

Kaynak değeri olan yaban hayvanlarının görüntü işleme tekniği ile tespiti ve sayımı

Detection and counting of wild animals as source value by image processing technique

İsmail YABANOVA¹ , Kadir KAYA^{2*} 

¹Elektrik-Elektronik Mühendisliği Bölümü, Teknoloji Fakültesi, Afyon Kocatepe Üniversitesi, Afyonkarahisar, Türkiye.

iyabanova@gmail.com

²Orman ve Su İşleri Bakanlığı, Doğa Koruma ve Milli Parklar Genel Müdürlüğü, 5. Bölge Müdürlüğü, Afyonkarahisar, Türkiye.

kkaya4214@gmail.com

Geliş Tarihi/Received: 11.12.2017, Kabul Tarihi/Accepted: 05.06.2018

doi: 10.5505/pajes.2018.19577

* Yazışılan yazar/Corresponding author

Araştırma Makalesi/Research Article

Öz

Bu çalışmada yaban hayatında görüntü işleme tabanlı yaban hayvanlarının tür tespiti ve sayımının yapılması hedeflenmiştir. Korunan alanlarda sabit bir kameradan elde edilen görüntülerden ülke ekonomisine av turizmi ile katma değeri olan yaban hayvanlarının tür tespiti yapılarak sayımının yapılmasına yönelik görüntü işleme tabanlı bir sistem geliştirilmiştir. Bu sistem sayesinde yüksek başarımla yaban hayvanlarının türlerinin belirlenmesi ve sayımının yapılması amaçlanmıştır. Bunun için ilk olarak gauss karma modelleri (GMM) tekniği ile gerçek zamanlı foto kapan videolarından alınan görüntü sahnelerinden arka plan görüntüsü çıkarılmıştır. Sonra videonun arka plan ve ön plan görüntülerinden yaban hayvanlarının fiziksel ve renksel özellikleri çıkarılmıştır. Hareketliliğin çok olduğu doğal yaşamda anlık elde edilen gerçek zamanlı kompleks bir görüntü sahnesinde geliştirilen alan testi, öznelik testi ve renk testi kriterleri ile hedeflenen yaban hayvanın tespit edilmesi sağlanmıştır. Yapılan deneysel çalışmalarda geyik, tilki, kurt ve yaban atından oluşan 4 adet yaban hayvanı tür tespiti %100 doğruluk oranı ile gerçekleştirilmiştir. Yazılımın video çerçevesi başına düşen işlem süresi 0.242 saniyedir. Geliştirilen yöntemler ile yaban hayvanı envanterine yönelik tür tespitinin %100 başarı oranı ile insan gücüne gerek duymadan, daha düşük maliyetli kamera sistemleri ve bilgisayar yazılımı ile yapılabileceği görülmüştür. Literatürdeki yaban hayvanları sınıflandırma çalışmalarından farkı yaban hayvanı tanıma işleminin nesne tanıma üzerine oluşturulan hazır algoritmaları kullanmadan geliştirilen daha basit matematiksel işlemlerle ve renk faktörü ile hedeflenen %100 tanıma oranının yakalanmasıdır. Çalışmamızda kullandığımız yaban hayvanı tanıma algoritmaları bilgisayarlı görme uygulamalarında dinamik nesne tespiti çalışmalarına altyapı olacağı ve diğer tüm nesne tanıma çalışmalardaki başarımlarını arttıracığı aşikardır.

Anahtar kelimeler: Hayvan izleme ve sınıflandırma, Vahşi hayvanlar sınıflandırması, Görüntü işleme, Nesne tanıma, Görüntü sınıflandırma

Abstract

In this study, it is aimed to detect and count wild animals based on image processing in wildlife. From the images obtained from a fixed camera in the protected areas, an image processing based system has been developed for detecting and counting wild animals which are added value with hunting tourism to the country's economy. Through this developed system, it is aimed to both determine and count the wild animal species with high performance. For this, firstly, using gaussian mixed models (GMM) technique, the background images were extracted from the image scenes coming from real-time photocapture videotapes. In a real-time complex image scene that is instantaneous in nature where there is a lot of mobility, developed field test, attribute test and color test criteria are used to determine the targeted wild animal. In the experimental studies, 4 species of wild animals including deer, fox, wolf and wild horses were detected with 100% accuracy. The software's processing time per video frame is 0.242 seconds. With the developed methods, it has been seen that species determination for wild animal inventory can be done with less cost camera systems and computer software without human power with 100% success rate. The difference from the wild animal classification studies in the literature is the catching of the 100% recognition rate targeted by wild animal identification process with simpler mathematical operations and color factor developed without using ready-made algorithms on object recognition. The wild animal recognition algorithms we use in our work are obviously to be the infrastructure for dynamic object detection studies in computer vision applications and all other object recognition will increase the performance ratio in the studies.

Keywords: Animal monitoring and classification, Wild animal classification, Image processing, Object recognition, Image classification

1 Giriş

Tüm dünyada nesli tükenmekte olan yaban hayvanları koruma altına alınmaktadır. Ekosistem içerisinde koruma ve kullanma dengesi birbirini tamamlayan iki önemli unsurdur. Bu bağlamda ülkemizin %7.24'ü resmi olarak koruma altına alınmıştır [1].

Korunan alanlarda özellikle ülke ekonomisine av turizmi ile katkısı olan yaban hayvanlarının denetimi envanter çalışmaları ile yapılmaktadır. Böylesine önem arz eden bir konu ülkemizde yaban hayvanlarına yönelik izleme, tür tespiti ve sayım

işlemleri insan gücü yordamı ile yapılmaktadır [2]. Pratikte yaban hayvanı envanterine yönelik tür ve sayı tespiti işlemlerinde şu sorunların olduğu tespit edilmiştir:

- Korunan alanların çok geniş olması, genelde aşırı ormanlık ve engebeli arazi şartlarından dolayı insan gücünün yetersiz kalması,
- İnsan faktörüne olan ihtiyacın fazla olması,
- Yaban hayatının izlenmesi amacı ile yüksek maliyetli fotokapan cihazlarının alınması,
- Envanter çalışmalarının haftalarca sürmesi,

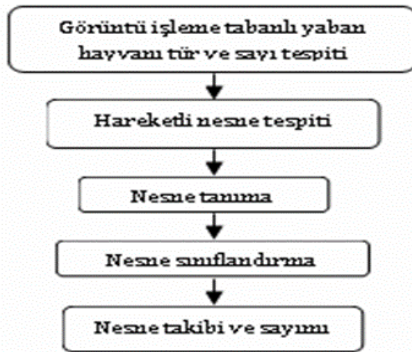
- Örneklemeye ile tahmini tür sayımı ve tespiti yapılması,
- Yaban hayatında kontrolün tam anlamda sağlanamaması.

Bilgisayarlı görme sistemlerinde nesne tanıma günümüzde modern akıllı sistemlerin ayrılmaz bir parçasıdır. Görüntü işleme son 50 yıla bakıldığında günümüze kadar tıpta, yarı iletken teknolojinin gelişmesi ile üretim ve montajda, gıda endüstrisinde, elektronik ve makine endüstrisinin üretim ve montaj kısımlarında, ilaç sanayide, savunma sanayide, trafik izlemede, güvenlik sistemlerinde ve bunun gibi daha birçok farklı alanda nesne tanıma ve sınıflandırma, bilgisayarlı görme uygulamalarının en temel konusu olmuştur [3].

Doğal yaşamdaki yabancı hayvanların günümüz teknolojisi ile tür ve sayısını belirlemenin ekonomik bir yolu görüntü işleme tabanlı bir sistem geliştirmektir. Yaban hayatında tür tespitine yönelik görüntü işleme tabanlı bir sistemin geliştirilmesinde bazı zorluklarla karşılaşmak olasıdır. Bunlar:

- Tespit edilecek canlı yabancı olduğu için davranışlarında değişkenlik söz konusudur. Bunun bir sonucu olarak geliştirilecek sistemin matematiğinin de değişkenlik göstermesi,
- Tespit edilecek yabancı hayvanlarının yaşadığı ortamların genelde görüntü işleme en zor sahneleri içeren sık ormanlık alanlardan oluşmuş olması,
- Ortam ışık yoğunluğunun sabit olmaması ve gölge oluşumlarının çok olduğu araziler olması.

Görüntü işleme tabanlı yabancı hayvanı tür tespiti 3 ana bileşenden meydana gelmektedir. Sistemin oluşturulmasında her bir yöntemin ve bu bileşenlerde kullanılan her bir yöntemin başarısına etkisi son derece önem arz etmektedir. Yaban hayvanı tür tespit sisteminin ana yapısı Şekil 1'de gösterilmektedir.



Şekil 1: Yaban hayvanı tür tespit sisteminin ana yapısı.

