısı ve sınıflandırma başarısı Tablo 1’de verilmiştir. Karanlık imge örneklerinden 1006’sı karanlık olarak nitelendirilmiş, 11 imge yanlış artı sonuç vermiştir. Parlak ve kullanışlı imgelerde ise hatalı sonuç alınmamıştır.

Bulanık imge tespiti için 692 imgelik veriseti hazırlandı. Bunların içinden 186 imge bulanık özellikleri, 181 imge parçalı bulanık özellikleri gösterirken, kalan 325 imge bulanıklık özellikleri göstermemektedir. Geliştirilen yöntemin sınıflandırma başarısı Tablo 2’de verilmiştir. Bulanık imgelerde 186 imgenin 175’i bulanık olarak nitelendirilirken %94.1’lik bir başarı yakalanmış, net imgelerde bu başarı 325 örnek arasında %100 olarak gözlemlenmiştir. Bu sayede net fotoğrafların hiç biri elenmeden, bulanık fotoğrafların %94’ü elenerek araştırmacıların gözle inceleyeceği fotoğraf sayısında azalma sağlanmıştır. Fakat, kullanışlı olarak nitelendirilmesi gereken (hayvan gözlenebilecek) parçalı bulanık imgelerde 181 imge arasında 20 fire verilmiştir.

Tablo 1. Karanlık ve parlak imge deneylerinin hata matrisi

Sınıflar		Tahmin Edilen Sınıf		
		Karanlık	Parlak	Uygun
Gerçek Sınıf	Karanlık(1017)	1006	0	11
	Parlak(7)	0	7	0
	Kullanışlı(2250)	0	0	2250

Tablo 2. Bulanık imge veriseti ile yapılan deneyin hata matrisi

Sınıflar	Örnek Sayısı	Tespit Edilen Sınıflar		Başarı Yüzdesi
		Bulanık	Net	
<b>Bulanık</b>	186	175	11	%94.1
<b>Net</b>	325	0	325	%100
<b>Parçalı Bulanık</b>	181	20	161	%88.9



## 4. Hayvan İçermeyen İmgelerin Elenmesi

### 4.1. Derin Öğrenme ile Hayvanlı İmgelerin Tespiti

Evrişimli Yapay Sinir Ağları (EYSA), özellikle Alexnet [19], ILSVRC [20] yarışmasının imge sınıflandırma kategorisinde birinci gelmesinden itibaren bilgisayarla görüde pek çok amaç için etkin bir şekilde kullanılmaktadır. Nesne tespiti için geliştirilmiş birçok EYSA yaklaşımı bulunmaktadır. Bunlardan bazıları: OverFeat [21], Faster R-CNN [22] ve YOLO [23]'dur. OverFeat modelinde, EYSA önce sınıflandırıcı olarak eğitilmiş, nesne kayan pencere yaklaşımı ile aranmış, ardından sınıflandırıcı katmanı kaldırılıp yerine bağlanım (regression) katmanı eklenerek bulunan nesnenin tam konumu (kapsayan kutusu) kestirilmiştir. Faster R-CNN modelinde ise, nesne barındırabilecek potansiyel konumlar son evrişim katmanı üzerinden kayan pencere yaklaşımı ile otomatik olarak önerilmiş ve önerilen konumlar içinde nesne aranmıştır. Bu şekilde önemli bir hız artışı sağlanmıştır. Daha sonrasında önerilen YOLO ise hem nesnelik potansiyeli tespitini hem de sınıflandırmayı aynı EYSA içinde yaparak gerçek zamanlı kullanımı hedefler.


Çalışmamızda Faster R-CNN'i herhangi bir hayvan bulduğunda pozitif sonuç verecek şekilde (arkaplan ve hayvan olmak üzere iki sınıflı) eğiterek kullandık. Faster R-CNN, evrişimsel katmanların üzerine eklenen ve birisi alan önerilerinde bulunan, diğeri ise bu öneriler üzerinde sınıflandırma yapan iki başlıktan oluşur (Şekil 5). Bu iki başlık son evrişimsel katmanı ortak olarak kullanır. Alan öneri ağı, paylaşılan son evrişimsel katman üzerinde kayan pencere yaklaşımı uygulayarak, her imge için farklı boyutlarda ve farklı ölçeklerde yaklaşık 20000 alan önerisinde bulunur ve bu alanlara nesnelik skoru atar. Daha sonra 20000 sayısını düşürmek için bu alanlar üzerinde örtüşen alanlardan düşük skorluların elenmesi (non-maximum supression) ve skor eşik değerleri uygular. 300'e kadar indirilen öneri sayısı, sınıflandırıcı başlığa gönderilir. Sınıflandırıcı başlık bu öneriler üzerinde sınıflandırma ve kapsayan kutu bağlanımı (bounding-box regression) yaparak en son konum tahmininde bulunur.

Faster R-CNN'i kullanma nedenlerimizden biri kaynak kodların rahatlıkla ulaşılabilir ve geniş dokümantasyonu oluşudur. Daha önemli bir faktör ise verisetimizin zorlayıcı olması ve genel amaçlı imge sınıflandırıcıların çok iyi sonuç elde edememesidir. Bunun nedeni arkaplanların resimde önemli miktarda yer kaplaması ve imge sınıflandırıcıların arkaplanı ezberlemeye meyilli hale gelmesidir. Tablo 3'te sahneleri karıştırılmış ve sahneleri karıştırılmamış şeklinde iki fotokapan veriseti üzerindeki sonuçlar ile Faster R-CNN [22] ve başarılı bir imge sınıflandırıcı olan ResNet [24] birbiriyle karşılaştırılmıştır. Sahneleri karıştırılmış verisetinde, eğitim ve test kümelerinde ortak sahneler olduğundan ResNet aynı

arkaplan için hayvanlı ve hayvansız imgeleri ayırt etmeyi çok iyi öğrenmiştir (%95.6 doğruluk). Bu sonuçla, önerdiğimiz Faster R-CNN ile nesne öğrenme yaklaşımın daha başarılı görünmektedir. Fakat eğitim ve test kümelerinde sahneler karıştırılmadığında, yani tıpatıp aynı arkaplanları görmediğinde, ResNet karşılaştığı arkaplanlarda nesneli imgeleri iyi ayırt edemez hale gelmiştir. Başarı %80.7'ye gerilemiştir. Gerçek hayat koşullarında ikinci durumdaki gibi yeni fotokapalardan farklı arkaplanlar gelecektir.

Tablo 3. Faster R-CNN ve ResNet yapılarının Orman Bakanlığı veriseti üzerindeki doğrulukları (elenen ve korunan imgelerin ortalama yüzdeleri).

	Faster R-CNN doğruluk oranı	ResNet doğruluk oranı
Eğitim ve test sahneleri karışmış veriseti	94.3 %	95.6 %
Eğitim ve test sahneleri karışmamış veriseti	90.3 %	80.7 %




Şekil 5. Faster R-CNN yapısı [22].

## 4.2. Arkaplan Çıkarımı ile Hayvanlı İmgelerin Tespiti

Arkaplan çıkarımı için [17]'de karşılaştırılan yöntemlerden biri olan Gaussian Karışım Modeli [18] seçilmiştir. Her piksel koordinatı için 'arkaplan' Gauss dağılımları olarak modellenir, bu dağılımlara yeterince dahil olmayan piksel değerleri önplan nesnesi olarak kabul edilir. İki-modlu arkaplanlarla uyumlu çalışabilmesi bu seçimde etkili olmuştur. Arkaplan çıkarımı sonrası elde edilen imgeler bir dizi morfolojik işlemden geçirilir. Morfolojik işleme maruz kalmış imgeler bağlantılı bileşen algoritmasıyla önplanı ifade eden bileşenlere ayrılır ve bileşenlerin alanları hesaplanır. Eşik değerin üzerinde alana sahip bileşenler önplan nesnelere olarak tanınır. Şekil 6a'da başarılı şekilde nesne niteliği kazanan bir bileşen görülmektedir.

