

Foto-kapan Görüntülerinde Hareketli Nesne Tespiti ve Konumunun Belirlenmesi

Emrah ŞİMŞEK^{1,2*}, Gülşah Tümüklü ÖZYER², Barış ÖZYER²

¹Recep Tayyip Erdoğan Üniversitesi, Mühendislik Fakültesi, Bilişim Sistemleri Müh. Rize/Türkiye

²Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Erzurum/Türkiye

Geliş / Received: 07/01/2019, Kabul / Accepted: 13/05/2019

Öz

Foto-kapanlar genellikle ormanlık arazide sabit noktaya yerleştirilmiş ve doğal yaşamı izlemek için kullanılan görüntüleme cihazlarıdır. Foto-kapanlar kullanılarak canlıların doğal yaşamı üzerinde araştırma yapmak amacıyla milyonlarca görüntü kaydedilmektedir. Kaydedilmiş görüntüler üzerinde bilgisayar tabanlı yöntemler ile canlıların tespit edilmesi ve tanınması amacıyla otomatik yöntemler geliştirilmektedir. Ayrıca foto-kapan görüntülerinde arka plan karmaşıklığı, arka planın hareketli olması, ışık şiddeti değişimi ve nesnenin parçalı olması gibi problemler hareketli nesne tespitini zorlaştırmaktadır. Literatürde bu amaçla yapılan çalışmalarda hareketli nesnelere ait model görüntüler görüntü içerisinden el ile tespit edilerek sınıflandırma tabanlı yöntemlerde ön bilgi olarak kullanılmaktadır. Nesnelere ait model görüntülerin el ile tespit edilmesi ve kırılması zor, zahmetli, zaman alan bir süreçtir ve yüksek iş yükü gerektirmektedir. Çalışmamızda bu iş yükünü azaltmak amacıyla doğal ortamdan elde edilmiş foto-kapan görüntülerinde nesnelere ait ön bilgi kullanılmadan hareketli nesnelere otomatik tespit edilmiş ve hareketli nesnelere ait görüntüdeki konumları belirlenmiştir. Önerilen yöntemde hareketli nesnelere ait tespit edilmesi için görüntüye arka plan çıkarma ve çerçeve farkı yöntemleri uygulanmıştır. Arka plan modelinin oluşturulması için Değişen Gauss Ortalama ve Gaussların Karışımı, görüntülerin azaltılması ve nesnelere belirginleştirilmesi amacıyla Gauss Bulanıklığı ve Medyan filtre, ön plan tespitindeki hataların giderilmesi için OTSU eşikleme kullanılmıştır. Foto-kapan veri setlerinde hareketli nesne tespit etme başarısı %83, nesne konumlandırma başarısı ise %80 olarak elde edilmiştir.

Anahtar Kelimeler: Hareketli Nesne Tespiti, Değişen Gauss Ortalama, Çerçeve Farkı, Foto-Kapan

Moving Object Detection and Localization in Camera-Trap Images

Abstract

Camera-traps are usually placed on a fixed point in a forest land and are used to monitor natural life. Millions of images are recorded to investigate the natural life of living things by using camera-traps. Computer based automatic methods are developed for detecting and identifying living things on recorded images. Also problems such as background complexity, moving background, change of light intensity and fragmentations of the object in camera-trap images make moving object detection difficult. In the literature, for this purpose the model images of moving objects obtained from manually are used as preliminary information in classification based methods. Detecting and cropping model images of the objects manually is a difficult, laborious, time-consuming process and requires high workload. In our study, To reduce this workload it was aimed to detect moving objects automatically and to determine the location of moving objects in camera-trap images that obtained from natural environment. In the proposed method for this purpose, background extraction and frame difference methods were applied to the images. Gaussian Average and Mixture of Gaussian were used to create a background model. Gaussian Blur and Median Filter were used to reduce noise and to clarify objects. .OTSU thresholding was used to eliminate the errors of foregrounds. In the camera-trap data sets, the success of detecting moving objects was 82% and the object localization success was 80%.

Keywords: Moving Object Detection, Running Gaussian Average, Frame Difference, Camera-Trap

1. Giriş

Son yıllarda foto-kapanların kullanılması ile hayvanlar üzerinde yapılan tür ve nüfus tespiti, sınıflandırma ve bölgesel çeşitlilik gibi çalışmalar hızla artmaktadır. Harekete duyarlı foto-kapanlar, sahip oldukları kameralar

sayesinde çok çeşitli hayvan türleri ile ilgili detaylı bilgi elde edilmesini sağlamaktadır. Foto-kapanlar, dikkat çekmemesi, düşük güç tüketimine sahip olması, doğru ve çeşitli veriler sunması nedeniyle hareketli nesne

izleme için uygundur (Kays vd., 2010). Yapılan çalışmalar ile canlıların tespit edilmesi, türlerin tanınması (Gonçalves vd., 2016; Gray vd., 2019; Hoebeke vd., 2018; Meek vd., 2013; Nguyen vd., 2017; Norouzzadeh vd., 2018; Willi vd., 2019; Yousif vd., 2019), vahşi hayvan tanıma (Andavarapu ve Vatsavayi, 2017), canlıların sayılması işlemleri, elde edilmiş çok sayıda foto-kapandan görüntüsü kullanılarak bilgisayarlı görme ve örüntü tanıma yöntemleri ile otomatikleştirilmeye çalışılmaktadır. Foto-kapanlar ilgili yapılan anket çalışmasında foto-kapanlarda önümüzdeki 10-20 yıl içerisinde olması istenen özellikler içerisinde nesne olmayan görüntülerin filtrelenmesi %54 ile üçüncü önemli konu başlığı olarak ifade edilirken, bu süreçte otomatik nesne tespiti bu istenen özellikler içerisinde ilk olarak gerçekleştirileceği düşünülmektedir (Glover vd., 2019).

Görüntüde nesne tespiti işlemi, nesnenin görüntüde bulunduğu konumun belirlenmesi olarak ifade edilebilmektedir (Chen vd., 2015). Eğer görüntüde aranacak nesne hakkında ön bilgi veya model görüntü var ise elde edilen görüntünün öznelikleri kullanılarak kayan pencere ve sınıflandırma tabanlı yöntemler ile nesne tespiti yapılabilmektedir (Andavarapu ve Vatsavayi, 2017; Wang, 2014; Zhang vd., 2016). Eğer aranan nesneye ait ön bilgi veya model görüntü yok ise, problem belirgin nesne tespiti yöntemleri ile çözülebilmektedir. Belirgin nesne tespitinde, nesneye ait renk, yoğunluk ve yönelim gibi öznelikleri kullanılarak belirginlik haritaları kullanılmaktadır (Sebastian ve Daniel, 2017). Eğer nesne tespiti birden fazla art arda çekilmiş görüntüde veya video üzerinde yapılacak ise problem hareketli nesne tespiti olarak düşünülür. Bu durumda nesne tespiti görüntüler arasındaki veya arka plandaki piksel yoğunluk farklarından yararlanılarak gerçekleştirilir (Kulchandani ve Dangarwala, 2015; Piccardi, 2004). Hareketli nesne

tespitinde temel amaç hareketli ön plan hedeflerinin tespit edilmesi ve takip edilmesidir (Sebastian ve Daniel, 2017). Video izleme, güvenlik, video sıkıştırma, otomatik hedef tespit ve takibi, aktivite tanıma gibi yaygın kullanım alanlarına sahip olmasından dolayı bilgisayarlı görme alanında önemli bir yere sahiptir. Literatürde bu amaçla kullanılan arka plan çıkarma, çerçeve farkı, geçici farklar, optik akış gibi yöntemler bulunmaktadır (Kulchandani ve Dangarwala, 2015).