Yaban hayatında yabancı hayvanı envanterine yönelik tür ve sayı tespiti sistemini görüntü işleme tabanlı yapmak için öncelikle hareketli nesnenin tespit edilmesi gerekir. Gerçek zamanlı video ve görüntü uygulamalarında dinamik nesne tespiti ilk aşama olup sabit ve hareketli kamera durumlarına göre farklı yaklaşımlar ile yapılmaktadır. Literatürde hareketli nesne tespiti için kullanılan temel yöntemlerin çerçeve farkı, arka plan çıkarımı ve optik akış yöntemi olduğu görülür [4],[5].

Hareketli nesne tespitinde kullanılan arka plan çıkarma yöntemi sahnede hareketli ön plan nesnelere algılamak için çok kullanışlı popüler bir yöntemdir. Sabit kameradan alınan video görüntüsünde arka plan elde edilir ve arka plandaki değişiklikli hareketli nesne olarak adlandırılır.

Bu algoritma üzerine yapılan testlerde arka planda nesnenin tümünün değil belli bir kısmının tespit edildiği veya çıkarımında aksaklıklara sebep olacak nedenlerden başlıcaları:

1. Sahnede aydınlatma şiddetindeki değişimler ve nesnelere yüzeyindeki yansımalar,
2. Kameranın sabit durmaması,(titremesi vs.)
3. Hareketli arka plan (rüzgâr, yaprak oynamaları vs.) olmasıdır.

Arka plan çıkarımında bu zorluklarla başa çıkabilmek için birçok algoritmalar geliştirilmiştir. Xu ve diğ. [6] yaptıkları çalışmada video analizinde arka plan çıkarımı metodlarını incelemiş ve deneylerle avantaj ve dezavantajlarını karşılaştırmıştır. Kötü hava koşulları, dinamik arka plan, termal video, düşük kare hızına sahip videoların işlenmesinde Gauss Karma Modelleri metodu (GMM) daha yüksek performans sonuçları vermiştir. Sabit kamerada gösterdiği yüksek performans başarısı, düşük bellek gereksinimi ve diğer metodlara göre daha yüksek işleme hızından dolayı bu makale çalışmasında yabancı hayvanı tespitinde GMM metodu kullanılmıştır [7].

GMM metodunda kamera sabit olduğu için genelde kararlı sonuç alınır fakat ortamdaki nesne dışında oluşan ışık değişimleri gölge etkisi, kamera titreşimleri ağaç, yaprak, ot oynamaları, sulak alanlardaki su akıntıları, yağış gibi doğal hava olayları arka planda hareketli nesne gibi algılanıp gürültülü piksellere yol açmaktadır. Özellikle yabancı hayatından yabancı hayvanlarının yer aldığı sahneler genelde arka planda gölgelenmelerin ve hareketlenmelerin çok olduğu sık ormanlık, sulak ortamlardır. Dolayısı ile arka planda çok fazla hareketli nesnenin olduğu yabancı hayatını içeren bir video sahnesinde görüntü işleme ile yabancı hayvanının tespit edilmesi zor bir işlemdir. Tespiti istenen yabancı hayvanının diğer hareketli nesnelere ayrılması için alan testi (yöntem-1), öznelik testi (yöntem-2) ve RGB (Red-Green-Blue) renk testi (yöntem-3) olmak üzere toplam 3 yöntem geliştirilmiştir.

Alan testi (yöntem-1) ile video sahnesinde hareketli nesnenin belli mesafeler arasında alabileceği minimum ve maksimum alan değerlerine bağlı olarak görüntü sahnesinde filtreleme yapılır. Bu yöntem ile arka planı GMM ile çıkarılmış bir video sahnesinde arka planda yer alan birden fazla hareketli nesne içerisinde sadece hedeflenen nesnenin tespit edilmesi sağlanmıştır. Ayrıca hareketli nesne tespitinde bu yöntem ile nesnede alan bütünlüğünün sağlanıp sağlanmadığı tespit edilmiştir. Çünkü alan bütünlüğü sağlanmamış bir nesnenin sınıflandırılması yanlış tür tespitine neden olur.

Alan testi sonrası arka planda kalan hareketli nesne izine öznelik testi (yöntem-2) uygulanmıştır. Öznelik testi görüntü arka planında yer alan alan bütünlüğüne sahip bir hareketli nesneyi diğer hareketli nesnelere ayırmanın en kolay yöntemidir. Arka planda nesne izi alan testi ile her ne kadar filtrelenmiş olsa da izli bölgenin tespitinin hedefte olan yabancı hayvanı türüne ait olup olmadığı belirlenemez. Öznelik testi ile video sahnesindeki hareketli nesne izlerinden hedefte olan yabancı hayvanı türü ve sayımı yapılması sağlanır.

Geliştirilen yaklaşımlardan bir diğeri RGB renk testi (yöntem-3) yöntemidir. Yöntem-3 sayesinde alan testi ve öznelik testi ile aşılması mümkün olmayan video sahnelerinde hedeflenen nesnenin tespiti ve sayımı yapılmıştır. Renk faktörü nesnelere tanınmasının ve birbirinden ayırt edilmesini sağlayan en önemli unsurdur.

Hareketli nesne tespitinde hedeflenen nesneye ait renk bilgilerinin kullanılması aynı video sahnesinde yer alan farklı türe ait yaban hayvanlarının bertaraf edilmesine olanak sağlamaktadır. Görüntü işleme tabanlı dinamik nesne tespitinde yöntem 1, 2 ve 3 hedeflenen nesne tespitine olanak sağlar.

Yaban hayvanı tür tespitinde başarımlarını belirleyen diğer önemli bileşen nesnenin tanınması üzerinedir. Literatürde nesne tanıma için öznelik çıkarımı üzerine birçok algoritmalar geliştirilmiştir[8],[9]. Literatürde yaygın kullanılan nesne tanıma algoritmalarından başlıcaları: SIFT algoritması (Scale Invariant Feature Transform, Ölçek değişmez özellik transformu), SURF algoritması (Speeded Up Robust Features, Hızlandırılmış sağlam özellikler), FAST algoritması (Features From Accelerated Segment test, hızlandırılmış segment testinden gelen özellikler, LBP algoritması (Local Binary Pattern, yerel ikili örüntü), HoG algoritması (Histogram of Oriented Gradients, Yönlü Gradyan Histogramı), MSER (Maximally Stable Extremal Regions, Maksimum durağan uç bölge) metodlarıdır.

Yaptığımız çalışmada nesne tanıma öznelik çıkarımı üzerine herhangi bir hazır algoritma kullanılmamıştır. Hareketli nesnenin fiziksel öznelikleri ile yaban hayvanı üzerinde belirlenen yeni koordinatlarından alınan piksel renk bilgilerinin ortalaması alınarak renksel öznelik kullanılmıştır. Bu sayede yaban hayvanı tür tespitinde %100 başarımlarına ulaşılmıştır.

Başarılı bir şekilde dinamik nesne tespitinin yapılması ve nesnenin tanınması sonrası gelen adım nesnenin sınıflandırılmasıdır. Sınıflandırmada kullanılacak olan yapay sınıflandırıcılarının performansı da yaban hayvanı tür tespitinde sonucu etkilemektedir. Başarımları yüksek bir sınıflandırma için çeşitli videolardan alınan yaban hayvanları görüntülerinin anlık çerçeve başına fiziksel ve renksel öznelikleri çıkarılmıştır. Sınıflandırma için yapay sinir ağları (YSA) ve destek vektör makineleri (DVM) eğitilmiş, başarımları karşılaştırılmıştır. Yaban hayvanı tür tespitinde YSA'nın daha başarılı sınıflandırma yaptığı tespit edilmiştir. Yapay sınıflandırıcı olarak YSA kullanılmıştır [10].

Aşırı esne yapıya sahip geometrik ölçüleri her an değişebilen yaban hayvanları en zor video sahnelerine sahip yaban hayvanı videolarında geliştirilen yöntemler ile %100 başarımlar tespit edilmiştir. Son olarak sınıflandırılması yapılan yaban hayvanı video çerçevesinde sınırlayıcı kutu içerisine alınıp takibi ve sayma işlemi gerçekleştirilmiştir.

Yaban hayvanları gibi geometrik şekli her an değişebilen canlıların tespitinde fiziksel ve renksel özneliklerin kullanılması ile %100 doğruluk oranının yakalanması yapılacak olan tüm nesne tanıma çalışmalarına örnek olacak, diğer tüm çalışmalarda ve özellikle geometrik şekli belli nesnelere tespitinde başarımlarını yükseltecektir.

Makalenin izleyen bölümlerinde literatürde yapılan başlıca çalışmalara yer verilmiştir. Çalışmanın ikinci bölümde amaçlanan hedef doğrultusunda geliştirilen yaklaşımlar ve uygulanan yöntemlerin detayları açıklanmıştır. Üçüncü bölümde elde edilen deneysel sonuçlar ve sonuçların analizi ortaya konulmuştur. Son bölümde ise çalışmanın önemi, görüntü işleme ile nesne tespiti konusunda geliştirilen yaklaşımların literatüre katkısı vurgulanmıştır.