Arkaplan çıkarma algoritmaları genellikle saniyede yüksek sayıda imge içeren videolar üzerinde çalışır, yani değişim miktarı bir önceki kareye göre oldukça az olan imgeler için tasarlanmıştır. Sistemimizdeki hedef, aynı fotokapandan değişen zamanlarda alınan imgeler üzerinde arkaplan çıkarımı yapmaktır. İki imge arasında süre az olduğu halde ışık değişiminin çok olduğu ve süre çok olduğu halde ışık şartlarının benzer olduğu (ayrı günlerin aynı saatinde alınmış fotoğraflar gibi) örnekler mevcuttur. İmgeleri bir video dizisi gibi görüp, aralarındaki farklılık en az iken işleme sokmak gereklidir. Bu amaçla tasarladığımız algoritma aşağıda açıklanmıştır.



(a)




(b)

Şekil 6. Ham verisetinde ardarda arkaplan çıkarma işlemine giren iki imge (her satırın solunda). Sağdaki imgeler önplan imgesini göstermektedir. (b) imgesi (a) imgesinden hemen sonra işleme girdiği için arkaplan öğrenme işlemi gerçekleşmemiş, imgede nesne yer almamasına rağmen (a)'ya göre neredeyse tüm piksellerde değişim olduğundan hatalı sonuç alınmıştır. Önerdiğimiz imge gruplama algoritması ile bu hata giderilmektedir.

Öncelikle, piksel değerlerine bakılarak imgeler arasında benzerlik metriği oluşturulur. İki imge arasında benzerlik ölçülürken piksel bazında karşılaştırma yapılır. Eğer değer farkları, deneyler sonucu belirlenen eşik değerinin altında ise fark yok, üzerindeyse fark var kabul edilir. Fark yok kabul edilen piksel sayısının toplam piksel sayısına oranı benzerlik metriğini ifade eder. İlk imge için en benzer imge bulunduktan sonra, ikinci sıraya konur. Daha sonra bu işlem her yeni gelen imge için tekrarlanır. Bu şekilde sıralanan imgeler arkaplan çıkarımında daha yüksek performans göstermektedir. İmgeler sıralanmaz ise yaşanan bir problem Şekil 6b'de gözlenebilir.

Sıralanan imgeler, ayrıca ışık şartlarının çok değiştiği (benzerliğin düştüğü) yerlerden ayrılarak kümelendir. Gece çekilen imgeler genellikle tek bir küme altında toplanırken, gündüz çekilen imgelerin birkaç farklı küme altında toplandığı gözlemlenmiştir (Şekil 7). Sonrasında ise her kümeye kendi içlerinde arkaplan çıkarma yöntemi uygulanır. Diğer bir deyişle, öğrenilen arkaplan modeli küme değiştiğinde unutulur.



Şekil 7. Sıralanan imgelerin arkaplan sahnesine göre oluşturdukları kümeler. Sol üstten başlayarak 1., 5., 13. ve 25. imgelerde yeni kümeler başlamıştır.

### 4.3. Deneyler

T.C. Orman ve Su İşleri Bakanlığı'ndan elde edilen yaklaşık 40000 imge taranarak, müdahale edilmemiş (ham) klasörlerden (fotokapanlardan) veriseti oluşturuldu. Hayvan içeren imgelerde, hayvanlar kutu içerisine alındı ve Pascal VOC formatında etiketler elde edildi. Eğitim setinin, mümkün olduğunca çok sayıda hayvan, çok sayıda ışıklandırma biçimi ve çok sayıda poz içermesine, kısmen imge içerisine giren hayvanlara yer verilmesine ve farklı arkaplana sahip sahnelerden oluşmasına dikkat edildi.

Çalışmamızda hangi hayvan içerdiğine bakmaksızın hayvanlı imgelerin tutulması diğer imgelerin ise elenmesi hedeflendiğinden EYSA eğitimi sırasında verisetindeki tüm hayvan içeren kutular tek bir pozitif sınıf altında etiketlenmiştir. Bazı hayvanların çok az görülmesi ve eğitim kümesinde bulunan bir hayvan bilgisinin bulunmayan başka bir hayvanı bulmak için işe yarayabilecek olması açısından da tek sınıf etiketleme uygundur. Negatif örnekler (arkaplan) ise aynı imgelerin hayvan içermeyen bölümlerinden otomatik olarak elde edilmiştir. Toplam 930 eğitim imgesi kullanılmıştır.

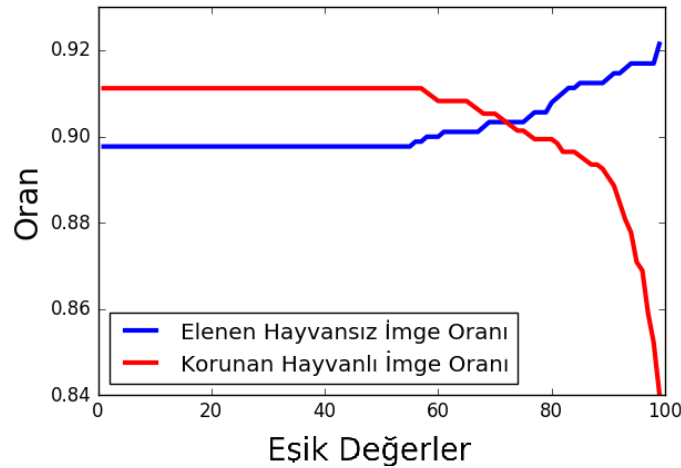
Test için yine mümkün olduğunca çeşitli hayvan ve ışıklandırma biçimi barındırmaya dikkat ederek yaklaşık 2000 imge içeren bir veriseti oluşturuldu. Derin öğrenme algoritması fotokapanın gördüğü arkaplanı da öğrendiğinden test setinde eğitim setinde kullanılan bir fotokapandan hiç fotoğraf kullanılmadı. Test seti, yüksek oranda hayvan içeren test grubu ve düşük oranda hayvan içeren test grubu olarak ikiye ayrıldı. Bu ayrımın sebebi, her bir fotokapan verisinin bu iki karakterden birine uyduğunun gözlenmesidir. Deneylerde yer alan Veriseti 1 düşük sayıda hayvan içeren imge barındırırken, Veriseti 2 yüksek sayıda hayvan içeren imge barındırmaktadır. Başarı, hayvan içeren imgelerin korunma ve hayvan içermeyen imgelerin elenme oranı ile ölçülmüştür. Sırasıyla, derin öğrenme ile, arkaplan çıkarımı ile ve birleşik yöntem ile deney sonuçları aşağıda aktarılmıştır.

#### 4.3.1. Derin Öğrenme ile Hayvanlı İmge Tespiti Deneyleri

Eğitilen EYSA'nın test seti üzerindeki sonuçları Şekil 8'de gösterildiği üzere farklı eşik değerleri ile grafiğe dökülmüştür. Nesnelik skoru eşik değerinin altında olan kutular elenecek şekilde hayvansız imgelerde 'elenme oranı' ve hayvanlı imgelerde 'korunma oranı' görülmektedir. Amaç, her iki oranın da 1.0 olmasıdır. Eşik değer 0.5 olana kadar grafikte bir değişiklik gözlenmemesinin nedeni, hayvan olma olasılığı 0.5'ten düşük kutuların zaten arkaplan olarak sınıflandırılmasıdır. Buradan hareketle, eşik değeri 0.5 seçilerek tüm test seti için derin öğrenme deney sonuçları Tablo 4'e aktarılmıştır. Sonuçların tablo ile verilmesi aynı zamanda arkaplan çıkarımı yöntemi ile karşılaştırmayı sağlamaktadır.