Arka plan çıkarma, sabit kameralardan elde edilen videolarda hareketli nesnelere tespit etmek için yaygın olarak kullanılan bir yaklaşımdır. Arka plan çıkarma veya arka plan modeli oluşturma yöntemlerinde, geçici ardışık görüntüler kullanılarak etkili bir arka plan modelinin tahmin edilmesini amaçlamaktadır (Piccardi, 2004). Bu yöntemler, belirli sayıdaki görüntünün piksel değerlerinin Gauss olasılık yoğunluk fonksiyonu üzerine uydurulmasına (Değişen Gauss Ortalaması) (Running Gaussian Average) (Wren vd., 1997), piksellerin ortanca değerlerinin belirlenmesine (Geçici Medyan Filtre) (Temporal Median Filter) (Lo ve Valestin, 2001), piksellerin belirli bir zaman aralığındaki gözlemlenme olasılığına (Gaussların Karışımı) (Mixture of Gaussians) (Stauffer vd., 1999), piksel sayısının yeterli olmadığı durumlarda parametrik olmayan yöntemle tahmin edilmesine (Çekirdek Yoğunluk Tahmini) (Kernel Density Estimation (KDE) (Elgammal vd., 2000), komşu piksel bloklarının zamanla gösterdiği benzer değişimlere (Görüntü Çeşitlerinin Eş Oluşumu) (Co-Occurrence of Image Variations) (Seki vd., 2003) ve piksel blokları yerine bütününde öz değer ayrıştırması yapılmasına (Öz Değer Arka Planı) (Eigen Backgrounds) (Oliver ve ark., 2000) dayanmaktadır. Arka plan çıkarma yöntemlerinin, hareketli nesnenin tespit edilmesi ve takip edilmesi için en güvenilir yöntemler olduğu kabul edilmektedir

(Piccardi, 2004). Geleneksel arka plan çıkarma yöntemlerinin performansı temel olarak ışık şiddeti değişiklikleri, gölge varlığı ve dinamik arka plan nedeniyle azalmaktadır (Kulchandani ve Dangarwala, 2015).

Çerçeve Farkı, ardışık iki görüntü arasındaki farkı göz önüne alarak hareket eden nesnenin varlığını tanımlayan bir yöntemdir (Jain ve Nagel, 1979). Çerçeve farkı yöntemi, hareketli nesne tespiti için en temel yöntemlerden birisidir. Geleneksel yaklaşımda, ardışık görüntülerde ilk görüntü karesinden ikinci görüntü karesini çıkararak çıktı görüntüsünü elde eden görüntü çıkarma operatörünü kullanılmaktadır. Bu yöntemde, referans görüntü olan bir arka plan, cisme sahip olan görüntülerle karşılaştırılmaktadır. İki görüntünün piksellerinin farkı, hareketli nesnenin bulunduğu bölgeyi algılamak için kullanılmaktadır. Çerçeve farkı yöntemi, daha iyi sonuçlar elde etmek için genel olarak morfoloji operasyonlarının kullanıldığı bir nesnenin tam konturunu elde etmekten yoksundur (Jain ve Nagel, 1979).

Çerçeve farkı yöntemi uygulandıktan sonra konumlandırma probleminin çözülmesi gerekmektedir. Çerçeve farkı yönteminin sonuçları bize nesnelerin görüntüdeki konumları hakkında bilgi vermektedir. Literatürde, görüntülerdeki nesnelere konumlandırmaya ihtiyaç duymayan kayan pencere ve nesne tanıma tabanlı yöntemler de bulunmaktadır. Bu yöntemlerde, nesne varlığı görüntü tanıma yöntemleri ile görüntü içerisinde aranmaktadır. Bu tanıma aşaması süreç ve zaman kaybına neden olmaktadır. Bu çalışmada, nesnelerin yerel bölgelerdeki varlığını tespit etmek için çerçeve farkı yönteminden elde edilen sonuç görüntülerinde Kabarcık Analizi (Blob Analysis) ve kayan pencere tabanlı histogram hesaplama kullanılmıştır (Kulchandani ve Dangarwala, 2015; Piccardi, 2004).

Ardışık foto-kapan görüntülerinde hareketli nesne tespiti için, ışık şiddeti değişimi,

hareketli ve karmaşık arka plan bulunması gibi zorlukları bulunmaktadır. Hatalı arka plan hesaplanmasına neden olan ani ışık şiddeti değişimi probleminin çözülmesi için literatürde genellikle histogram eşitleme yöntemi kullanılmaktadır. Hareketli ve karmaşık arka planın neden olduğu görüntülerin giderilmesi için Gauss bulanıklaştırma ve medyan filtre kullanılmıştır. Gauss bulanıklaştırma ve medyan filtre ile geçişler yumuşatılmış ve nesnelere belirginleştirilmiştir. OTSU eşikleme yöntemi ile nesne bütünlüğü artırılmış, arka plan görüntülerinden ayrıştırılmış ve arka plan hareketinin neden olduğu hatalı tespit sorunu giderilmeye çalışılmıştır (Otsu, 1979).

Foto-kapan ile elde edilen görüntülerde karmaşık ve hareketli arka plan olması, ışık şiddeti değişiminin fazla olması ve hareketli nesnenin görüntülerde kısmi olarak bulunması problemi zorlaştırmaktadır (Kulchandani ve Dangarwala, 2015; Lin vd., 2014; Nguyen vd., 2017; Yu vd., 2013). Foto-kapan görüntülerinde yapılan çalışmalarda öncelikli amaç aranan nesnenin görüntüde olup olmadığının tespit edilmesidir. Yu ve arkadaşları, Andavarapu ve arkadaşları ve Buehler ve arkadaşlarının yaptığı (Andavarapu ve Vatsavayi, 2017; Buehler vd., 2019; Yu vd., 2013) çalışmalarda örnek görüntülere ait öznelikler kullanılarak, kayan pencere tabanlı yöntemlerle aranan nesne tespit edilmeye çalışılmıştır. Zhang ve arkadaşlarının yaptığı (Zhang vd., 2016) çalışmada arka plan ve ön plan olarak belirlenen görüntülerin öznelikleri ve çok katmanlı grafik kesim yöntemi kullanılarak her görüntü parçasının arka plan veya nesne olduğu tespit edilmiştir. Khorrami ve arkadaşlarının yaptığı (Khorrami vd., 2012) çalışmada Sağlam Temel Bileşen Analizi (RPCA-Robust Principal Component Analysis) ile arka planı çıkarılmış görüntülerde yerel entropi ve bağlı bileşen analizi yöntemleri ile nesne tespiti gerçekleştirilmiştir. Yapılan derin öğrenme

tabanlı (Gonçalves vd., 2016; Gray vd., 2019; Hoebeke vd., 2018; Nguyen vd., 2017; Norouzzadeh vd., 2018; Willi vd., 2019; Yousif vd., 2019) çalışmalarda ise tespit işlemi elle kırılmış görüntüler kullanılarak eğitilen sinir ağlarının kullanılması ile görüntülerde nesne tespit işlemi gerçekleştirilmiştir.

Foto-kapan görüntülerinde nesne tespit etme ve tanıma üzerine yapılan çalışmalarda, çoğunlukla kırpma işleminin elle yapıldığı model görüntüler ön bilgi olarak kullanılmaktadır (Andavarapu ve Vatsavayi, 2017; Gray vd., 2019; Hoebeke vd., 2018; Nguyen vd., 2017; Wang, 2014; Willi vd., 2019; Yousif vd., 2019; Yu vd., 2013). Bu çalışmalarda daha önceden kaydedilmiş foto-kapan görüntülerinden insanlar tarafından tespit edilmiş hayvan görüntüleri el ile kırılmaktadır. Kırılan bu model görüntüler öznelik çıkarma ve örüntü tanıma yöntemlerinde eğitim verisi olarak kullanılmaktadır (Buehler vd., 2019). Bu nesnelere otomatik olarak tespit edilmesi için sırasıyla tespit ve konumlandırma aşamalarının uygulanması gerekmektedir. Tespit aşamasında arka plan modeli oluşturulmakta ve her görüntünün arka plan modeli ile olan farktan hareketli nesnenin bulunup bulunmadığı belirlenmektedir. Devamında konumlandırma aşamasında ise hareketli nesnenin görüntü içerisinde bulunduğu konum ve boyutları belirlenmektedir (He vd., 2016; Lin vd., 2014).