1.1 Literatür özeti

Görüntü işleme tekniği ile yaban hayvanları tanıma konusunda çeşitli çalışmalar mevcuttur. Yapılan bu çalışmalarda farklı yöntemler kullanılarak farklı başarımlarında yaban hayvanları tespit edilmiştir. Yapılan çalışmalarda yaban hayvanlarını, bilgisayarlı görme sistemlerinde en yüksek başarımları ile tanıma hep ortak hedef olmuştur.

Matuska ve diğ. [11] tarafından yapılan çalışmada vahşi hayvanların BOW (Bags of keypoints) kelime çantası yöntemi ile sınıflandırma ve DVM ile sınıflandırılması çalışması yapılmıştır. Kurt, tilki, kahverengi ayı, geyik ve yaban domuzu gibi Slovak ülkelerinde bulunan büyük hayvanların sınıflandırılması yapılmıştır. Nesne tanıma imgedeki kilit noktaları bulmaya yarayan SIFT, SURF ve bu iki yöntemde bir arada kullanıldığı melez bir yöntem olan SISURF(SIFT-SURF) ile SUSIFT(SUFT-SIFT) yöntemi kullanılmıştır. Bu 4 yöntem ile elde edilen özellikler BOW ve DVM sınıflandırıcı ile karşılaştırmalı olarak yapılmış ve yaban hayvanı tanıma %86 en yüksek başarı doğruluğu oranı ile SISURF algoritmasına dayalı yöntem olduğu tespit edilmiştir.

Yu ve diğ. [12] tarafından yapılan çalışmada 18 adet yaban hayvanının 7000'den fazla fotokapan görüntüsü üzerine tür tespiti için, cLBP (Hücrenin Özellikleri Yapılandırılmış yerel ikili kalıplar) ve SIFT+cLBP algoritmaları uygulanmıştır. %82'lik bir ortalama sınıflandırma doğruluğu elde edilmiştir.

Alli ve Viriri [13] yaptıkları çalışmada hayvanların ayak izlerinin görüntü işleme teknikleri ile morfolojik açımlarla en iyi görüntüyü yakalamış ve ayak izindeki piksellerin sayısını sayarak ölçülmüş ve %97'lik bir başarımları ile hayvan türünü tespit etmiştir.

Boniecki ve diğ. [14] tarafından yapılan çalışma ile elma ağaçlarına zarar veren 6 adet zararlı böceğin görüntü işleme ve sinir ağları ile tanımlamasını yapmıştır. Bu zararlı böceklerin yüzey alanı çevre uzunluğu gibi geometrik şekilsel özelliklerinin yanında renk faktöründe kullanılmış ve 1200 adet görüntü imgesi kullanılmıştır. YSA ile veriler eğitilmiş başarılı sonuçlar elde edilmiştir.

Risse ve diğ. [15] tarafından hareketli kamera kullanarak doğal ortamlarda hayvanların görüntü tabanlı izlenmesini %96 doğruluk başarımları ile gerçekleştirmişlerdir.

Jasko ve diğ. [16] yaptıkları çalışmada belirlenen bölgelerde yaşayan yaban hayvanlarının tür tespitini yaparak vahşi hayvan trafiğini gözlemeyi hedeflemişlerdir. Çalışmalarında DVM sınıflandırıcı ile %90 üzeri doğruluk başarımlarına ulaşmışlardır.

Son yıllarda bilgisayarlı görme uygulamalarında nesne tanıma ve izleme uygulamaların da popüler olan derin öğrenme (deep learning) tekniklerindeki son gelişmelerden yararlanılmaktadır.

Nguyen ve diğ. [17] tarafından öğrenme tekniklerinden yararlanarak otomatik vahşi yaşam izleme sistemi inşa eden bir derin öğrenme yaklaşımının fizibilitesini çalışmalarında ortaya koymuşlardır. Yaban hayvanlarını tanıma %96 doğruluk başarımlarını yakalamışlardır. Bu başarımlar birbirine özellikleri itibarı ile yakın olan ortak hayvanlarda(fare, sıçan gibi) %90'a ulaşmıştır.

G. Villa ve diğ. [18] tarafından yapılan çalışmada sinir ağlarının yaban hayvanı sınıflandırmadaki problemlerini çözmeye yönelik kendi oluşturduğu veri kümesi ile diğer veri kümelerini karşılaştırmıştır.

Çalışmasında kullandığı yeni sinir ağı mimarisi ile yaban hayvanı tür tespitinde %98.1 doğruluk başarımını yakalamıştır.

Son zamanlarda yapılan böcek tanıma ve sınıflandırma çalışmalarında doğruluk başarı oranı % 90'ı yakalamıştır. Ayrıca literatürde hayvanın fiziksel özelliklerinin hayvan türü tespitinde kullanıldığı, bazı renk bazlı çalışmaların özellikle balık tazeliği ve türü tespiti gibi daha dar kapsamlı çalışmalarda kullanıldığı gözlemlenmiştir.

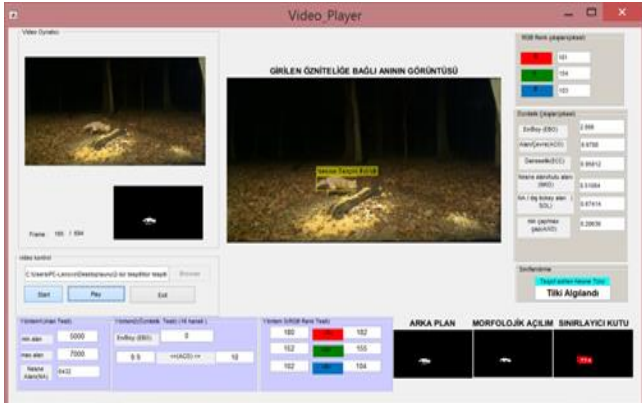
Nesne tanımda Graves ve Batchelor [19] yaptıkları çalışmalarında nesnenin şekline dayalı öznelik çıkarımları için bazı şekil tanımlayıcılar önermiştir. Bu ikili şekil tanımlayıcılar nesnenin piksel sayısı, blob (izli bölge) kenarı üzerindeki en uzak noktanın merkeze olan uzaklığı, blob kenarı üzerindeki en yakın noktanın merkeze olan uzaklığı, gerçek resim alanı ile resme ait çevresel daire alanlarının oranı, majör ve minör eksenlerin oranıdır.

Sonugür [20] insansız kara araçları için görüntü işleme tabanlı nesne tespiti başlıklı çalışmada hareketli bir nesnenin özneliklerinin çıkarılmasında oran değişmezliğinden yola çıkarak çalışmada özneliklerin oranlarını kullanmış ve nesne tanımda arka plan görüntüsünde mesafe ile alan değişiminin olumsuzluğunu ortadan kaldırmıştır.

2 Yöntem

Görüntü işleme tekniği ile yaban hayvanı tür tespiti ve sayımına yönelik tüm yöntemler ve çıkarılan tüm deneysel sonuçlar Matlab 2015a sürümünde yapılmıştır. Bu makale çalışmasında nesne tanıma ve sayımı için videolardan ayıklanan görüntü çerçeveleri Matlab yazılım ortamında bir takım sayısal işlemlere ve yöntemlere tabi tutulmuştur. Ayrıca Matlab GUI ile etkili ve kolay kullanım amaçlı arayüz hazırlanmıştır. Yine Computer Vision System Toolbox araç kutusu ile ve Neural Network Toolbox araç kutusu ile nesne tanımda başarımlarını arttıran yöntemler geliştirilmiştir.

Yöntem 1, 2, 3'te verilen işlemler Şekil 2'de görülen gerçek zamanlı video nesne tespit ve öznelik çıkarma arayüz modülü ile yapılmaktadır.

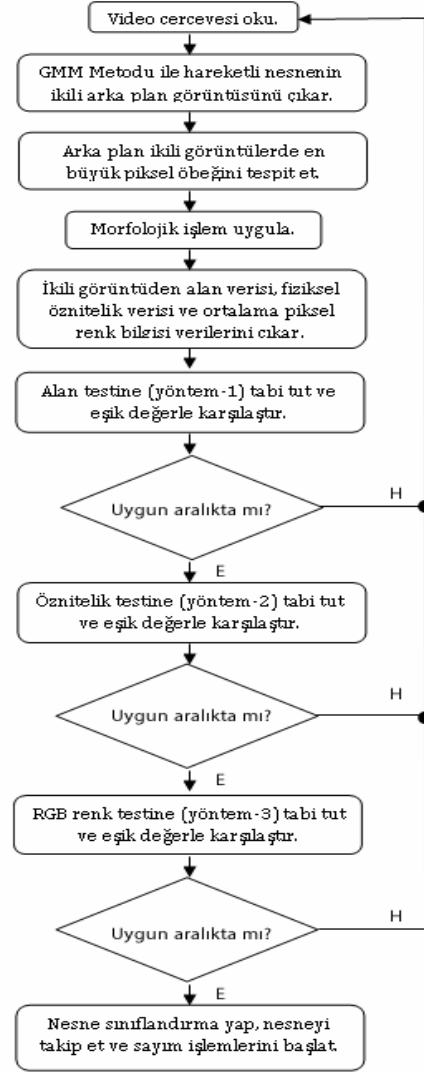


Şekil 2: Video oynatıcı, Nesne tanıma, fiziksel ve renksel öznelik öznelik çıkarıcı modül.