Orman Bakanlığı veriseti ile eğittiğimiz modelin genelleştirme başarısı ölçmek için başka bir fotokapan veriseti olan Missouri Üniversitesi veriseti [9] ile test ettik. Bu verisetinde 18 hayvan türü ve insan yer almaktadır. Gerek verisetinde arkaplan sahnelerinin farklılaşması gerekse farklı türde hayvanlar yer alması nedeniyle eğitilen model aynı başarıyı sağlayamamış, Tablo 5'te görüldüğü üzere hem elenen hem korunan imge yüzdesi düşmüştür.

Başka bir deneyimizde hem eğitim hem test için Orman Bakanlığı ve Missouri verisetleri beraber kullanılmıştır. Tablo 6'da verilen sonuçlarda elenen ve korunan imge yüzdeleri (tek bir EYSA satırı) Tablo 4'e göre biraz düşüktür. Verisetleri karışık kullanıldığında, sadece bir veriseti (Orman Bak.) kullanıldığı duruma göre öğrenme azalmıştır. EYSA'ların topluluk öğrenmesi ile birleştirildiğindeki başarıyı da ölçtük. Eğitim setinin farklı %70'lik bölümleri ile eğitilen dört ayrı Faster R-CNN modeli test imgeleri için ayrı ayrı çalıştırılmıştır. Topluluk öğrenme stratejisi olarak ağırlıksız ortalama kullanılmış, yani her bir modelin ürettiği sonuçların ortalaması alınarak sınıflandırma yapılmıştır. Verinin hepsini kullanan tek bir EYSA'nın başarısı ile topluluk öğrenmesi başarısı Tablo 6'da verilmiştir. Doğruluk yüzdesinde topluluk öğrenmede ufak da olsa bir ilerleme kaydedilmiştir.



Şekil 8. Farklı eşik değerleri için derin öğrenme deney sonuçları

Tablo 4. Derin Öğrenme ile Elenen ve Korunan İmge Oranları

Verisetleri	Hayvan İçeren İmge Sayısı	Hayvan İçermeyen İmge Sayısı	Elenen Hayvansız İmge Yüzdesi	Korunan Hayvanlı İmge Yüzdesi
Veriseti 1	76	631	90.8	51.3
Veriseti 2	941	307	86.9	94.1
TOPLAM	1015	938	89.5	91.1

Tablo 5. Orman Bakanlığı veriseti ile eğitilen modelin Missouri Üniversitesi veriseti üzerindeki başarısı

Hayvan İçeren İmge Sayısı	Hayvan İçermeyen İmge Sayısı	Elenen Hayvansız İmge Yüzdesi	Korunan Hayvanlı İmge Yüzdesi
886	588	68.3	81.9

Tablo 6. Tek bir EYSA başarısı ile topluluk öğrenmesi (dört EYSA) başarısının karşılaştırılması

Yöntem	İmge sayısı		Başarı yüzdesi		
	Hayvanlı	Hayvansız	Elenen	Korunan	Doğruluk
Topluluk öğrenmesi (dört EYSA)	1743	976	89.5	87.6	88.3
Tek bir EYSA			83.6	89.7	87.5



(a)



(b)

Şekil 9. Derin öğrenme yaklaşımı ile doğru tespit edilen hayvanlar (a)'da yer alırken, (b)'de sol imgede su birikintisi önünde bulunan domuz arkaplan dokusuna benzediği için ayırt edilmemiş, (b)'de sağdaki imgede ise hayvan dokusuna benzer dokudaki taşlar ve ağaçlar etiketlenmiştir.

Derin öğrenme (Faster R-CNN ile nesne öğrenme), %90 dolayında elenme ve korunma oranı gibi iyi sonuçlar (Tablo 4) verse de deneyler sırasında farkedilen bir eksiklik, kayalık arazide bulunan taşlar için yanlış alarmlar vermesi, yahut ağaçlık ve taşlık dokuya benzer dokuda hayvanları arkaplan nesnesi olarak nitelendirmesidir. Bu yanlışlar arkaplan çıkarımı tabanlı yöntem ile giderilebileceği değerlendirilmiştir. Arkaplan çıkarımındaki değişim ölçen nitelik, arkaplanda yer almayan ve ağaçsı dokuya sahip bir hayvanı yine de ayırt edecektir. Aynı şekilde arkaplanda yer alan kayalıkları, sahnede değişim olmadığından hayvan olarak nitelemeyecektir. Şekil 9'da bu durumların birer örneği verilmiştir.

#### **4.3.2. Arkaplan Çıkarımı ile Hayvanlı İmge Tespiti Deneyleri**

Bölüm 4.2'de anlatıldığı üzere önerdiğimiz ışık değişimlerine göre imge gruplama yöntemi ve arkasından Gaussian Karışım Modeli ile arkaplan modellemesi sonucu hayvan olduğu tespit edilen imgelerle Tablo 7'teki sonuçlar alınmıştır. Korunan hayvanlı imge sayısı derin öğrenme yöntemine yakın çıkarken elenen hayvansız imge oranı gerilemiştir.

Bu sonuçlar sadece Orman Bakanlığı veriseti ile elde edilmiştir çünkü o veriseti fotoğrafların fotokapandan toplandığı şekliyle elimizdedir. Missouri veriseti ise münferit fotoğraflardan oluştuğundan arkaplan çıkarımına dayalı teknik uygulanamaz.

Tablo 7. Arkaplan Çıkarımı Yöntemi ile Elenen ve Korunan İmge Oranları

<b>Verisetleri</b>	<b>Hayvan İçeren İmge Sayısı</b>	<b>Hayvan İçermeyen İmge Sayısı</b>	<b>Elenen Hayvansız İmge Yüzdesi</b>	<b>Korunan Hayvanlı İmge Yüzdesi</b>
<b>Veriseti 1</b>	76	631	60.6	75
<b>Veriseti 2</b>	941	307	46.9	91.9
<b>TOPLAM</b>	1015	938	56.1	90.8

#### **4.3.3. Birleşik Yöntem ile Hayvanlı İmge Tespiti Deneyleri**

Arkaplan çıkarımı yönteminin sonuçları, derin öğrenme deney sonuçlarına göre daha başarısız görünmekle beraber, yapılan hatalar farklı imgelerde olabileceğinden her iki yöntemin sonuçlarını karar aşamasında birleştirdiğimiz üçüncü bir deney gerçekleştirdik. Her iki yöntemin de eksi sonuç verdiği imgeler elenirken, herhangi bir yöntemin hayvan var demesi imgenin korunması için yeterli kılındı. Böylece iki yöntemin kendi içerisinde kaçırdığı hayvanlı imgeler kaçırılmamış oldu. Bu durum elenen hayvansız imge sayısında düşmeye



sebeptir, ancak elenen imge oranı %54.5 iken korunan hayvanlı imge oranı olarak %99.1'e ulaşıldı. Orman Bakanlığı veriseti ile elde edilen sonuçlar Tablo 8'de verilmiştir.

Tablo 8. Birleşik Yöntem ile Elenen ve Korunan İmge Oranları

Verisetleri	Hayvan İçeren İmge Sayısı	Hayvan İçermeyen İmge Sayısı	Elenen Hayvansız İmge Yüzdesi	Korunan Hayvanlı İmge Yüzdesi
Veriseti 1	76	631	60	89.4
Veriseti 2	941	307	43.3	99.9
TOPLAM	1015	938	54.5	99.1

Çalışmamızda derin öğrenme ve arkaplan çıkarımı tabanlı yöntemlerle ham fotokapan verisetinde hayvan içeren tüm imgeleri korurken araştırmacılarının bakacakları hayvansız imgeleri mümkün olduğunca elemeye çalıştık. Birleşik yöntemimiz ile 1015 hayvanlı imge %99.1 oranında doğru etiketlenirken, hayvansız 938 imgede %54.5 oranında elenme sağlanmıştır (Tablo 8). Hayvan içeren verisetinde kaçırılan %1'lik dilimi incelediğimizde kaçırılan hayvanların komşu fotoğraflarda (fotokapan hareket devam ettiği sürece fotoğraf çektiğinden) görüldüğünü fark ettik. Bu durumda deney sonucu olarak hiçbir hayvan bireyi kaçırılmadan 500 dolayında hayvansız fotoğrafın elendiği söylenebilir. Bu sonuç, araştırmacıların gözle inceleme zorunluluğunu olan fotoğraf sayısında önemli bir düşüş sağlanabileceğini göstermektedir.