Foto-kapan görüntüleri üzerinde yapılan çalışmalarda genellikle görüntünün her bir alt parçası, model nesne görüntülerinin öznelikleri kullanılarak arka plan, hayvan veya insan olarak sınıflandırılmaktadır (Buehler vd., 2019; Gray vd., 2019; Yousif vd., 2019;). Bazı derin öğrenme tabanlı yöntemlerin uygulandığı çalışmalarda ise nesnelere ait derin öznelikler çıkarılabildiği için çok sayıda model nesne görüntüsü kullanılarak çok sayıda hayvan türü tespit

edilmeye ve sınıflandırılmaya çalışılmaktadır (Andavarapu ve Vatsavayi, 2017; Gonçalves vd., 2016; Norouzzadeh vd., 2018; Willi vd., 2019; Zhang vd., 2016). Model görüntülerin kullanıldığı bazı çalışmalarda öncelikle el ile kırılmış nesne görüntülerinin yerel veya genel öznelikleri çıkarılmakta, nesnelere ait bu öznelikler sınıflandırma yöntemleri modellenmekte ve daha sonra görüntülerin her alt parçası sınıflandırılarak nesne olup olmadığı tespit edilmektedir (Andavarapu ve Vatsavayi, 2017; Gonçalves vd., 2016; Norouzzadeh vd., 2018; Willi vd., 2019; Zhang vd., 2016). Derin öğrenme tabanlı yöntemlerde ise model görüntüler tasarlanmış ağ mimarisinde belirlenen devir sayısınca eğitilmekte ve nesnelere ait derin öznelikler ile nesnelere modellenmektedir. Bu nesne modelleri ile görüntülerdeki alt parçalar sınıflandırılmakta ve nesnelere tespit edilmektedir (Norouzzadeh vd., 2018; Willi vd., 2019).

Foto-kapan görüntülerinde nesne tespiti yapılan çalışmalarda, farklı türdeki nesnelere model görüntülerinin tespit edilmesi, kırılması ve kaydedilmesi zor, zahmetli, zaman alan bir süreçtir ve çok fazla iş yükü gerektirmektedir (Buehler vd., 2019; Nguyen vd., 2017; Norouzzadeh vd., 2018). Ayrıca nesne tespit işleminin performansı, elle yapılan bu tespit etme ve kırpma işleminin miktarı ve başarısı ile sınırlanmaktadır. El ile yapılan tespit işleminde veri setinin küçük bir kısmı incelenmekte, tespit edilen türlere ait yetersiz model görüntü kaydedilmekte, bu nedenle bazı nesne türleri tespit edilememektedir (Buehler vd., 2019).

Çalışmamızda, foto-kapan üzerinde yapılan diğer çalışmalardan farklı olarak, aranan nesneye ait ön bilgi veya model görüntü kullanılmadan görüntülerde bulunan hareketli nesnelere otomatik olarak tespit edilmesi amaçlanmıştır. Çalışmamızda nesnelere varlığı öznelik tabanlı sınıflandırma yöntemleri veya belirginlik tespiti tabanlı yöntemler yerine hareket bilgisini gösteren

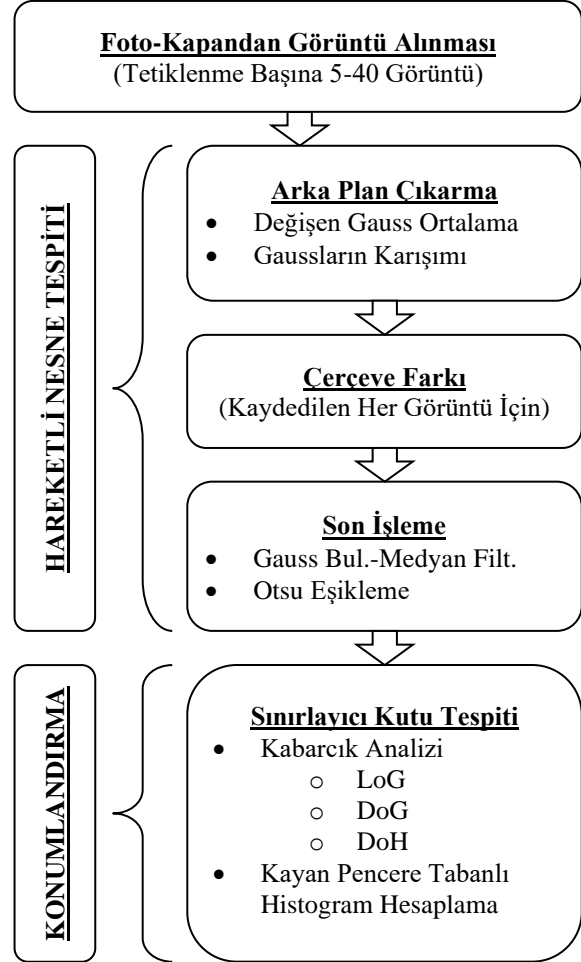
ardışık görüntülerdeki piksel yoğunluk değişimi incelenerek tespit edilmiş ve bu bilgi ile konumları ve boyutları belirlenmiştir. Model nesne görüntülerinin el ile tespit edildiği ve kırıldığı veya nesne bulunan görüntülerin el ile etiklendiği diğer çalışmalara kıyasla görüntülerde bulunan nesnelere daha az iş yükü ile tespit edilmesi sağlanmıştır. Ayrıca görüntü işlemede kullanılan histogram eşitleme, gauss bulanıklığı, medyan filtre gibi işlemler ile farklı arka plan çıkarma yöntemlerinin başarıya olan etkisi incelenmiştir.

Çalışmamızın 2. bölümünde sistemin genel yapısı, kullandığımız veri setleri, hareketli nesne tespiti için kullandığımız yöntemler ve tespit edilen hareketli nesnelere konumlandırılması için kullanılan yöntemler açıklanmıştır. 3. bölümde çalışmadaki hareketli nesne tespiti ve konumlandırma başarıları bulunmaktadır. 4. bölümde ise çalışmada elde edilen sonuçlar yorumlanmış ve daha sonra yapılması planlanan çalışmalar ifade edilmiştir.

2. Materyal ve Metot

Foto-kapan görüntülerinde hareketli nesnelere tespiti için önerdiğimiz sistem modeli Şekil-1 de gösterilmiştir. Foto-kapanlar hareket ile tetiklendiğinde saniyede 1 görüntü olmak üzere toplam en az 5 görüntü yakalamakta ve hareket devam ettiği sürece görüntü kaydetmektedir (Meek vd., 2013; Meek vd., 2014). Veri setlerinde, tetikleme başına 5 ile 40 arasında değişen sayıda kaydedilmiş görüntüler bulunmaktadır. Önerilen sistemin ilk aşamasında görüntü içerisinde hareketli nesnelere tespiti gerçekleştirmektedir. Yöntemimizde, her tetiklemede elde edilen görüntüler kullanılarak öncelikle bu tetiklemeye ait arka plan modeli oluşturulmuştur. Bu arka plan modeli çerçeve farkı yönteminde referans görüntü olarak kullanılmıştır. Hareketli nesnelere bulunduğu görüntüler arka plan modelinden çıkartılarak hareketli nesnelere

tespit edilmiştir. Elde edilen görüntüler filtreleme ve eşikleme işlemleri ile gürültü ve hatalardan ayrıştırılıp, hareketli nesnelere belirgin hale getirilmiştir. Sistemin ikinci aşamasında tespit edilen hareketli nesnenin görüntü içerisinde konumu ve nesnenin boyutu belirlenmiştir. Her bir adımda uygulanan yöntemlerle ilgili ayrıntılı bilgiler aşağıda açıklanmaktadır.