Hazırlanan bu arayüz modülü ile yaban hayvanına ait istenilen video görüntüleri yüklenip oynatılabilir. Geliştirilen alan testi (yöntem-1), öznelik testi (yöntem-2) ve RGB renk testi (yöntem-3) ile yaban hayvanlarına ait belirlenen alan, öznelik ve renk yoğunluğu değerleri kullanıcı tarafından girilerek hedeflenen yaban hayvanı en zor sahnelerde bile tespit edilebilir. Tespit edilen yaban hayvanına ait belirlenen fiziksel ve renksel öznelikler anlık video çerçevesi ile çıkarılır. Video

görüntüsündeki yaban hayvanı anlık sınıflandırılır ve algılanan yaban hayvanı türü yazılı olarak gösterilir. Arayüz diğer hareketli nesnelerin tespitine de uyarlanabilir [21].

Herhangi bir video sahnesinde yaban hayvanlarının tespiti için geliştirilen yaklaşımlarında yer aldığı genel akış algoritması Şekil 3'te verilmiştir.



Şekil 3: Yaban hayvanı tür tespiti ve sayımı için kullanılan genel akış diyagramı.

2.1 Alan testi (yöntem-1), Öznelik testi(yöntem-2) ve RGB renk testi (yöntem-3) ile hedeflenen hareketli nesne tespitinin yapılması

Herhangi bir görüntü çerçevesinde de aynı sahnede yer alan farklı tür canlıların piksel olarak kapladıkları alanlar farklıdır. Burada önemli olan mesafe kavramıdır. Çünkü nesnenin kameraya olan uzaklığı arttıkça görüntüdeki kapladığı nesne alanı da küçülmektedir. Dolayısı ile görüntü kaynağına yakın çekim yapılan bir tilki uzaktaki bir geyikten arka plan nesne alanı olarak daha büyük görünür. Bunu önlemek için foto kaptarlarda hareket sensörü bulunur. Hareketli nesne genelde 30 metre ve daha ötesi mesafelerdeki hareketi algılamaz. Uygulamada hareket sensörünün yaptığı işi görüntü işlemede alan testi kriteri ile yapabiliriz.

Alınan fotokapan görüntüleri ve yapılan mesafe ölçümleri sonucu 20 metre uzaklıktaki bir geyiğin alanın 15801 piksel çıkmıştır. Çeşitli fotokapan videolarında tilki yaban atı ve geyiklerin öz nitelikleri yanında nesne alanları da piksel cinsinden çıkartılmış ve Tablo 1'deki sonuca varılmıştır.

Tablo 1: Bazı yaban hayvanlarının alan değerleri.

Yaban hayvanları	Ortalama alan	Minumum alan	Maksimum alan
Tilki	4000	1000	10000
Geyik	17000	8000	50000
Yaban Atı	52000	20000	80000

Alan testinin nesne tespiti ve sınıflandırmada sağlayacağı yararlar şunlardır:

1. Alan testi ile aynı sahnede yer alan birden fazla hareketli nesne içerisinde sadece hedeflenen nesnenin tespit edilmesi sağlanmıştır,
2. Arka planda tespit edilen hareketlinin eğer alan bütünlüğü yoksa (çevredeki ağaç, yapı vb. gölgesi nesne üzerine düşmesi vs.) ve arka plan ikili görüntüsü tama yakın değilse sınıflandırmalarda yanlış yapılacağından bu kriter ile yanlış sınıflandırmanın önüne geçilecektir,
3. Görüntü kaynağına aşırı uzaktaki veya aşırı yakındaki nesnelerin arka plan görüntüleri de fiziksel olarak bir şeye benzemeyeceğinden bu objelerin arka plan görüntüleri nesne tanımada yanlışlıklara neden olmaktadır. Alan kriteri ile bunun önüne geçilmektedir,
4. Alan kriteri ile ayrıca arka planda hareket eden çevresel faktörlerinde (ağaç, yaprak, bayrak sallanması vs.) algılanmasının önüne geçilmiş ve nesne tanımadaki olumsuzluğu ortadan kaldırılmıştır,

Hedeflenen hareketli nesne tespitinde video sahnesine uygulanan diğer yöntem öz nitelik testi olan yöntem-2'dir. İlk olarak yaban hayvanlarının dinamik video görüntülerinden GMM metodu ile arka plan görüntüleri çıkartılmıştır.

Şekil 4'te fotokapan video sahnesinden hareketli nesne olarak geyik tespit edilmiş ve geyiğin GMM metodu ile arka plan görüntüsü çıkarılmıştır. Şekil 5'te ise Şekil 4'teki video sahnesinin GMM metodu ile arka plan görüntüsü çıkarılmıştır.

Video Karesi



Şekil 4: Fotokapan video sahnesi.


Ön plan maskesi



Şekil 5: Şekil 4'te tespit edilen hareketli yaban hayvanının GMM metodu ile arka planı görünümünün çıkarımı.

Şekil 5'te görüldüğü üzere arka plan görüntüsünün bu hali ile net çıkmadığı görüntüde çok fazla piksel kopmalarının olduğu ve nesne özelliklerinin tam çıkamayacağı aşikârdır. Bu gibi durumlarda nesne tespiti yapılsa da nesnenin doğru bir şekilde tanınması ve etiketlenmesi imkânsızdır. Bundan dolayı bu şekilde eksik ve aşırı gürültülü arka plan görüntülerinin iyileştirilmesi için morfolojik açma ve kapama işlemleri uygulanması gerekmektedir.

Şekil 5'te arka plan görüntüsü elde edilen yaban hayvanına morfolojik olarak önce açma sonra kapama işlemleri uygulanmıştır. Morfolojik işlemler sonrası Şekil 6'daki arka plan görünümü elde edilmiştir. Şekil 6'da görüldüğü üzere piksel kopmaları giderilerek hareketli nesnenin arka plan görüntüsünde alan bütünlüğü sağlanmıştır.




Şekil 6: Şekil 5'te arka planı çıkarılmış görüntüye morfolojik işlem uygulanması.

Tespit edilen hareketli yaban hayvanı arka plan görüntüsünden aşağıdaki 6 adet öz nitelik matrisi çıkarılmıştır. Bunlar:

1. EBO: Nesnenin piksel cinsinden en/boy oranıdır,
2. ACO: Nesnenin piksel cinsinden nesne alanı/çevre uzunluğu oranıdır,
3. ECC: Dairesellik kavramı olup piksel cinsinden nesnenin,
4. Alanı /çevre² oranıdır. 0-1 arası bir değer olup 1 değerine yakın çıkan sonucun daireselliğe yaklaşıldığını 0 değerine yakın çıkan sonuç ise çizgiselliğe yaklaşıldığını gösterir,
5. 4-NKO: Nesne içine girebileceği en küçük sınırlayıcı kutu ile çerçevesinin. Nesnede piksel cinsinden sınırlayıcı kutu alanı/nesne alanı oranıdır,
6. 5-SOL: Nesnenin piksel cinsinden alanı/dış bükey alanı oranıdır,
7. 6-AXO: Nesnenin içine girebileceği en küçük daire veya elips için minimum çap/maksimum çap oranıdır.

Şekil 7'de görüntü kaynağına 20 m mesafede tespit edilen dişi kızıl geyiğin sınırlayıcı kutu içerisine ve Tablo 2'deki fiziksel öznitelikleri piksel cinsinden çıkarılmıştır.



Şekil 7: Fotokapan videosunda 20 m uzakta tespit edilen dişi kızıl geyiğin arka plan görüntüsü.

Tablo 2: Dişi geyiğin fiziksel özniteliklerinin çıkarılması.

Fiziksel öznitelikler	Öznitelik değerleri
NESNE ALANI	17561
EBO	1.5476
ACO	14.9413
ECC	0.85713
NKO	0.40204
SOL	0.50653
AXO	0.7854

Çeşitli fotokapan video sahnelerinden tilki, yaban atı ve geyiklerin öznitelikleri piksel cinsinden çıkarılmış ve Tablo 3'teki sonuca varılmıştır.