## 5. İmgelerde Belirli Hayvanların Tespiti

### 5.1 Motivasyon

Evrişimli yapay sinir ağları (EYSA) bir derin öğrenme yöntemi olarak son yıllarda bilgisayarlı görü problemleri başta olmak üzere kendini ispatlamıştır. Bölüm 4'te EYSA'ları imgeler içerisinde hayvan bulmak için kullandık, fakat hayvan türünün hangisi olduğu ile ilgilenmedik. Bu bölümde ise EYSA'ların belirli bir hayvan türünü bulmak için nasıl kullanılabileceğini irdeleyip, yeni geliştirdiğimiz bir yöntemi tanıtacağız. Önerdiğimiz yöntemde imgeden nesneye ait bölgelerden alınan parçalar (pozitif örnekler) ve nesneye ait olmayan bölgelerden alınan parçalar (negatif örnekler) ile model eğitilmiştir. Bu parça tabanlı yöntemin, güncel nesne bulma yöntemlerinden biri olan Faster R-CNN'e göre özellikle gövdesinde ayırt edici desene sahip hayvanlar için daha yüksek başarı gösterdiği görülmüştür. Ayrıca parça tabanlı yöntemin Faster R-CNN ile beraber kullanılıp performansının yukarı taşınabileceği de gösterilmiştir.

Bölüm 4.1'de ayrıntıları ile anlatıldığı üzere Faster R-CNN [22], hedef nesne olma potansiyeli yüksek bölgeleri ayrı bir yapay sinir ağı ile tespit ederek sadece bu bölgeler için sınıflandırma ve kapsayan kutu bağlanımı (bounding box regression) yapar. Gerçek zamanlı çalışmaya uygun hale getirmek üzere son yıllarda yapılan çalışmalar hem nesnelik potansiyelini hem de sınıflandırmayı aynı EYSA içerisinde yapan yöntemler doğurmuştur (ör: You Only Look Once (YOLO) [23]). Hız artsa da başarı pek yukarıya taşınamamıştır.

Faster R-CNN, YOLO ve benzeri nesne tespit yöntemleri, resimde nesnenin tamamını arayacak şekilde eğitilmektedir. Her ne kadar gürbüzlük sağlamak için nesnelerin kısmen görüldüğü durumlardan eğitim setine örnekler kalsa da nesnenin tamamı görüldüğünde iyi skor üretecek şekilde eğitilmektedir. Diğer yandan, bazı nesnelerin kendine özgü desenleri önemli bir ipucudur. Bu ipucunu değerlendirmek adına, nesnenin fotoğraflarıyla değil, nesnenin gövdesinden alınan parçalarla eğittiğimiz bir sistem üzerinde durduk. Projemize de uygun olarak, örnek çalışmalarımızı belirli hayvan türlerini ayırt etme üzerine gerçekleştirdik.

### 5.2 Yöntem

Öncelikle, çoklu nesne sınıflandırma için derin bir EYSA (50-katmanlı bir ResNet [24]) eğittik. Leopar, zebra, fil ve ayı olmak üzere dört hayvan sınıfı belirlenmiştir. Fil ve ayı, leopar ve zebralarda olduğu gibi belirgin bir vücut deseni içermez. Sınıflandırma performansında düşüş olup olmayacağını gözlemlemek amacıyla eğitilen sınıflar arasına konmuştur.

Daha önce belirttiğimiz gibi EYSA'mız hayvan sınıflarına ait parçalarla eğitilmiştir. Her sınıf için yaklaşık 1000 parça kullanılmıştır. Parça (yama) resim boyutu 64x64 pikseldir

(Şekil 10'da bazı örnekler verilmiştir). Arkaplan sınıfına ait parçalar da (eğitim için) yine aynı resimlerin hedef nesnelere içermeyen yerlerinden alınmıştır.

Bir test imgesinde nesne aranırken 64x64 piksel boyutunda pencereler ile ve kayan pencereler yaklaşımı ile tüm konumlar ziyaret edilir. Kayma miktarı 32 piksel alınmıştır. Her bir pencere parçalarıyla eğitilmiş EYSA'ya verilir ve sınıflandırma sonucu (her sınıf için olasılık olarak) alınır. Her bir sınıf için tüm konumların olasılıkları bir sıcaklık haritasına aktarılır. Örnek bir sıcaklık haritası Şekil 11b'de verilmiştir. Kırmızı renk en yüksek skoru ifade etmektedir ve o konumun toplam 1.0 olasılıkla hedef hayvana ait olduğunu gösterir. Mavi ise yine aynı hayvan için en düşük olasılığı ifade eder. Alınabilecek en yüksek skor 4'tür çünkü 32x32 piksellik bir alanda en çok 4 ayrı 64x64'lük pencere üst üste gelebilir. Hesaplamalarımız geri kalanında [0-4] aralığı [0-1] aralığına normalize edilerek kullanılmıştır. Şekil 12'de başka hayvanlar için de sıcaklık haritası örnekleri (her hayvanın kendi sınıfı için sıcaklık haritası) verilmiştir. Görüldüğü üzere, hedef hayvana ait neredeyse tüm alanlar yüksek olasılıklarla kaplanmıştır.

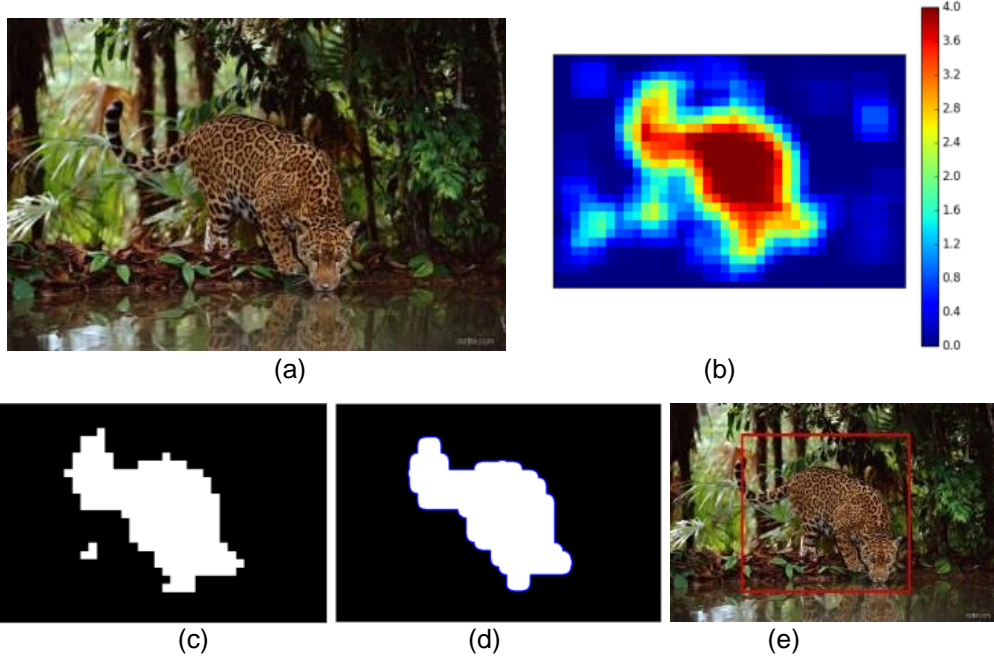
Yöntemimizde bir nesne etrafına kapsayan kutu çizebilmek için sıcaklık haritası belirli eşik değerleri kullanılarak ikili imgeye çevrilir. Ardından, çok küçük buluntuları elemek ve yakın parçaları birleştirmek için morfolojik işlemler uygulanır. İşlem adımları Şekil 11c ve Şekil 11e arasında görsellenmiştir.