Şekil 1: Sistem Modeli

2.1. Foto-Kapan Veri Setleri

Çalışmamızda Kays ve arkadaşları tarafından 2010 yılında yapılan çalışmada foto-kapanlar kullanılarak doğal ortamdan elde edilen, birincisinde 20 farklı hayvan sınıfının, ikincisinde ise insan ve hayvan olmak üzere iki sınıfın bulunduğu iki farklı veri seti (Kays vd., 2010) kullanılmıştır (URL-1). Birinci veri setinde 100 arka plana sahip 1276, ikinci veri

setinde 215 farklı arka plana sahip 1806 görüntü bulunmaktadır. 1920x1080 boyutlarında olan bu görüntüler gece ve gündüz kaydedilmiştir. Veri setlerinde, bu görüntülerde bulunan nesnelere ait tür, konum ve büyüklük bilgileri kesin referans (ground-truth) olarak bulunmaktadır. Birinci veri setinde 859 görüntüde bir adet hareketli nesnenin, 88 adet görüntüde ise birde fazla hareketli nesnenin parçalı veya tam görüntüsü

bulunmaktadır. 329 adet görüntüde ise hareketli nesne bulunmamaktadır. İkinci veri setinde 771 görüntüde bir adet nesne, 85 görüntüde birden fazla nesne bulunmaktadır. İkinci veri setinde 950 görüntüde ise hareketli nesne bulunmamaktadır. Şekil 2 a'da birinci, Şekil 2 b'de ikinci veri setinde insan ve hayvan içeren gece ve gündüz kaydedilmiş örnek görüntüler gösterilmiştir.



(a)



(b)

Şekil 2: Veri setlerinden farklı kamera ve zamanlarda alınmış örnek görüntüler
(a) Birinci Veri Seti (b) İkinci Veri Seti

2.2. Hareketli Nesne Tespiti

Önerilen sistem, model nesne görüntülerinin elle kırılarak kullanıldığı literatürdeki diğer çalışmalardan farklı olarak, nesnelere ait ön bilgi kullanılmadan görüntülerin arka plandan hareketli nesnelere ayırt edilmesine dayanmaktadır. Önerilen sistemde hareketli nesne tespiti için gerekli adımlar Şekil-1'de görüleceği üzere iki aşamadan oluşmaktadır. Şekil 3'te bu iki işleme ait örnek görüntüler

gösterilmektedir. Birinci aşamada, Şekil 3-a ve Şekil 3-b'de gösterildiği üzere, her tetiklemede elde edilen görüntüler kullanılarak arka plan modeli oluşturulmaktadır. Arka plan, sabit bir kameradan çekilmiş görüntülerde belirli süre hareketsiz kalan nesnelere meydana gelmektedir. Bu amaçla çalışmamızda Değişen Gauss Ortalama (Running Gaussian Average) ve Gaussların Karışımı (Gaussian

Mixture) yöntemleri kullanılmış ve yöntemlerin başarıları karşılaştırılmıştır. Değişen Gauss Ortalama metodu her bir piksel (x, y) lokasyonundan bağımsız olarak, n adet pikselin son değerlerini Gauss olasılık yoğunluk fonksiyonu üzerine uydurulmasına dayanmaktadır (Piccardi, 2004; Wren vd., 1997). Değişen Gauss Ortalama metoduna göre arka planın her bir pikselinin ortalama değeri μ_t Eşitlik 1. ile hesaplanmaktadır.

$$\mu_t = \alpha I_t + (1 - \alpha) \mu_{t-1} \quad (1)$$

Eşitlik 1. de I_t , t anındaki görüntüyü, μ_{t-1} pikselin önceki ortalama değerini ve α ise güncelleme hızı olarak tercih edilebilecek bir ağırlık değerini ifade etmektedir (Piccardi, 2004; Wren vd., 1997).

Gaussların karışımı metodunda Gauss değerlerinin karışımı vasıtasıyla t zamanında belirli bir piksel değerinin gözlemlenme olasılığı $P(x_t)$ Eşitlik 2. ile hesaplanır (Piccardi, 2004; Wren vd., 1997).

$$P(x_t) = \sum_{i=1}^K \omega_{i,t} \eta(x_t - \mu_{i,t}, \Sigma_{i,t}) \quad (2)$$

Eşitlik 2.'de gösterilen Gaussların karışımı algoritmasında, x_t , t görüntüsünün piksel değerini, K karışımındaki toplam dağılım sayısını, $\omega_{i,t}$ t görüntüsündeki k . dağılımın ağırlığını, $\mu_{i,t}$, t görüntüsündeki k . dağılımın ortalamasını, $\Sigma_{i,t}$ ise k . dağılımın standart sapmasını ifade etmektedir (Piccardi, 2004; Nurhadiyatna vd., 2013).



Şekil 3: : (a) Tetikleme Sonrası Kaydedilen Foto-kapan Görüntüleri

(b) Bu Görüntüler Kullanılarak Arka Plan Modelinin Oluşturulması

(c) 1. Aşamadaki Görüntüler ile 2. Aşamadaki Arka Plan Modelinin Çerçeve Farkı Yönteminde Kullanılması

(d) Görüntülerdeki Hareketli Nesnelerin Elde Edilmesi

Arka plan modeli elde edildikten sonra her görüntüdeki hareketli nesnelerin tespiti için Şekil 3-a ve Şekil 3-c'de gösterilen görüntüler üzerinde çerçeve farkı yöntemi uygulanmış ve Şekil 3-d çıktılarını elde edilmiştir. Bu yöntemde ardışık görüntülerin her birinin arka plan modeli ile farkı olan I_d aşağıdaki Eşitlik 3. ile hesaplanmıştır.

$$I_{d(k,k+1)} = |I_{k+1} - I_k| \quad (3)$$

Yukarıdaki Eşitlik 3. de I_k ardışık görüntülerdeki k . görüntüyü ve I_{k+1} ise bir

sonraki $(k+1)$ inci görüntüyü ifade etmektedir (Jain ve Nagel, 1979; Singla, 2014).

Şekil 4'te ışık şiddeti değişimi olan ardışık görüntüler gösterilmiştir. Işık şiddeti değişimi, Şekil 5-a'da görülebileceği üzere, arka plan modelinin hatalı oluşturulmasına ve nesne tespitinin yapılamamasına neden olmaktadır. Bu problem histogram eşitleme yöntemi kullanılarak çözülebilmektedir. Şekil 5-b'de ışık şiddeti değişimi olan görüntülerdeki hataların giderilmesinden

sonra elde edilen hareketli nesne çıktısı gösterilmiştir.




Şekil 4: Ardışık Görüntülerdeki Işık Şiddeti Farkı



Şekil 5: Işık Şiddeti Farkı Olan Görüntülerin Çerçeve Farkı Yöntemi Çıktısı
(a) Normal, (b) Histogram Eşitleme

Ardışık görüntülerdeki hareketli arka plan, çerçeve farkı yönteminden elde edilen çıktı görüntülerinde gürültüye neden olmaktadır. Görüntülerde meydana gelen gürültüleri azaltılmak ve nesneyi belirginleştirilmek

amacıyla Gauss bulanıklaştırma, Medyan Filtre ve OTSU eşikleme yöntemleri ayrı ayrı uygulanmıştır. Şekil 6'da, çerçeve farkı, bulanıklaştırma ve eşikleme işlemlerinden sonraki çıktılar gösterilmektedir.