Tablo 3: Bazı yaban hayvanlarının ACO değerleri.

Yaban hayvanları	Ortalama ACO	Minimum ACO	Maksimum ACO
Tilki	7	4	10
Geyik	16	6	26
At	56	12	100

Yapılan çalışmada alan kriteri sonrası tespit edilen hareketli nesne ikinci olarak 6 adet öznitelikten biri olan ACO yani alan/çevre oranı ile de teste tabi tutulmaktadır. Çünkü görüntü çerçevesinde nesne alanı görüntü kaynağına olan mesafeye bağlı olarak değişmekte ise de oran kriteri mesafeye bağlı olarak değişmez. Bu testi de sağlayan nesnenin ikili arka plan görüntüsünü sınıflandırmaya tabi tutmak nesnenin doğru etiketlenmesinde başarıyı bir adım daha arttırmaktadır. Bu yöntem ile hareketli nesne diğer hareketli nesnelere ayrılır. Bu kriterler tespit edilmesi istenen nesnenin esnekliğine göre artırılabilir veya azaltılabilir.

Yaban hayatı video sahnesinde hedeflenen yaban hayvanının tespitinde uygulanan diğer yöntem ise RGB renk testi olan yöntem-3'tür.


Yapılan çalışmada arka plan ikili görüntüden çıkarılan fiziksel özniteliklerin yanında tespit edilen yaban hayvanın ön plan RGB renkli görüntüsünden de renk pikselleri olarak renksel öznitelik çıkarılmıştır. İlk aşamada arka plan ikili görüntüsünden çıkarılan fiziksel özelliklere bağlı olarak tespit edilen yaban hayvanının ağırlık merkezinden renk pikselleri alınmıştır. Fakat uygulama piksel alınan noktanın hayvanın hareketine bağlı olarak bazen hayvan üzerinde bazen hayvan dışında sahne üzerinde başka noktalara denk geldiği ve yanlış noktalardan renk pikseli alındığı görülmüştür. Yaban hayvanı simetrik bir şekle sahip olmadığından dolayı hayvanın ağırlık merkezi ile geometrik merkezi aynı değildir. Ağırlık merkezi nesnenin anlık duruş şekline bağlı olarak sürekli değişmekte ve genelde daha fazla piksele sahip olan hayvanın baş kısmına

yakın bir noktada çıkmaktadır. Çoğu zaman da nesnenin kütlesi dışında özellikle geyikte ağırlık merkezinin hayvanın bacakları arasındaki boşluğa denk geldiği gözlemlenmiştir.

Bu da hayvanın üzerinden renk bilgisi almak yerine sahnedeki başka koordinatlardan piksel rengi bilgisi alınmasına neden olmuştur.


Bu olumsuzluğu ortadan kaldırmak için sınırlayıcı kutunun 9 sütun ve 3 satıra bölünerek genelde yaban hayvanının gövdesine denk gelecek şekilde piksel koordinatları belirlenmiştir. Belirlenen bu piksel koordinatları kesişiminden renk pikseli bilgisi alınmıştır. Bu da her hayvanda hayvanın fiziksel özelliğine bağlı olmaksızın direk gövde kısmına denk gelmektedir. Fakat hayvanın bazı yerlerinde renk yoğunluğunun değişik olduğu tespit edilmiş olup 3 ayrı noktanın renk bilgisi alınıp ortalaması bulunarak nesne tanıma yapılmıştır. Ayrıca yeni koordinatı belirlenen 3 nokta hayvanın görüntü kaynağı karşısında ön, sağ, sol ve arka duruş konumlarına göre hayvan yüzeyinde gezmektedir. Diğer taraftan hayvanın baş gövde kuyruk gibi birkaç noktasından renk bilgisi alınmasının nesne tanımda başarıyı daha da arttıracığı aşikârdır. Fakat yaban hayvanından 3 noktanın renk pikseli alınarak %100 başarı elde edildiği için daha fazla noktadan renk pikseli alma veya hayvanın renk haritasını çıkarmaya gerek duyulmamıştır. Çünkü programda eklenecek her komutun belli bir işleme süresi mevcut olup programın gecikmeye neden olmaktadır. Aynı zamanda programın bellekte kaplayacağı yerde artmaktadır.

Şekil 8'de görüldüğü gibi tilki normal olmayan bir pozisyonda bulunmakta ve arka planı çıkarıldığında tilkinin ağırlık merkezi (kırmızı nokta) bacakları arasında hayvanın üzerinde olmayan bir nokta çıkmıştır.



Şekil 8: Farklı fiziksel şekil alan tilkinin arka plan çıkarımı.

Şekil 9'da görüldüğü gibi ağırlık merkezi dışında yaban hayvanının gövde kısmına denk gelecek şekilde yeni piksel koordinatları belirlenmiştir. Tilkinin o anki pozisyonunda yeni belirlenen noktaların hayvanda nereye denk geldiği gösterilmiştir.



Şekil 9: Yaban hayvanı üzerinde piksel rengi bilgisi alma.

Belirlenen 3 yeni noktasının her bir pikselinin yeni x ve y koordinatları aşağıdaki şekilde hesaplanmıştır.

1 No.lu noktanın yeni koordinatı:

$$(X_o + ((4 \times en) / 9), Y_o + (boy / 3)) \quad (1)$$

2 No.lu noktanın yeni koordinatı:

$$(X_o + ((5 \times en) / 9), Y_o + (boy / 3)) \quad (2)$$

3 No.lu noktanın yeni koordinatı:

$$(X_o + ((6 \times en) / 9), Y_o + (boy / 3)) \quad (3)$$

Belirlenen yeni koordinatlardaki pikselin renk bilgisi bulunmuş aşağıdaki şekilde bu renklerin ortalaması alınarak hayvana ait renksel öznitelik elde edilmiştir.

$$R_{ort} = (R_1 + R_2 + R_3) / 3 \quad (4)$$

$$G_{ort} = (G_1 + G_2 + G_3) / 3 \quad (5)$$


$$B_{ort} = (B_1 + B_2 + B_3) / 3 \quad (6)$$

Yaban hayvanı üzerinde belirlenen yeni piksel koordinatları ile yapılan çalışmalarda çeşitli yaban hayvanları videosundan alınan gerçek zamanlı yaban hayvanlarına ait RGB renk yoğunlukları Tablo 4'te verilmiştir.

Tablo 4: Bazı yaban hayvanlarının Gün Işığında Ortalama RGB yoğunluk değerleri

Bazı Yaban Hayvan Türleri	Ortalama Renk Yoğunlukları Değerleri		
	R(kırmızı)	G(yeşil)	B(mavi)
Koyu Kızıl Tilki	145	115	75
Kızıl Geyik	80	68	71
Kahverengimsi Geyik	90	84	81
Beyazımsı Yaban Atı	218	243	255
Gri Kurt	130	130	138

Görüldüğü üzere farklı türdeki yaban hayvanlarının renk yoğunluk değerleri de birbirinden farklıdır. Yaban hayvanları genelde geceleri daha fazla hareket kabiliyeti kazanırlar. Yapılan çalışmalar ile ortamın ışık etkisinin, ışığın görüntü kaynağına geliş açısının ve nesne yüzeyinin yapısının nesne rengini algılamada değişikliklere yol açtığı ortaya konulmuştur. Bundan dolayı yaban hayvanı tür tespitinde sınıflandırıcı eğitimi için Şekil 10'da görüldüğü gibi gece görüş özelliğine sahip kamera ile alınan video sahnelerinde de hedeflenen yaban hayvanı yöntem 1, 2 ve 3 ile başarılı bir şekilde tespit edilmiş olup renk bilgisi çıkarılmıştır.



Şekil 10: Fotokapanda gece görüş ile tespit edilen yaban hayvanı sahne görüntüsü.

Tablo 5'te görüldüğü gibi kızıl geyiğin gün ışığındaki ve gece kızılötesi IR (infrared) kamera ile çekilmiş video sahneleri görüntü işleme ile işlendiğinde kızıl geyiğe ait renk verilerinin değiştiği ve gece görüş ile hayvanın farklı bölgelerinden alınan piksellere ait ortalama RGB renk yoğunluklarının da eşit çıktığı görülmektedir. Bu durumun yol açtığı olumsuz etkiden etkilenmemek için yaban hayvanlarının gece görüş kamera videolarından elde edilen görüntülerinde eğitilmesi gerekir.

Tablo 5: Kızıl geyiğin gün ışığında kamera ve gece görüş kamera görüntülerinden elde edilen ortalama RGB yoğunluk değerleri.