Nesne tespit algoritmalarının başarılarını değerlendirmek için literatürde sıkça kullanılan bir yöntem kesinlik-anma (precision-recall) eğrileri çizmektir. Tespit edilen bir nesne kutusu, eğer doğru sınıflandırılmış ise ve fotoğrafta elle etiketlenen gerçek kutu ile örtüşme oranı (Denklemler 2) belirli bir eşik değerinden yüksekse, doğru-artı (true-positive) olarak işaretlenir. Literatürde örtüşme oranı için genellikle 0.5 eşik değeri kullanılmaktadır.


$$\text{Örtüşme oranı} = \frac{Kutu_{tespit} \cap Kutu_{etiket}}{Kutu_{tespit} \cup Kutu_{etiket}} \quad (2)$$




Şekil 10. Parça tabanlı eğitim yöntemi için eğitim setinden bazı örnekler. Soldan sağa, leopar (iki tane), zebra, fil ve ayı örnekleri.



Şekil 11. Kapsayan kutuların tahminleme. (a) Bir girdi imge, (b) leopar sınıfı için imgenin sıcaklık haritası, (c) sıcaklık haritasına eşikleme yapılması ile elde edilen ikili imge, (d) morfolojik işlemler sonrası sonuç, (e) tahmin edilen kapsayan kutu.



Şekil 12. Girdi imge örnekleri üst satırda, önerilen parça tabanlı yöntem ile elde edilen sıcaklık haritaları ise alt satırda verilmiştir.



Şekil 13. a) Girdi imge, b) Elde edilen sıcaklık haritası, c) Eşik değeri = 0.3 iken tahmin edilen kapsayan kutu, d) Eşik değeri = 0.9 iken tahmin edilen kapsayan kutu.


Diğer nesne tespit yöntemlerinin aksine, önerdiğimiz parça tabanlı yöntemde kapsayan kutuların büyüklüğü tercih edilen eşik değeri ile orantılı olarak değişmektedir. Düşük eşik değerleri için üretilen kutular büyük, yüksek eşik değerleri için üretilen kutular ise küçüktür. Şekil 13'te eşik değeri arttıkça kapsayan kutuların küçülmesi görsellenmiştir. Yüksek eşik değeri ile saptanan küçük kapsayan kutunun doğruluğu çok yüksektir, ancak Denklem 2'de verilen örtüşme oranına göre bir yanlış-artı (false-positive) üretmektedir. Bu durum, artan eşik değeri ile beraber kesinlik ve anma değerlerinin aynı anda düşmesine neden olur ki bu da önerdiğimiz yöntemin performansını kesinlik-anma eğrisiyle ölçmekten bizi alıkoyar. Daha uygun olduğu için, Denklem 3'te verilen alan-kesinlik (area-precision,  $P_{AR}$ ) ve alan-anma (area-recall,  $R_{AR}$ ) değerlendirme ölçütlerini kullandık [25].

$$P_{AR}(G, D) = \frac{\sum_j \text{Alan}(G \cap D_j)}{\sum_j \text{Alan}(D_j)}, \quad R_{AR}(G, D) = \frac{\sum_j \text{Alan}(G \cap D_j)}{\text{Alan}(G)} \quad (3)$$


Burada  $G$  etiketlenen gerçek bir kutuyu,  $D$  ise tespit edilen kutu listesini gösterir,  $j = 1, \dots, |D|$ .  $P_{AR}$  (alan-kesinlik) tespit edilen kutuların alanlarının ne kadarının gerçek kutular ile örtüştüğünü,  $R_{AR}$  (alan-anma) ise gerçek kutunun alanının ne kadarının tespit kutuları ile örtüştüğünü gösterir.

### 5.3 Deneyleler

Kendi yöntemimizle kıyasladığımız Faster R-CNN, ImageNet ([www.image-net.org](http://www.image-net.org)) verisetinden alınan 446 ayı, 351 fil, 400 leopar ve 450 zebra imgesi ile eğitilmiştir. Parça tabanlı yöntem ise sınıf başına sadece 50 imgeden elde edilen 1000 kadar parça ile eğitilmiştir. Test kümesi her sınıf için 62 imge içerecek şekilde oluşturulmuştur, her imgede hedef sınıfa ait bir hayvan vardır. Test kümesi üzerindeki alan-kesinlik / alan-anma eğrileri Şekil 14'te sunulmuştur. Leopar ve zebra sınıfı için parça tabanlı yöntemin Faster R-CNN'den daha başarılı olduğu açıkça görülmektedir. Fil sınıfı için de benzer bir durum söz konusudur. Fakat ayı sınıfı için (Şekil 14d), parça tabanlı yöntem sadece alan-anma değeri 0.4 ve üzeri için galip gelmiştir. Başarımdaki bu düşüş ağırlıklı olarak ayı sınıfına ait parçaların çimen gibi bazı arkaplan sınıfı parçaları ile karıştırılmasından kaynaklanmaktadır. Parça tabanlı yöntem tarafından kötü tahminlenen bir ayı örneği Şekil 15'te gösterilmiştir. Özellikle hayvanın arka tarafındaki bazı bölgeler arkaplan sıcaklık haritasında da yüksek sayılabilecek değerlere ulaşmıştır. Baş bölgesinde ise bazı alanların fil sınıfı için yüksek skor aldığı görülmektedir. Bu durum, ayı içeren söz konusu yerlerde ayı için elde edilen skorları (olasılıkları) düşürmektedir.



Şekil 14. Faster R-CNN ve parça tabanlı yöntemi kıyaslamak üzere a) leopar, b) zebra, c) fil ve d) ayı sınıfları için çizilmiş alan-kesinlik (area-precision) / area-recall (alan-anma) eğrileri. Eğrinin daha yukarıda olması başarının yüksekliğini gösterir.



Şekil 15. Parça tabanlı yöntem tarafından kötü tahminlenen bir ayı örneği. a) Girdi imge. Sırasıyla b) arkaplan, c) ayı, d) fil, e) leopar ve f) zebra sınıfları için sıcaklık haritaları