Şekil 6: (a) Çerçeve Farkı Yöntemi Çıktısı, (b) Gauss Bulanıklaştırma, (c) Otsu Eşikleme


2.3. Konumlandırma

Yöntemin ikinci aşamasında, tespit edilen hareketli nesnelerin konumlandırılması amacıyla Kabarcık Analizi (Blob Analysis) ve kayan pencere tabanlı histogram hesaplama yöntemleri uygulanmıştır. Konumlandırma aşamasında hareketli nesnenin bulunduğu konum ve büyüklüğü hesaplanarak sınırlayıcı kutu (bounding box) tespit edilmektedir. 1. aşamanın sonunda Şekil 6-c'de gösterilen ikili (binary) çıktı elde edilmektedir. Kabarcık tespiti için kullanılan yöntemler, siyah arka plan üzerindeki beyaz piksellerin bulunduğu

bölgeyi ve büyüklüklerini hesaplamak için kullanılmaktadır. Çalışmamızda kabarcık tespiti için LoG (Gaussian of Laplacian), DoG (Difference of Gaussian) ve DoH (Determinant of Hessian) algoritmaları kullanılmıştır. Bu yöntemler arasında LoG en başarılı ama en yavaş çalışan yaklaşımdır. LoG, görüntülerin Laplacian değerini art arda standart sapma ile hesaplamakta ve bir küp içinde toplamaktadır. Bu küpün yerel maksimumu kabarcıkları ifade etmektedir. Daha büyük kabarcıkları tespit etmek, özellikle konvolüsyon sırasında daha büyük

çekirdek boyutları gerektirmesi nedeniyle daha yavaş çalışmaktadır. DoG, LoG yaklaşımından daha hızlı çalışan bir yaklaşımdır. Bu yaklaşımda, görüntü artan standart sapmalar ile bulanıklaşmakta ve birbirini izleyen iki bulanık görüntü arasındaki fark bir küp içinde biriktirilmektedir (Suzuki, 1985). DoG, görüntünün birbirini izleyen iki Gauss konvolüsyonunun çıkarılması ile hesaplanmaktadır. DoG haritasındaki yoğunluk maksimum ve minimumları, sırasıyla algılanan parlak ve karanlık bölgeleri temsil etmektedir (Schindelin vd., 2012). DoH ise en hızlı çalışan yaklaşımdır. Görüntünün Hessian Determinantının matrisinde maksimum noktalar ile kabarcıkların tespit

edilmesine dayanmaktadır. Algılama hızı, uygulamada konvolüsyonlar yerine kutu filtreleri kullandığı için kabarcıkların boyutundan bağımsızdır. Dezavantajı ise 3 pikselden küçük lekelerin doğru olarak algılanmamasıdır (Suzuki, 1985). Bu algoritmalar, çerçeve farkı yönteminden elde edilen sonuca uygun olarak, gri ton görüntülerde kullanılabilir. Kayan pencere tabanlı histogram hesaplamada ise görüntü içerisinde değişen büyüklükte pencereler ile beyaz piksel sayısını maksimum yapan konum belirlenmektedir. Şekil 7-a'da LoG, Şekil 7-b'de DoG, Şekil 7-c'de DoH algoritmalarının çıktıları, Şekil 8'de kayan pencere tabanlı konumlandırma işlemine ait çıktı gösterilmiştir.



Şekil 7: Kabarcık Analizi Algoritmasının Sonuçları
(a) Laplacian of Gaussian (b) Difference Of Gaussian (c) Determinant of Hessian



Şekil 8: Kayan Pencere Tabanlı Konumlandırma Sonucu

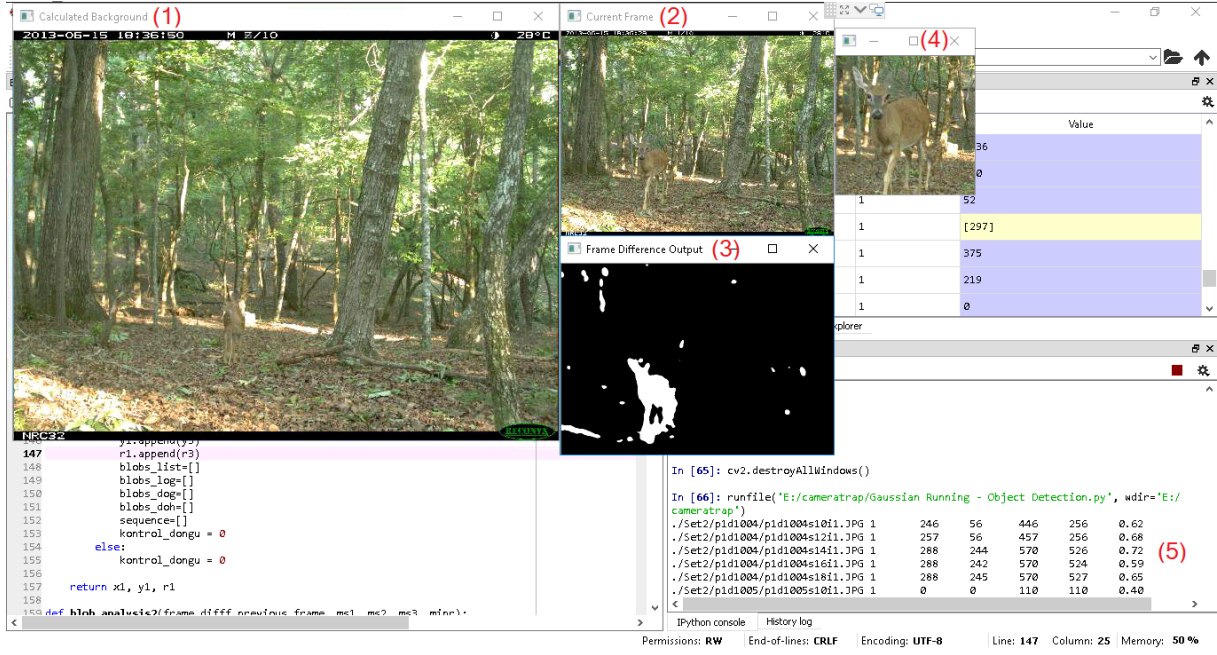
Sınırlayıcı kutu tespitinde başarı ölçümü amacıyla birleşimin kesişimi (IoU-Intersection Over Union) formülü kullanılmaktadır (Zitnick ve Dollár, 2014). Şekil 9’da siyah olan sınırlayıcı kutu nesnenin bulunduğu bölgeyi, kırmızı ise bizim elde ettiğimiz sınırlayıcı kutuyu temsil etmektedir. Örnek olarak gösterilen bu iki sınırlayıcı kutu için konumlandırma işleminin başarısı, bu iki kutunun kesiştiği bölgenin piksellerinin, iki kutunun birleşimi olan bölgenin piksellerine oranı üzerinden değerlendirilmektedir. Konumlandırma işleminin başarısı için nesne tespit çalışmalarında birleşimin kesişimi değeri olarak 0.5, 0.7 ve 0.9 kullanılmakta olup (Zitnick ve Dollár, 2014) çalışmamızda bu değerlere ait konumlandırma sonuçları gösterilmiştir.