Kızıl Geyik	Ortalama Renk Yoğunlukları Değerleri		
	R(kırmızı)	G(yeşil)	B(mavi)
Gün ışığında	80	68	71
Gece görüş (aynı hayvanın farklı bölgesi)	123	123	123
Gece görüş (aynı hayvanın farklı bölgesi)	141	141	141


2.2 Nesne tanıma, sınıflandırma ve sayım işlemleri

Doğru bir şekilde hareketli nesne tespiti yapıldıktan sonra en önemli aşamalardan biriside tespit edilen nesnenin doğru bir şekilde sınıflandırılıp etiketlendirilmesidir. Şekil 2'de görüldüğü gibi nesnenin fiziksel özneliği ve renksel özelliklerinden meydana gelen 9 adet belirleyici özneliği sınıflandırıcıda eğiterek 4 adet yaban hayvanının sınıflandırması yapılmıştır.

İnsan veya cansız nesnelerin görüntü sahnesindeki alabileceği pozisyonlar ve ölçülerinde meydana gelecek değişiklikler az çok belli iken hayvanlarda bu durumun kestirilmesi imkânsızdır. Örneğin iki ayağa kalkan bir geyiğin sınıflandırılmasının sadece fiziksel ölçülerden yola çıkılarak yapılması sınıflandırmada başarı oranının düşürür ve yanlış nesne etiketlendirilmelerine neden olur.

Bu çalışmada aynı zamanda nesne tanımda renk faktörünün başarıyı ne kadar arttırdığı da ortaya koyulmuştur.

Şekil 11'de tasarlanan yapay sınıflandırıcının mimarisi görülmektedir. Gerçek zamanlı fotokapan videolarında elde edilen geyik, tilki, kurt ve yaban atı görüntülerinin önce fiziksel ve renksel öznelikleri çıkarılmıştır. Bu öznelikler ile önce destek vektör makinaları (DVM) ile sınıflandırma yapılmış sonra da yapay sinir ağları (YSA) sınıflandırma yapılmıştır. Her iki sınıflandırıcının başarı oranları karşılaştırmalı olarak denenmiştir.



Şekil 11:Tasarlanan sınıflandırıcı mimarisi.

YSA uygulamada Çok Katmanlı İleri Beslemeli bir yapay sinir ağı kullanılmıştır. Bu çalışma kapsamında geliştirilen ileri beslemeli YSA'da 9 adet girdi ve 4 adet çıktı nöronunu bulunmaktadır. Geliştirilen YSA tek gizli katmandan oluşmaktadır. Oluşturulan ağ modellerinde girdi katmanı ile gizli katman arasında tanjant hiperbolik transfer fonksiyonu, gizli katman ile çıktı katmanı arasında ise doğrusal transfer fonksiyonu kullanılmıştır.

Gizli katmanlardaki nöron sayılarının tespitine yönelik sabit bir kural olmadığından, deneme ağırları üretilerek en uygun nöron sayısı belirlenmeye çalışılmıştır.

YSA' da öğrenme amaçlı birçok algoritma kullanılmaktadır. Bu çerçevede, tasarlanacak ağ için 1'den 30'a kadar nöron denemesi yapılmıştır. Her biriyle 6 farklı eğitim algoritması ile eğitilerek toplam 180 adet ağ üretilmiştir. YSA da her zaman belirlenen ağdan daha iyi bir ağ elde etme olasılığı olduğundan dolayı en başarılı ağ yapısının belirlenmesi için her ağda en az 400 yenileme yapılmıştır. En yüksek başarımla 22 nöronla eğitimde ölçeklenmiş eşlenik gradyan iniş algoritmasının (Scaled conjugate gradient) kullanılması ile bulunmuştur.

DVM uygulamada ise YSA ile aynı mimariye sahip 9 adet girdi verisinin 4 adet çıktı şeklinde sınıflandırılması yapılmıştır. Çekirdek fonksiyonu olarak en sınıflandırma başarımla yakalandığı lineer fonksiyon seçilmiştir. Çoklu sınıflandırma yöntemi olarak yüksek başarımla elde edildiği bire karşı bir (BKB) kullanılmıştır. Çekirdek fonksiyonu genişliği (γ) ve düzleştirme parametresi (c , ceza katsayısı) doğruluk oranı en yüksek değer elde edinceye kadar değiştirilmiştir. Yapılan deneylerde DVM parametrelerinden $\gamma = 10$, $c=1000$ olduğu değerlendirilmiştir.

Literatürde YSA ve DVM eğitiminde birçok araştırmacının giriş verilerini [%80, %10, %10] veya [%70, %15, %15] ya da [%60, %20, %20] kuralını temel alan bir yöntem izlediği görülmektedir. En yüksek sınıflandırma başarımları bahse konu 3 ayrı oran denenerek uygulanmıştır. Her iki sınıflandırıcıda da en yüksek başarımla elde edildiği giriş verilerinin %70'i eğitim, %15'i doğrulama ve %15'i test için kullanıldığında elde edildiği gözlemlenmiştir. Her iki sınıflandırıcının başarımları karşılaştırılmış ve YSA'nın daha yüksek başarımla sınıflandırma yaptığı görülmüştür.

Yapılan karşılaştırmalarda kurt ve tilki gibi fiziksel özellikleri birbirine çok yakın olan yaban hayvanlarının sınıflandırılmasında başarı oranı düşük çıkarken tür sayısının azalması ve birbirine göre fiziksel özellikleri arasındaki sayısal farkın daha yüksek olduğu türlerin sınıflandırılmasında başarı oranının daha yüksek olduğu tespit edilmiştir.

Ayrıca ortalama başarı oranına göre yaban hayvanlarının sınıflandırılmasında YSA ile sınıflandırmada DVM ye göre daha üstün başarımla elde edildiği için çalışmamızda YSA ile sınıflandırma kullanılmıştır. Literatürde özellikle sınıflandırma çalışmalarında YSA'nın DVM'ye oranla daha üstün başarımla sonuçlar verdiği çalışmalar mevcuttur. Bu durum tamamen eğitim verileri arasındaki matematiksel ilişkiyle alakalıdır. Genel olarak eğitim verileri arasında matematiksel olarak oransızlığın fazla olduğu durumlarda YSA DVM'ye göre daha iyi öğrenme sonuçları vermektedir. Bir başka deyişle DVM eğitim oranlarına daha az duyarlıdır [22]-[24].

Son olarak anlık görüntüde etiketlenilen hayvanın takibi ve sayımı yapılmıştır. Doğru şekilde tespit edilip sınıflandırılması yapılan yaban hayvanı video çerçevesinde sahne süresince sınırlayıcı kutu içerisinde alınıp takibi ve sayma işlemi gerçekleştirilmiştir. Şekil 12'de fotokapan video sahnesinde tespit edilen yaban hayvanının tür tespiti ve sayımının yapıldığı görülmektedir.



Şekil 12: Fotokapan video sahnesinde tür tespiti ve sayımı yapılan yaban hayvanı [25].

3 Deneysel sonuçlar

3.1 Alan testi (yöntem-1), Öznitelik testi (yöntem-2) ve RGB renk testi (yöntem-3) ile hedeflenen nesne tespitinin yapılması üzerine fotokapan videosu ile yapılan çalışma

Alan ve öznitelik testi yöntemi kullanılarak yapılan çalışmalarda hedeflenen yaban hayvanının doğru bir şekilde tespit edilmesi, arka plandaki ikili görüntüde alan bütünlüğü olmadan yapılan yaban hayvanı tespiti ve akabindeki yaban hayvanı türü belirlemenin doğru sonuçlar vermeyeceği ortaya konulmuştur.

Şekil 13'te yaban hayatında nadir görülen iki farklı türe ait olan rakun ile geyiğin aynı sahnede yer aldığı görülmektedir. Şekil 14'te geyiğin uzun süre hareketsiz kalmasından ve hayvan yüzündeki ışık yansımalarından dolayı belli bir süre arka plan izinin tam çıkmadığı, alan bütünlüğünün sağlanmadığı görülmektedir.

Şekil 13'te aynı zamanda alan testi ve öznitelik testi kullanılmadan hedef dışı yanlış yapılan yaban hayvanı tespiti ve sınıflandırılması görülmektedir. Aynı sahnede rakunun arka plan izi daha net çıktığı için sınıflandırıcıya rakunun fiziksel özellikleri giriş verisi olarak verilmiştir. Bunun sonucunda rakun belli bir zaman diliminde geyik olarak sınıflandırılmıştır. Sahnenin o anı için nesne tespiti ve sınıflandırma yapmadan videonun ilerleyen çerçevelerinde bu kriterlerin yerine gelmesi ile bu gibi olumsuzlukların ortadan kaldırıldığı görülmüştür.



Şekil 13: Alan testi ve öznitelik testi kullanılmadan yapılan yanlış yaban hayvanı tespiti [26].




Şekil 14: Şekil 13'teki sahnenin GMM yöntemi ile arka plan çıkarımı.

Şekil 15'te en zor sahne şartlarında dahi hedeflenen yaban geyiğinin tespiti ve takibi yapıldığı görülmektedir.