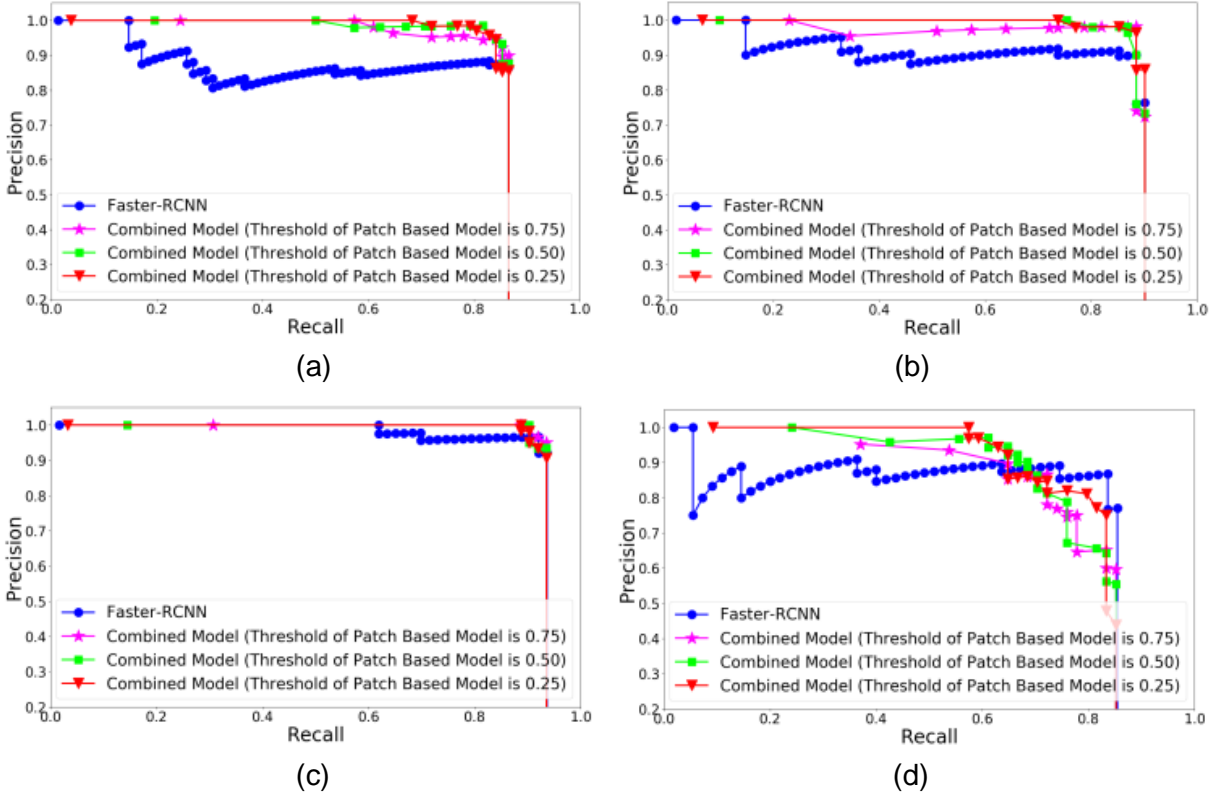
Başka bir deneyde ise önerdiğimiz parça tabanlı yöntemin, Faster R-CNN'in bireysel başarımını artırıp artıramayacağını inceledik. Birleşik model (combined model) dediğimiz bu yaklaşımda, eğer parça tabanlı yöntemin ürettiği kutu ile çakışıyorsa, bir Faster R-CNN kutusunun skoru aşağıdaki denklem kullanılarak artırılmıştır.

$$P_{FasterRCNN_j} = \frac{P_{FasterRCNN_j} + PatchCont_j}{2}$$

Burada,  $P_{FasterRCNN}$  Faster R-CNN tarafından tahminlenen kutuların skorlarını temsil eder.  $PatchCont_j$  ise parça tabanlı yöntemle elde edilen  $n$  tane kutunun  $j$ 'inci Faster R-CNN kutusuna katkısıdır ve şu şekilde hesaplanır:

$$PatchCont_j = \frac{\sum_{i=1}^n Area(PatchBasedBox_i \cap FasterRCNN_j)}{\sum_{i=1}^n Area(PatchBasedBox_i)}$$

Bu deneyde, Faster R-CNN kutularının skorları parça tabanlı yöntem katkısı ile güncellendiği için başarımların kıyaslaması kesinlik-anma eğrileri ile yapıldı. Parça tabanlı modeldeki skor eşik değeri 1.0 üzerinden 0.25, 0.50 ve 0.75 olacak üç ayrı değer için deneyler tekrarlanmıştır.



Şekil 16. Faster R-CNN ve Birleşik Modeli karşılaştırdığımız kesinlik/anma (precision/recall) eğrileri. a) leopar, b) zebra, c) fil, d) ayı sınıfları. Eğrinin daha yukarıda olması başarımın yüksekliğini gösterir.

Şekil 16 göstermektedir ki leopar, zebra ve fil sınıfları için, Birleşik Model Faster R-CNN'den iyi sonuçlar vermiştir. Ayı sınıfı için ise (Şekil 16d), eğri altındaki alanı karşılaştırdığımızda, sadece 0.25 eşik değerli Birleşik Model Faster R-CNN'e üstünlük sağlamıştır.

Deney sonuçlarını değerlendirdiğimizde parça tabanlı yöntemin nesne bulmadaki performansının özellikle belirgin desene sahip hayvanlar için oldukça iyi olduğunu söyleyebiliriz. Diğer sınıflar için (örneğin bu çalışmadaki ayı sınıfı) başarı düşmektedir ancak bu sınıflar için bile Faster R-CNN gibi başarılı bir yöntemin başarısını yukarıya çekebilecek şekilde uygulanabilir. Bu iyileşmenin nedeni, öğrenilen desenler resimde belirgin olduğunda parça tabanlı yöntemin bu alanları çok iyi konumlandırmasıdır. Bu sebeple Faster R-CNN dışındaki başka başarılı nesne tespit yöntemlerine de (ör: YOLO) benzer derecede katkı yapması beklenir. Önerilen yöntemin bir avantajı da eğitim için oldukça az sayıda imgeye ihtiyaç duymasındır (ör: Faster R-CNN'deki 450 yerine sadece 50 zebra imgesi kullanıldı). Bu durum özellikle kısıtlı verisetleri için ayrıca fayda sağlayabilir.

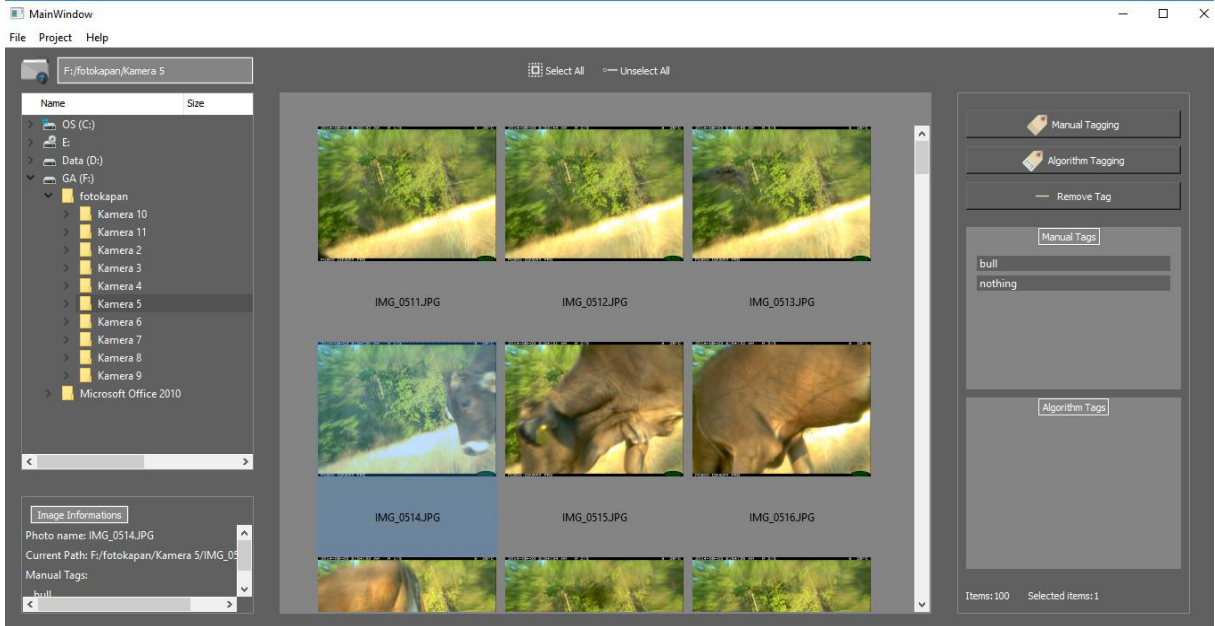


## 6. Prototip Yazılım

Geliştirilen yöntemlerin fotokapan verisetleri üzerine uygulanmasını sağlayan bir prototip yazılım geliştirilmiştir. Bu aslında son kullanıcının, yani fotoğraflarını elemek isteyen doğa araştırmacısının kullanacağı bir arayüzdür. Bir yazılım geliştirme sürecine uygun olarak öncelikle fonksiyonel ve fonksiyonel olmayan yazılım gereksinimleri belirlenmiş, kullanıcı senaryoları (use-case) oluşturulmuş, veri modeli belirlenmiştir. Bunun ardından arayüz tasarımı ve gerçekleştirilmesi yapılmıştır. Geldiğimiz noktada, arayüzü Şekil 17’de görülen prototip mevcuttur. Program,