Şekil 9: Sınırlayıcı Kutu Tespiti

3. Bulgular

Çalışmamız, tümleşik python dağıtımı içeren Anaconda programının Spyder alt programı kullanılarak gerçekleştirilmiştir. Arayüze ait örnek görüntü Şekil 10’da gösterilmiş olup, Python sürümü olarak 3.6 tercih edilmiştir. Çalışmada önerilen yöntemler ve diğer görüntü işleme aşamaları, bilgisayarlı görme 2 (CV2) ve Python Görüntü Kütüphaneleri (PIL) kullanılarak gerçekleştirilmiştir. Şekil 10’da görüldüğü üzere, algoritma çalıştırıldığında öncelikle tetiklemede elde edilen görüntüler kullanılarak 1 numaralı çıktı olan arka plan modeli elde edilmektedir. Elde edilen arka plan modeli ile 2 numaralı olarak işaretlenmiş her görüntüye çerçeve farkı yöntemi uygulanmakta ve 3 numaralı çıktı elde edilmektedir. 3 numaralı çıktı üzerinde sınırlayıcı kutu belirleme işlemi uygulanarak görüntüdeki hareketli nesne, 4 numaralı çıktı olarak elde edilmektedir. Elde edilen sonuca ait dikey ve yatay koordinat bilgileri 5 numara ile işaretlenmiş kısımdan görülebileceği üzere metin dosyasına kaydedilmekte ve devamında kesin referans (ground-truth) değerleri ile karşılaştırılmaktadır.



Şekil 10: Arayüze Ait Görüntü

Tablo 1’de foto-kapan veri setleri üzerinde yapılan çalışmalarda, elle kırılmış nesne görüntülerinin sayısı, veri setindeki nesnelerin sınıf sayısı, çalışmalarda tespit edilen sınıf sayısı ve bu tespit işlemlerine ait başarı oranları gösterilmektedir. Görüldüğü üzere, elle nesne tespiti yapılmış görüntü sayısı arttıkça veya veri setine kıyasla tespit

edilmeye çalışılan sınıf sayısı azaldıkça başarı oranı artmaktadır. Sınıf sayısı 2 ve 3 olan çalışmalarda sınıflar arka plan, insan ve hayvan olarak uygulanmaktadır. Sınıf sayısının fazla olduğu çalışmalarda ise derin öğrenme tabanlı yöntemlerle farklı türde hayvanlar tespit edilmeye çalışılmaktadır.

Tablo 1: Yapılan Çalışmalarda El ile Nesne Tespiti Yapılan Görüntü Sayıları, Sınıf Sayıları ve Tespit Başarı Oranları

Çalışma	Elle Kırılan Görüntü Sayısı	Tespit Edilen Sınıf Sayısı	Veri Setindeki Sınıf Sayısı	Başarı Oranı %
Andavarapu ve Vat., 2017	400	8	20	87-97
Zhang vd., 2016	6493	20	23	75-85
Norouzzadeh vd., 2018	1.4 milyon	48	48	92-99
Nguyen vd., 2017	107.000	6	18	92-95
Yu vd., 2013	7196	18	57	74-82
Buehler vd., 2019	1300	2	2	89-90
Willi vd., 2019	141.368	19	55	87-93
Yousif vd., 2019	459.427	3	>50	90-95
Gray vd., 2019	467	2	2	93
Gonçalves vd., 2016	14.547	13	13	86-97
Zhang vd., 2016	6.493	23	23	75-85

Şekil 11’de önerilen yöntem kullanılarak veri setlerinde elde edilmiş hareketli nesnelere ait çıktı görüntüleri gösterilmektedir. Tetikleme sonrasında kaydedilen görüntülerde ışık

şiddeti değişimi ve arka plan hareketinin olması durumunda arka plan modelinin hatalı oluşturulduğu gözlemlenmiştir.



Şekil 11: Önerilen Yöntem Kullanılarak Elde Edilen Hareketli Nesnelere Ait Görüntüler

Tablo 2 ve Tablo 3’te görüldüğü üzere, birinci veri setinde tespit aşamasında, %77-%82 ve %59-%79 arasında, konumlandırma aşamasında ise %55-%64 ve %41-%60 arasında doğruluk oranları elde edilmiştir. Histogram eşitlemenin kullanılmadığı Gaussların karışımı hariç diğer yöntemlerde, kabarcık analizinin konumlandırma aşamasında daha etkili olduğu anlaşılmaktadır. Nesne tespit aşamasında, Değişen Gauss Ortalama yönteminde Gaussların Karışımı yöntemine kıyasla %2-%5 daha iyi sonuçlar elde edilmiştir. Tablo 2 ve Tablo 3’ten anlaşıldığı üzere, Histogram eşitleme işlemi Tablo 2’deki kayan pencere

tabanlı yöntem dışında konumlandırma aşamasında doğruluk oranını arttırmıştır.

Tablo 2: Birinci Veri Setinde Gauss Bulanıklığı ile Elde Edilen Tespit – Konumlandırma (0.5-0.7-0.9) Sonuçları (%)

Metot	Kayan Pencere Tabanlı Histogram	Kabarcık Analizi
Gauss Ortalama	81-(56-32-19)	82 -(60-33-22)
Gaussların Karışımı	77-(58-33-18)	77-(57-32-20)
Gauss Ortalama + Histogram Eşitleme	80-(55-35-22)	81-(64-41-28)
Gaussların Karışımı + Histogram Eşitleme	79-(56-36-21)	79-(63-39-26)

Tablo 3: Birinci Veri Setinde Medyan Filtre ile Elde Edilen Tespit – Konumlandırma (0.5-0.7-0.9) Sonuçları (%)

Metot	Kayan Pencere Tabanlı Histogram	Kabarcık Analizi
Gauss Ortalama	79 -(47-24-6)	%73-(49-24-15)
Gaussların Karışımı	68-(41-20-5)	%59-(37-18-10)
Gauss Ortalama + Histogram Eşitleme	78-(52-27-8)	%79-(60-39-15)
Gaussların Karışımı + Histogram Eşitleme	77-(51-27-9)	%74-(53-27-11)

Tablo 4 ve Tablo 5'te görüldüğü üzere, ikinci veri setinde tespit aşamasında, %75-%83 ve %72-%81 arasında, konumlandırma aşamasında ise %62-%80 ve %59-%73 arasında doğruluk oranları elde edilmiştir. İkinci veri setinde konumlandırma işleminde birinci veri setine kıyasla daha iyi doğruluk oranları elde edilmiştir. Histogram eşitleme işleminin nesne tespit aşamasında başarıyı %3-%7 arasında düşürdüğü, konumlandırma aşamasında ise başarıyı %4-%16 arasında arttırdığı anlaşılmaktadır. Ayrıca konumlandırma işleminde kabarcık analizinin kayan pencere tabanlı yöntemle göre daha başarılı olduğu gözlemlenmiştir. Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te görüldüğü üzere daha iyi konumlandırma başarısı anlamına gelen 0.7 ve 0.9 birleşimin kesişimi parametrelerinde nesne konumlandırma işleminde doğruluk oranlarının düşük olduğu anlaşılmaktadır. Bu sonuca arka plan çıkarma

işlemindeki yetersizliklerin, arka plan hareketlerinin ve kesin doğruluk değerlerindeki küçük hataların sebep olduğu düşünülmektedir. Foto-kapan görüntülerinde arka plan hareketi ve ışık şiddeti değişimi problemi fazla olduğu için birleşimin kesişimi 0.5 değeri tercih edilmektedir (Yousif vd., 2019; Zhang vd., 2016).