Şekil 15: Alan testi ve öznelik testi kullanarak yapılan doğru yaban hayvanı tespiti [27].

Şekil 16'daki sahnede görüldüğü üzere ikili görüntüde görüntü kaynağı ile nesne arasında yer alan ağaç görüntüsü alan bütünlüğünde eksikliğe neden olmuştur. Bu şekilde o anki eksik arka plan görüntüsü ile nesne tanıma, sınıflandırmanın yanlış olacağı aşikârdır. Çünkü kalan pikseller tam anlamı ile herhangi bir hayvanın silüetini göstermemektedir. Bunun önlenmesi için bu sahnenin alan testi ile es geçilip alan bütünlüğünün daha çok sağladığı bir sonraki sahnelerde nesne türü ve sayımı yapılması sağlanmıştır.



Şekil 16: Akdağ'da bir kızıl geyiğin kurulu fotokapana 20 m uzaklıkta geçiş görüntüsü.

Şekil 17'de görüldüğü üzere fotokapan ile kızıl geyiğin arasında yer alan ağaç sahnenin arka plan ikili görüntüsünde piksel

kopmalarına yol açmıştır. Bu şekilde elde edilen görüntünün işlenerek hareketli nesnenin tanımlanması imkansızdır.




Şekil 17: Şekil 16'daki sahnenin arka plan görüntüsünde nesne alanında meydana gelen eksiklik örneği.

Şekil 18'de görüldüğü gibi geyik bir an için yaban atı olarak sınıflandırılıp etiketlenmiştir. Ancak alan bütünlüğü testi ile bu olumsuz durum pas geçilerek bir sonraki çerçevede geyiğin Şekil 19'daki gibi doğru bir şekilde geyik olarak tanınması ve sınıflandırılması sağlanmıştır.



Şekil 18: Şekil 17'deki sahnede yaban hayvanının yanlış sınıflandırılması.




Şekil 19: Şekil 18'deki sahnede alan testi yöntemi uygulanıp doğru sınıflandırma yapılması.


Şekil 20'de yaban hayatında karşılaşılabilecek en zor sahnelerden biri görünmektedir. Şekil 21'de GMM ile video sahnesinin arka plan görüntüsü çıkarılmış ve fiziksel öznelikleri elde edilmiştir. Fotokapan sahnesinde saksığan kuşunun görüntü kaynağına yakın bir yerde hareket ettiği ve arka plan alanının 5359 piksel, ACO değerinin ise 5.6675 piksel olduğu tespit edilmiştir. Saksığan kuşunun farklı

hareketlerinde alan değerinin 14813 piksele, ACO değerinin ise 10.8787 piksel değerine yükseldiği gözlemlenmiştir.

RGB renk testi uygulamadan sadece alan testi ve öznelik testi ile sınıflandırma yapılmıştır. Saksığan kuşu geyik olarak sınıflandırıldığı görülmüştür. Çünkü bu öznelik değerleri sayısal olarak hem geyik hem de tilki verilerine yakın değerlerdir.



Şekil 20: Alan testi ve öznelik testi ile aşılamayan video sahnesi ile arka plan görünümü [28].

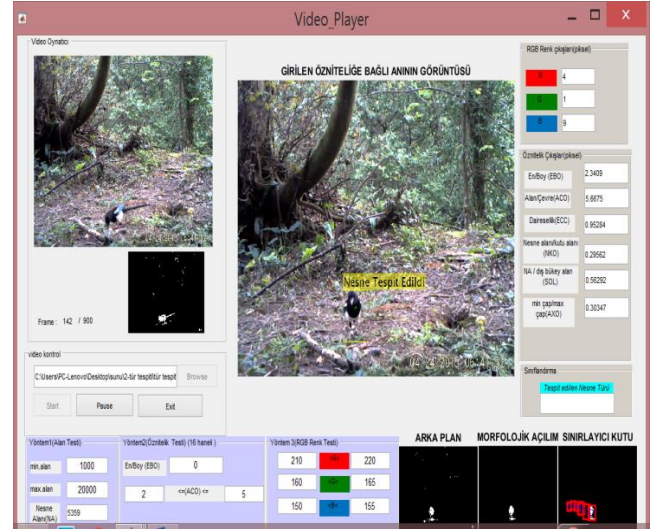


Şekil 21: Şekil 20'deki video sahnesinin GMM yöntemi ile arka plan çıkarımı.

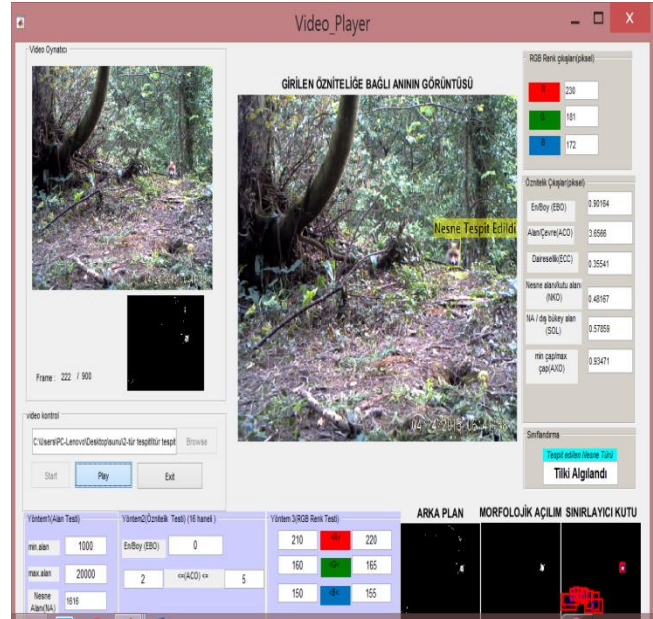
Şekil 22'de alan testi ve öznelik testi ile aşılamayan durumda nesne tespiti yapılmış fakat RGB renk testi ile tespit edilen nesnenin sınıflandırılmasının önüne geçilmiştir. Hedeflenen yaban hayvanı türleri içerisinde saksığan kuşu olmadığı için saksığan kuşunun tür tespiti ve sayısı yapılmamıştır. Şekil 22'de görüldüğü gibi Saksığan kuşunun renk yoğunlukları ortalama olarak [4 1 9] çıkmıştır. Oysa tür tespiti yapılmak istenen yaban hayvanlarından biri olan kızıl tilkinin renk yoğunlukları ortalama [230 181 172] değerlerindedir.

Hazırlanan arayüz modülün de tespiti yapılmak istenen yaban hayvanına ait aynı video sahneleri için geçerli olan RGB renk değerleri verisi girilmiş ve saksığan kuşunun sınıflandırılmadan o sahnelerin pas geçilmesi sağlanmıştır. Şekil 23'te görüldüğü üzere saksığan kuşunun olduğu sahnelerde hareketli nesne tespiti yapılmış fakat hedef dışı

canlı olduğu için RGB renk testi ile saksığan kuşunun olduğu sahnelerde sınıflandırma yapılmamıştır.



Şekil 22: Alan ve öznelik testi aşılamayan zor sahnelere RGB renk testinin uygulanması.



Şekil 23: RGB renk testi ile hedeflenen yaban hayvanı tespiti.

3.2 DVM ve YSA sınıflandırıcı başarımlarının karşılaştırılması üzerine yapılan çalışma

Görüntü işlemede nesne tespitinde her ne kadar özneliklerin doğru bir şekilde çıkartılması başarıyı belirlese de nesnenin doğru sınıflandırılmasında bir diğer önemli faktörde sınıflandırıcıların başarı oranlarıdır. Belli bir geometrik ölçülere sahip olsa da her hareketi ile tahmin etmesi zor geometrik şekillere girebilen canlılardan biriside yaban hayvanlarıdır.

Yaban hayvanlarının yüksek başarı oranı ile sınıflandırılması ve doğru bir şekilde etiketlenmesi için 2170 adet içerisinde yaban hayvanlarının olduğu video çerçeveleri ve resimler önce DVM sonra da YSA ile eğitilmiş ve elde edilen başarı oranları Tablo 6'da gösterilmiştir.

Önce 1. gruptaki dişi geyik, erkek geyik, kurt, tilki, yaban atı olan 5 tür ile sınıflandırma yapılmıştır. Dişi geyikte boynuz yoktur. Doğal olarak bu fark dişi geyik ile erkek geyiğin tanınmasında farklı öznelik matrisi oluşturur. Doğru bir sınıflandırma için bu fark gözetilerek geyik türü dişi ve erkek olarak sınıflandırma çalışmasına ilave edilmiştir. Sınıflandırmada sadece fiziksel öznelik matrisleri olan EBO, ACO, ECC, NKO, SOL ve AXO oranları kullanılmıştır. Daha sonra birbirine matematiksel olarak öznelikleri çok yakın değerlerde çıkan dişi geyik-erkek geyik ayrımı 2. grupta ortadan kaldırılmıştır. Yine aynı bilgi doğrultusunda 3. gruptaki tilki-kurt ayrımı ikilisi ortadan kaldırılmıştır. 3. grupta görüldüğü üzere yaban hayvanı tür sayısı azaltılarak başarımlar her türlü olasılıkta DVM ve YSA başarımlar oranları kıyaslanmıştır. Tablo 6'da görüldüğü gibi yaban hayvanlarının sınıflandırılmasında YSA daha yüksek başarımlar oranı göstermiştir.