- istenen klasörün ve klasörden istenen fotoğrafların seçilmesine olanak vermektedir,
- fotoğrafın içerdiği hayvanların ve fotoğrafın diğer özelliklerinin (ör: aşırı parlak) kullanıcı tarafından elle etiketlemesine olanak vermektedir,
- etiketlerine göre tarama yapıp (belirli bir hayvan içeren fotoğraflar gibi) veritabanından çekilebilmektedir,
- istenen bir algoritmanın sonuçlarına göre otomatik etiketleme yapabilmektedir.

Fotokapan verisetleri için kullanılan diğer programlardan farkı algoritmaların fotoğraflar üzerinde yapacağı elemelere olanak sağlamasıdır. Örneğin aşırı parlak fotoğraflar veya bulanık fotoğraflar algoritma tarafından seçilip otomatik etiketlenmektedir. Orman Bakanlığı çalışanları ve temasta olunan diğer doğa araştırmacılarından kullanıcı arayüzü ile ilgili geri bildirimler alınacak ve olanak olduğu ölçüde geliştirilerek kullanışlı bir yazılım elde edilecektir.



Şekil 17: Prototip yazılımın arayüzünden bir örnek görüntü. Solda klasör organizasyonu, merkezde ise imgelerin görülmesine ve seçilmesine olanak sağlayan pencere mevcuttur. Sağ bölümde ise otomatik (algoritmik) etiketleme için butonlar ve elle konulan ve otomatik konulan etiketleri görebildiğimiz pencereler mevcuttur.

## 7. Sonuçlar

Projemizde fotokapan görüntülerinin elden geçirilmesi ve içinde hayvan olup olmadığının ve hangi hayvan olduğunun tespit edilmesi için gerekli insan işgücünü azaltmak üzere bu tespitleri otomatik yapacak bilgisayarlı görü yöntemleri geliştirilmiştir.

Öncelikle aşırı parlak, karanlık ve bulanık fotoğrafların elenmesi için etkili teknikler araştırılmıştır. Aşırı parlak ve aşırı karanlık imgelerin ayıklanmasında histogram tabanlı bir analiz kullanılmıştır. Bulanık imgeler ise Fourier dönüşüm imgelerine yüksek frekansların oranına dayalı bir yöntem ile tespit edilmiştir. Bu aşamalarda kullanışlı fotoğrafları yanlışlıkla elememeye dikkat edecek şekilde eşik değerleri seçilmiştir. Bunun yanında elenmesi gereken ama elenemeyen fotoğraf oranı %1-%5 arasında değişmektedir.

Aşırı parlak, karanlık ve bulanık fotoğrafların elenmesinden sonraki hedef hayvan içermeyen fotoğrafların elenmesidir. Bunun için hem arkaplan çıkarımı ile nesne tespiti hem de evrişimli yapay sinir ağları (EYSA) ile nesne bulma tekniklerini bir arada kullanan bir sistem önerdik. EYSA'ları imge sınıflandırma için eğitmek yerine türden bağımsız hayvan bulmak üzerine eğiterek hayvansız imgeleri eleme başarısı %90'a çıkardık. Ayrıca sadece EYSA ile elde edilen bu başarıyı arka plan çıkarımı ile daha da yukarıya çekebilen bir yöntem önerdik. Birleşik yöntemde hayvanlı fotoğrafları korumada %99 doğruluğa ulaşılmıştır. Kaçırılan fotoğraftaki hayvanın da devam eden fotoğrafta yakalandığı görülmüştür. Bunun yanında elenmesi gereken fotoğrafların yarısından fazlası elenmiştir. Son tahlilde, geliştirilen sistemin herhangi bir hayvanı kaçırmadan %50'den büyük bir başarı ile kullanışsız fotoğrafları eleyebildiğini söylenebilir.

Projemizde ayrıca belirli bir hayvan türü ayırt etmek için de özgün bir yöntem geliştirilmiştir. Bu yöntemde imgeden nesneye ait bölgelerden alınan parçalar (pozitif örnekler) ve nesneye ait olmayan bölgelerden alınan parçalar (negatif örnekler) ile model eğitilmiştir. Bu parça tabanlı yöntemin, özellikle gövdesinde ayırt edici desene sahip hayvanlar için Faster R-CNN'e göre daha yüksek başarı gösterdiği görülmüştür, sonuçlar raporlanmıştır.

Son olarak, geliştirilen eleme ve hayvan bulma yöntemlerin nasıl bir arayüz ile kullanıcıya aktarılması gerektiği ile ilgili de araştırma yapılmış, bir yazılım prototipi geliştirilmiştir.

Proje çıktıları ile ilgili olarak, Bölüm 4'te anlatılan çalışmalar SIU 2018'de sunulmuştur. Özellikle derin öğrenme için yapılan ilave deneyler ve Bölüm 3 çalışmaları ile birleştirilerek hazırlanan makalemiz TJEECS'e (Turkish Journal of Electrical Engineering and Computer Sciences) gönderilmek üzere hazırlanmış, raporun ekinde sunulmuştur. Bölüm 5'teki çalışmalarımızın ise öncül sonuçları SIU 2017'de sunulmuş, son gelinen nokta ise IET Electronics Letters dergisinde basılmıştır.



Oxford Üniversitesi'nden elde edilen özellikle leopar içeren veriseti ile ilgili de belirli hayvan türlerinin tespitine yönelik deneyler yapılmakta olup yakın gelecekte ortak bir yayın çıkarılması hedeflenmektedir.

Raporda bahsedildiği üzere Orman Bakanlığı Doğa Koruma ve Milli Parklar Genel Müdürlüğü arşivinde bulunan değişik zamanlarda çeşitli bölgelerden elde edilmiş fotokapan verisi kullanılmıştır. Söz konusu veri üzerinde çalışılırken çok sayıda fotoğraf, içerisinde hayvan olup olmadığı, varsa hangi hayvan olduğu ve fotoğrafın tam olarak neresinde yer aldığı bilgisi ile etiketlenmiştir. Bu bilgi bizim gibi fotoğraflarda otomatik nesne bulma üzerinde bilimsel araştırma yapan insanlar için değerli olduğundan etiketli fotoğrafları dünyadaki diğer araştırmacılarla paylaşmak için Orman Bakanlığı'ndan izin talep edilmiştir. Yazışması devam etmekle beraber sözlü onay alınmıştır. Yazılı onayı takiben veri, çalışma grubumuzun web sitesinde (<http://cvrg.iyte.edu.tr>) paylaşılacaktır.