Tablo 4: İkinci Veri Setinde Gauss Bulanıklığı ile Elde Edilen Tespit – Konumlandırma (0.5-0.7-0.9) Sonuçları (%)

Metot	Kayan Pencere Tabanlı Histogram	Kabarcık Analizi
Gauss Ortalama	83 -(71-54-32)	82-(71-53-30)
Gaussların Karışımı	82-(62-49-25)	75-(64-49-23)
Gauss Ortalama + Histogram Eşitleme	76-(78- 59-34)	76-(80 -58-32)
Gaussların Karışımı + Histogram Eşitleme	79-(78-58-31)	74-(77-55-30)

Tablo 5: İkinci Veri Setinde Medyan Filtre ile Elde Edilen Tespit – Konumlandırma (0.5-0.7-0.9) Sonuçları (%)

Metot	Kayan Pencere Tabanlı Histogram	Kabarcık Analizi
Gauss Ortalama	81-(66-50-28)	81 -(69-50-24)
Gaussların Karışımı	80-(60-46-20)	74-(59-45-20)
Gauss Ortalama + Histogram Eşitleme	75-(70- 56-29)	72-(73 -53-26)
Gaussların Karışımı + Histogram Eşitleme	77-(69-54-29)	75-(70-52-27)

Medyan filtre, tuz ve karabiber gürültüsünü gidermede başarılı olsa da, nesnenin silinmesine veya belirginliğinin azalmasına neden olabilmektedir. Nesne algılama performansını arttırmak için, gürültünün tamamen temizlenmesi yerine yalnızca eşik değerinin altına indirmek yeterli olmaktadır. Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te gösterildiği gibi, medyan filtre tespit aşamasını olumlu, konumlandırma aşamasını ise olumsuz etkilemiştir.

Tablo 6 ve Tablo 7'de iki veri setindeki arka planın nesne olarak etiketlenme (False Positive) ve nesnenin arka plan olarak etiketlenme (False Negative) oranları verilmiştir. Tablo 4'ten anlaşıldığı gibi, histogram eşitleme, nesnenin arka plan olarak etiketlenme oranını düşürdüğü böylece konumlandırma işleminde genellikle başarıyı arttırdığı ancak arka planın nesne olma oranı da arttırdığı anlaşılmaktadır. Tablo 7'de

görüldüğü üzere, Tablo 6'ya kıyasla medyan filtre gürültülerin temizlenmesinde daha etkili olarak hatalı tespitleri (False Positive) azalttığı, buna karşılık nesne varlığı ile ilgili bilgileri silerek nesne tespitini (False Negative) zorlaştırdığı anlaşılmaktadır. Medyan filtre gauss bulanıklığından başarısız olsa da, gauss bulanıklığının başarılı olamadığı bazı görüntüler için yararlı olmaktadır.

Tablo 6: Gauss Bulanıklaştırma Hata Matrisi (False Negative – False Pozitive) (%)

Metot	Gauss Ortalama	Gaussların Karışımı	Gauss Ortalama + Histogram Eşitleme	Gaussların Karışımı + Histogram Eşitleme
Kayan Pencere Tabanlı Histogram	11-10	18-10	1-22	2-23
Kabarcık Analizi	10-12	13-14	2-20	3-21

Tablo 7: Her İki Veri Setine Ait Medyan Filtre Hata Matrisi (False Negative – False Pozitive) (%)

Metot	Gauss Ortalama	Gaussların Karışımı	Gauss Ortalama + Histogram Eşitleme	Gaussların Karışımı + Histogram Eşitleme
Kayan Pencere Tabanlı Histogram	16-5	29-10	3-20	8-19
Kabarcık Analizi	27-4	38-8	4-20	13-18

Tablo 8'den anlaşıldığı üzere, tespit ve gauss bulanıklığının faydalı olmadığı konumlandırma işlemlerinde medyan filtre, görüntülerin %2-%8'i için faydalı olmuştur.

Tablo 8: Her İki Veri Setinde Gürültülerin Giderilmesinde Gauss Bulanıklaştırmanın Başarısız Olduğu, Medyan Filtrenin Başarılı Olduğu Görüntülerin Oranı (%)

Metot	Gauss Ortalama	Gaussların Karışımı	Gauss Ortalama + Histogram Eşitleme	Gaussların Karışımı + Histogram Eşitleme
Kayan Pencere Tabanlı Histogram	9	3	2	4
Kabarcık Analizi	6	4	2	7

4. Sonuç ve Tartışma

Bu çalışmada ardışık foto-kapanlardan görüntülerinde arka plan çıkarma ve çerçeve farkı yöntemleri kullanılarak hareketli nesne tespiti gerçekleştirilmiştir ve yöntemlerin doğruluk performansları karşılaştırılmıştır. Literatürde nesne tespiti ile ilgili yapılan çalışmalarda nesnelere ait model görüntülerin insanlar tarafından el ile tespit edilmesi, kırılması ve kaydedilmesi aşaması yüksek iş yükü gerektiren bir süreçtir ve nesne tespit

başarısı bu model görüntülerin sayısı, çeşidi ve doğruluğuna bağlı olmaktadır. Önerilen yöntemde, yerel veya genel öznitelik tabanlı tespit yöntemlerinde ihtiyaç duyulan model veya örnek nesne görüntüsüne ihtiyaç duyulmamaktadır ve bu nedenle yüksek iş yükünü oldukça azaltmaktadır.

Foto-kapan görüntülerinde hareketli ve karmaşık arka plan ve ışık şiddeti değişiklikleri olması hareketli nesne tespit etme ve konumlandırma sonuçlarının

doğruluğunu azalttığı gözlemlenmiştir. Gauss bulanıklığı ve medyan filtrenin arka plan hareketlerinin neden olduğu gürültüyü azaltmak ve görüntüdeki nesneyi belirginleştirmek için yeterli olduğu anlaşılmaktadır. Foto-kapanlar, hareketli nesnelere tarafından tetiklendiğinde yaklaşık olarak 5-40 arası görüntü kaydetmektedir. Her tetiklemede elde edilen görüntülerin sınırlı olması, arka plan modelinin yetersiz oluşturulmasına neden olabilmektedir. OTSU eşikleme, bu yetersiz arka plan modelinin sebep olduğu gürültülerin giderilmesinde başarılı olduğu anlaşılmıştır.

Her ne kadar arka plan çıkarma yöntemleri videolarda uygulanıyor olsa da, bu çalışma az sayıda görüntüde de bu yöntemlerin kullanılabilirliğini gösterilmiştir. Tespit işleminde en yüksek başarı %83 olarak, Gauss bulanıklıklaştırmanın kullanıldığı Değişen Gauss Ortalama metodu ile elde edilmiştir. Konumlandırma işleminde ise en yüksek başarı %80 olarak, Gauss bulanıklaştırma, Histogram eşitleme ve Değişen Gauss Ortalamasının kullanıldığı Kabarcık analizi yöntemi ile elde edilmiştir. Birinci veri setinde konumlandırma başarısının, tespit başarısına kıyasla daha düşük olması, veri setlerindeki görüntülerde arka plan hareketinin fazla olmasından ve hareketli nesne sayısının birden fazla olmasından kaynaklanmaktadır. İkinci veri setinde ise bu sorunların daha az olması nedeniyle daha iyi konumlandırma başarısı elde edildiği anlaşılmıştır. Ayrıca insanlar tarafından yapılan tespit işleminin (Ground-Truth), ardışık görüntülerdeki nesne varlığının bilinerek yapılması, çalışmadaki otomatik tespit yönteminin başarısını daha az göstermiştir.

Gelecek çalışmalarda hareketli nesnenin konumunu belirlemede ve doğruluğunu arttırmak amaçlanmaktadır. Ayrıca tespit edilen hareketli nesnenin türünü belirlemek amacı ile gerçekleştirilen çalışmalara devam edilmektedir.

5. Kaynaklar

- Andavarapu, N., & Vatsavayi, V. K. (2017). Wild-Animal Recognition in Agriculture Farms Using W-COHOG for Agro-Security. *International Journal of Computational Intelligence Research*, 13(9), 2247-2257.
- Buehler, P., Carroll, B., Bhatia, A., Gupta, V., & Lee, D. E. (2019). An automated program to find animals and crop photographs for individual recognition. *Ecological Informatics*.
- Chen, Q., Song, Z., Dong, J., Huang, Z., Hua, Y., & Yan, S. (2015). Contextualizing object detection and classification. *IEEE transactions on pattern analysis and machine intelligence*, 37(1), 13-27.
- Elgammal, A., Harwood, D., & Davis, L. (2000, June). Non-parametric model for background subtraction. In *European conference on computer vision* (pp. 751-767). Springer, Berlin, Heidelberg.
- Glover-Kapfer, P., Soto-Navarro, C. A., & Wearn, O. R. (2019). Camera-trapping version 3.0: current constraints and future priorities for development. *Remote Sensing in Ecology and Conservation*(pp. 36-48).
- F., Gonçaves, Arruda, M. D. S., Spadon, G., Rodrigues, J., W. N., & Machado, B. B. (2018, July). Recognition of Pantanal Animal Species using Deep Learning Methods. In *2018 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
- Gray, P. C., Fleishman, A. B., Klein, D. J., McKown, M. W., Bézy, V. S., Lohmann, K. J., & Johnston, D. W. (2019). A convolutional neural network for detecting sea turtles in drone imagery. *Methods in Ecology and Evolution*, 55-61.
- He, Z., Kays, R., Zhang, Z., Ning, G., Huang, C., Han, T. X., ... & McShea, W. (2016). Visual informatics tools for supporting large-scale collaborative wildlife monitoring with

- citizen scientists. *IEEE Circuits and Systems Magazine*, 16(1), 73-86.
- Hoebeker, L., Stock, M., Van Hoey, S., Casaer, J., & De Baets, B. (2018, September). Automated recognition of people and identification of animal species in camera trap images. In *ICEI 2018: 10th International Conference on Ecological Informatics-Translating Ecological Data into Knowledge and Decisions in a Rapidly Changing World*.
- Jain, R., & Nagel, H. H. (1979). On the analysis of accumulative difference pictures from image sequences of real world scenes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (2), 206-214.
- Kays, R., Tilak, S., Kranstauber, B., Jansen, P. A., Carbone, C., Rowcliffe, M. J., & He, Z. (2010). Monitoring wild animal communities with arrays of motion sensitive camera traps. *arXiv preprint arXiv:1009.5718*.
- Khorrami, P., Wang, J., & Huang, T. (2012, November). Multiple animal species detection using robust principal component analysis and large displacement optical flow. In *Proceedings of the 21st International Conference on Pattern Recognition (ICPR), Workshop on Visual Observation and Analysis of Animal and Insect Behavior* (pp. 11-15).
- Kulchandani, J. S., & Dangarwala, K. J. (2015, January). Moving object detection: Review of recent research trends. In *Pervasive Computing (ICPC), 2015 International Conference on* (pp. 1-5). IEEE.
- Lin, K. H., Khorrami, P., Wang, J., Hasegawa-Johnson, M., & Huang, T. S. (2014, October). Foreground object detection in highly dynamic scenes using saliency. In *Image Processing (ICIP), 2014 IEEE International Conference on* (pp. 1125-1129). IEEE.
- Lo, B. P. L., & Velastin, S. A. (2001). Automatic congestion detection system for underground platforms. In *Intelligent Multimedia, Video and Speech Processing, 2001. Proceedings of 2001 International Symposium on* (pp. 158-161). IEEE.
- Meek, P. D., Vernes, K., & Falzon, G. (2013). On the reliability of expert identification of small-medium sized mammals from camera trap photos. *Wildlife Biology in Practice*, 9(2), 1-19.
- Meek, P. D., Ballard, G., Claridge, A., Kays, R., Moseby, K., O'brien, T., & Townsend, S. (2014). Recommended guiding principles for reporting on camera trapping research. *Biodiversity and Conservation*, 23(9), 2321-2343.
- Nguyen, H., Maclagan, S. J., Nguyen, T. D., Nguyen, T., Flemons, P., Andrews, K., ... & Phung, D. (2017, October). Animal Recognition and Identification with Deep Convolutional Neural Networks for Automated Wildlife Monitoring. In *Data Science and Advanced Analytics (DSAA), 2017 IEEE International Conference on* (pp. 40-49). IEEE.
- Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences*, 201719367, (pp. 185-201).
- Nurhadiyatna, A., Jatmiko, W., Hardjono, B., Wibisono, A., Sina, I., & Mursanto, P. (2013, October). Background subtraction using gaussian mixture model enhanced by hole filling algorithm (gmmhf). In *Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on* (pp. 4006-4011). IEEE.
- Oliver, N. M., Rosario, B., & Pentland, A. P. (2000). A Bayesian computer vision system for modeling human interactions. *IEEE transactions on pattern analysis and machine intelligence*, 22(8), 831-843.

- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Piccardi, M. (2004, October). Background subtraction techniques: a review. In *Systems, man and cybernetics, 2004 IEEE international conference on* (Vol. 4, pp. 3099-3104). IEEE
- Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T., & Tinevez, J. Y. (2012). Fiji: an open-source platform for biological-image analysis. *Nature methods*, 9(7), 676.
- Sebastian, E., & Daniel, N. (2017). A Survey on Various Saliency Detection Methods. *International Journal of Computer Applications*, 161-168(5).
- Seki, M., Wada, T., Fujiwara, H., & Sumi, K. (2003, June). Background subtraction based on cooccurrence of image variations. In *Computer Vision and Pattern Recognition, 2003. Proceedings. 2003 IEEE Computer Society Conference on* (Vol. 2, pp. II-II). IEEE.
- Singla, N. (2014). Motion detection based on frame difference method. *International Journal of Information & Computation Technology*, 4(15), 1559-1565.
- Stauffer, C., & Grimson, W. E. L. (1999, June). Adaptive background mixture models for real-time tracking. In *cvpr* (p. 2246). IEEE.
- Suzuki, S. (1985). Topological structural analysis of digitized binary images by border following. *Computer vision, graphics, and image processing*, 30(1), 32-46.
- Weiming Hu, Tieniu Tan, Liang Wang, and Steve Maybank, "A Survey on Visual Surveillance of Object Motion and Behaviors," *IEEE Trans. on Systems, Man, and Cybernetics—Part C: Applications and Reviews*, vol. 34, no. 3, pp. 334-352, August 2004.
- Wren, C. R., Azarbayejani, A., Darrell, T., & Pentland, A. P. (1997). Pfnder: Real-time tracking of the human body. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (7), 780-785.
- Yousif, H., Yuan, J., Kays, R., & He, Z. (2019). Animal Scanner: Software for classifying humans, animals, and empty frames in camera trap images. *Ecology and Evolution* (pp. 140-149).
- Yu, X., Wang, J., Kays, R., Jansen, P. A., Wang, T., & Huang, T. (2013). Automated identification of animal species in camera trap images. *EURASIP Journal on Image and Video Processing*, 2013(1), 52.
- Willi, M., Pitman, R. T., Cardoso, A. W., Locke, C., Swanson, A., Boyer, A., Fortson, L. (2018). Identifying animal species in camera trap images using deep learning and citizen science. *Methods in Ecology and Evolution* 116-122.
- Zhang, Z., He, Z., Cao, G., & Cao, W. (2016). Animal detection from highly cluttered natural scenes using spatiotemporal object region proposals and patch verification. *IEEE Transactions on Multimedia*, 18(10), 2079-2092.
- Zitnick, C. L., & Dollár, P. (2014, September). Edge boxes: Locating object proposals from edges. In *European conference on computer vision* (pp. 391-405). Springer, Cham.
- Wang, B. (2014). Automatic Animal Species Identification Based on Camera Trapping Data (Thesis).
- URL-1:
<http://videonet.ece.missouri.edu/cameratrap/>,
 (Erişim Tarihi: 22 Ocak 2018).