## Referanslar

- [1] Krishnappa Y. S. and Turner W. C. 2014. "Software for minimalistic data management in large camera trap studies", *Ecological Informatics*, 24.
- [2] Fegraus E.H., Lin K., Ahumada J.A., Baru C., Chandara S., Youn C. 2011. "Data acquisition and management software for camera trap data: A case study from the TEAM network", *Ecological Informatics*, 6(6).
- [3] Boom, B., He, J., Palazzo, S. et al. 2014. "A research tool for long-term and continuous analysis of fish assemblage in coral-reefs using underwater camera footage", *Ecological Informatics*.
- [4] Dunn, M., Billingsley, J., Finch, N. 2003. "Machine vision classification of animals," *IEEE International Conference on Mechatronics and Machine Vision in Practice*.
- [5] Serna, A.H., Segura, L.F.J. 2014. "Automatic identification of species with neural networks", *PeerJ*, DOI: 10.7717/peerj.563.
- [6] Song, D., Xu, Y. 2010. "A Low False-Negative Filter for Detecting Rare Bird Species from Short Video Segments using a Probable Observation Data Set-based EKF Method", *IEEE Transactions on Image Processing* 19(9).
- [7] Weinstein, B.G. 2015. "MotionMeerkat: integrating motion video detection and ecological monitoring", *Methods in Ecology and Evolution* 2015, 6.
- [8] Norouzzadeh, M.S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M., Packer, C., Clune, J. 2017. "Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning", *arXiv:1703.05830*.
- [9] Chen, G., Han, T.X., He, Z., Kays, R. Forrester, T. 2014. "Deep convolutional neural network based species recognition for wild animal monitoring", *International Conference on Image Processing (ICIP)*.
- [10] Gomez-Villa, A., Salazar, A., Vargas, F. 2017. "Identification of animal species in camera-trap images using very deep convolutional neural networks", *Ecological Informatics* 41.
- [11] Nguyen, H., Maclagan S.J., Nguyen, T.D. et al. 2017. "Animal Recognition and Identification with Deep Convolutional Neural Networks for Automated Wildlife Monitoring", *International Conference on Data Science and Advanced Analytics*.
- [12] Yu, X., Wang, J., Kays, R. et al. 2013. "Automated identification of animal species in camera trap images", *Eurasip Journal on Image and Video Processing*, 2013:52.
- [13] Pavlovic G., Tekalp A.M. 1992. "Maximum likelihood parametric blur identification based on a continuous spatial domain model", *IEEE Trans. on Image Processing*, 1(4):496-504.

- [14] Narvekar N.D., Karam L.J. 2011. "A no-reference image blur metric based on cumulative probability of blur detection (CPBD)", *IEEE Trans. on Image Processing*, 20(9): 2678-2683.
- [15] Tong H., Li M., Zhang H., Zhang C. 2004. "Blur detection for digital images using wavelet transform", *IEEE International Conference on Multimedia and Expo*.
- [16] Dosselmann R. W., Yang X. D. 2012. "No-Reference Noise and Blur Detection via the Fourier Transform", *Technical Report*, University of Regina, Canada.
- [17] Sobral A. and Vacavant A. 2014. "A comprehensive review of background subtraction algorithms evaluated with synthetic and real videos", *Computer Vision and Image Understanding*, 122:4-21.
- [18] Zivkovic Z. 2004. "Improved adaptive Gaussian mixture model for background subtraction", *International Conference on Pattern Recognition*.
- [19] Krizhevsky, A., Sutskever, I. and Hinton, G.E. 2012. "Imagenet classification with deep convolutional neural networks". *Advances in Neural Information Processing Systems*, pp. 1097-1105.
- [20] Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M. and Berg, A.C. 2015. "Imagenet large scale visual recognition challenge". *Int. Journal of Computer Vision*, 115(3), pp.211-252.
- [21] Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R. and LeCun, Y. 2013. "Overfeat: Integrated recognition, localization and detection using convolutional networks". *arXiv preprint arXiv:1312.6229*.
- [22] Ren, S., He, K., Girshick, R. and Sun, J. 2015. "Faster R-CNN: Towards realtime object detection with region proposal networks". In *Advances in Neural Information Processing Systems*, pp. 91-99.
- [23] Redmon, J., Divvala, S., Girshick, R., Farhadi, A. 2016. "You Only Look Once: Unified, Real-Time Object Detection". *IEEE Conf. on Computer Vision and Pattern Recognition*.
- [24] He, K., Zhang, X., Ren, S., Sun, J. 2016. "Deep residual learning for image recognition", In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- [25] Wolf, C., Jolion, J.M. 2006. "Object count/area graphs for the evaluation of object detection and segmentation algorithms", *International Journal of Document Analysis and Recognition (IJ DAR)*, 8(4), pp. 280–296.

**TÜBİTAK**  
**PROJE ÖZET BİLGİ FORMU**

Proje Yürütücüsü:	Doç. Dr. YALIN BAŞTANLAR
Proje No:	115E918
Proje Başlığı:	Fotokapan Fotoğraflarında Bazı Hayvan Türlerinin Tespiti
Proje Türü:	1001 - Araştırma
Proje Süresi:	24
Araştırmacılar:	
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	İZMİR YÜKSEK TEKNOLOJİ ENS. MÜHENDİSLİK F. BİLGİSAYAR MÜHENDİSLİĞİ
Projenin Başlangıç ve Bitiş Tarihleri:	01/04/2016 - 01/04/2018
Onaylanan Bütçe:	248934.0
Harcanan Bütçe:	145019.33
Öz:	<p>Fotokapanlar doğada vahşi hayvanları gözlemlemek için kurulan hareket sensörlü kameralardır. Gelişen teknolojilerle birlikte fotokapan kullanımı ve dolayısıyla sahadan toplanan imge sayısı belirgin bir şekilde artmıştır. Tüm fotokapan görüntülerinin elden geçirilmesi ve içinde hayvan olup olmadığının ve hangi hayvan olduğunun tespit edilmesi için gerekli işgücü de orantılı olarak artmaktadır. Çalışmamızda amaç, bu tespitleri otomatik yaparak doğa araştırmacılarına gözle kontrol etmeleri gereken çok daha az sayıda fotoğraf bırakmaktır. Bu amaç doğrultusunda öncelikle aşırı parlak, karanlık ve bulanık fotoğrafların elenmesi için etkili teknikler araştırılmıştır. Bu kullanışsız fotoğrafların elenmesinin ardından birinci hedef hayvan içeren fotoğrafların tespitidir. Çalışmamızda, bunun için hem arkaplan çıkarımı ile nesne tespiti (fotokapanlar değişmeyen arkaplanı bulunan sahneden değişen zaman aralıkları ile imge topladığından) hem de evrişimli yapay sinir ağları (EYSA) ile nesne bulma teknikleri bir arada kullanılarak hayvan içermeyen imgeleri ayıklayan bir sistem önerilmiştir. Bir diğer hedef de fotoğraflarda belirli bir hayvan türünün tespitidir. Bunun için de evrişimli yapay sinir ağlarını (EYSA) belirli bir hayvan türünü bulmak için eğitmek üzerine araştırma yapılmış, parça-tabanlı eğitime dayalı özgün bir yöntem önerilmiştir. Ayrıca, geliştirilen eleme ve hayvan bulma yöntemlerin nasıl bir arayüz ile kullanıcıya aktarılması gerektiği ile ilgili de araştırma yapılmış, bir yazılım prototipi geliştirilmiştir.</p>
Anahtar Kelimeler:	Görüntü işleme, örüntü tanıma, fotokapan, hayvan tespiti, derin öğrenme, evrişimli yapay sinir ağla
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır
Projeden Yapılan Yayınlar:	<ol style="list-style-type: none"><li>1- Effect of Patch Based Training on Object Localization with Convolutional Neural Networks (Bildiri - Ulusal Bildiri - Sözlü Sunum),</li><li>2- Detecting Photos with Leopards Using Convolutional Neural Networks (Bildiri - Uluslararası Bildiri - Sözlü Sunum),</li><li>3- Detecting Photos with Leopards Using Convolutional Neural Networks (Bildiri - Uluslararası Bildiri - Sözlü Sunum),</li><li>4- Training CNNs with image patches for object localisation (Makale - Diğer Hakemli Makale),</li><li>5- Detection of Images with Animals in Raw Camera-Trap Data (Bildiri - Ulusal Bildiri - Sözlü Sunum),</li></ol>