Tablo 6: Yaban hayvanları sınıflandırılmasında DVM ve YSA başarımlar oranlarının karşılaştırılması.

Yaban hayvanı grupları	Yaban hayvanı türleri	Başarı oranları	DVM başarımlar oranı	YSA başarımlar oranı
1.Grup	1-Dişi geyik	Eğitim	%72.8	%72.8
		Test	%71.4	%73.3
	2-Erkek geyik	Genel	%70	%72.9
	3-Tilki			
	4-Kurt			
2.Grup	5-Yaban atı			
	1-Geyik	Eğitim	%82.1	%84.2
	2-Tilki	Test	%77.2	%73.3
	3-Kurt	Genel	%83	%84.3
	4-Yaban atı			
3.Grup	1-Geyik	Eğitim	%96.4	%96.6
	2-Tilki	Test	%93.7	%94.8
	3-Yaban atı	Genel	%95.9	%96

Ayrıca fiziksel özellikleri birbirine çok yakın olan yaban hayvanlarının sınıflandırılmasında sadece fiziksel öznelik kullanılması başarımlar çok düşürdüğü gözlemlenmiştir. Sınıflandırılacak tür sayısının azalması ve sınıflandırıcının daha fazla giriş verisi ile eğitilmesi başarımlar oranını arttıracaktır.

3.3 Yöntem 3: renksel öznelik ile sınıflandırma başarımlar oranının artırılması

Bu çalışmada daha önceki çalışmalardan farklı olarak nesne tanıma ve sınıflandırma başarımlarında nesnenin fiziksel özneliklerinin yanında renk faktörünün de kullanılmasının yaban hayvanlarının sınıflandırılmasında başarımlar hangi oranda arttırdığı ortaya konulmuştur. Özellikle rengi ile adlandırılan bazı yaban hayvanlarının renk yoğunluklarından yararlanılarak tespit edilip sayımın yapılmasının çok başarılı bir yöntem olduğu gösterilmiştir.

Tablo 7'de görüldüğü gibi geyik, tilki, kurt ve yaban atından oluşan 4 tür yaban hayvanının sınıflandırılmasında renksel özneliğin başarımlar olan etkisi görülmektedir. Tablo 7 aynı zamanda yaban hayvanı tür tespitinde sadece fiziksel öznelikler ile %100 başarımlar oranına ulaşamadığını kanıtlar.

Tablo 7'de görüldüğü üzere yaban hayatında yaşayan geyik, tilki, kurt ve yaban atından oluşan 4 türe ait ilk önce 1193 adet anlamlı fiziksel öznelik verileri ile sınıflandırma yapılmış ve genel başarımlar oranında %98.5 değerine ulaşılmıştır. Aynı fiziksel öznelik verilerine aynı hayvanların gün ışığında fotokapan ile çekilmiş video sahnelerinden elde edilen renk verileri de

katılarak aynı çalışma tekrar yapılmıştır. Yapılan çalışma sonucu elde edilen sınıflandırma başarımlar %100 olmuştur.

Tablo 7: Yaban hayvanı sınıflandırılmasında fiziksel özneliğe ilave olarak renksel özneliğin kullanılmasının nesne tanımda başarımlar etkisi.

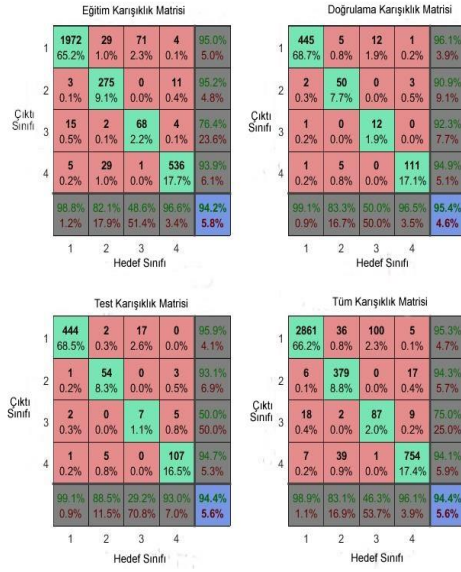
Yaban hayvanı grupları	Yaban hayvanı türleri	Giriş data sayısı	Başarı oranları	Fiziksel öznelik ile YSA başarımlar	Fiziksel ve renksel öznelik ile YSA başarımlar
1.Grup	1- Geyik	1193 Adet	Eğitim	%98.7	%100
	2- Tilki		Test	%97.2	%100
	3- Kurt		Genel	%98.5	%100
	4- Yaban atı				
2.Grup	1- Geyik	1483 Adet	Eğitim	%97	%100
	2- Tilki		Test	%96.4	%100
	3- Kurt		Genel	%96.8	%100
	4- Yaban atı				
3.Grup	1- Geyik	4321 Adet	Eğitim	%94.2	%100
	2- Tilki		Test	%94.4	%100
	3- Kurt		Genel	%94.4	%100
	4- Yaban atı				

Geyik, tilki, kurt ve yaban atından oluşan 4 türe ait olan fiziksel öznelik veri sayısı 1193'ten önce 1483 daha sonra 4321'e yükseltilmiştir. Birbirine fiziksel özellikleri yakın olan tilki kurt gibi hayvanlardan daha fazla öznelik verisi alınmıştır. Fakat giriş verilerinin sayısı artmasına rağmen öznelik vektörlerinin birbirine yakın sayısal değerler olması sonucu sınıflandırmada genel başarımlar oranı %98.5'den önce %96.8'e sonra %94.4'e düşmüştür. Aynı çalışmada aynı sayıda verilere yaban hayvanlarına ait fiziksel özneliğe ilaveten renksel öznelik verileri de katılarak tekrar sınıflandırma yapılmıştır. Genel başarımlar oranının %100 olup önceki değerini koruduğu görülmüştür.

Görüntü işlemede nesne tespiti ve nesne tanımda, özellikle yaban hayvanı gibi geometrik şekli her an değişebilen ve her anı ile sayısız fiziksel özneliği ortaya çıkan hareketlilerin tespitinde fiziksel özneliğin yanında mutlaka renksel öznelik faktörü de kullanılmalıdır. Sadece renk faktörü kullanmanın da yaban hayvanı tanımda ve sınıflandırmada yetersiz olacağı aşikârdır. Çünkü rengi birbirine benzer çok hayvan türü vardır.

Ayrıca günlük hayatta hayvanların her zaman aynı renksel özellikleri ile kamera optiğine yakalanması olağan değildir. Çünkü hayvanın çamura yatmış, üzeri tozlanmış veya ıslanmış olması hayvanın renk yoğunluğu değerlerinin yani renksel özneliklerinin değişmesine neden olur. Bunun için makale çalışmasında olduğu gibi hareketlinin en az 3 ayrı noktadan piksel rengi bilgisi almak bu olumsuzlukların doğuracağı başarımlar azalmasını da minimize eder.

Şekil 24'te karışıklık matrisinde görüldüğü gibi Tablo 7'de yer alan ve genel başarımlar oranı %94.4 olan YSA ile yaban hayvanı sınıflandırma çalışmasının sonucunda elde edilen karışıklık matrisi görülmektedir. Karışıklık matrisinde eğitimde %94.2 testte ise %94.4 başarımlar oranının elde edildiği ve hangi sınıfta yanlış sınıflandırma yapıldığı görülmektedir.



Şekil 24: Genel başarı oranı %94.4 olan YSA sınıflandırıcının karışıklık matrisi.

Tablo 8'de görüldüğü gibi en son veri sayısı ile eğitilmiş ve %100 başarımın elde edildiği YSA'ya ait sonuç değerleri görülmektedir.


Tablo 8: Genel başarım oranı %100 olan YSA sınıflandırıcı performansı.

	Giriş örnekleri sayısı	Çapraz entropi (CE)	Hata %E
Eğitim	3025	4.23354	0
Doğrulama	648	12.14704	0
Test	648	12.14572	0

Giriş verisi olarak 6 adet fiziksel özneliğe ilave 3 adet renksel öznelik değerlerinden oluşan toplam 6 adet öznelik matrisi [EBO ACO ECC NKO SOL AXO Rort Gort Bort] kullanılmış olup bu verilerin %70'i eğitim, %15'i doğrulama ve %15'i de test için kullanılmıştır. Eğitim, doğrulama ve test için %100 başarım elde edilmiştir.

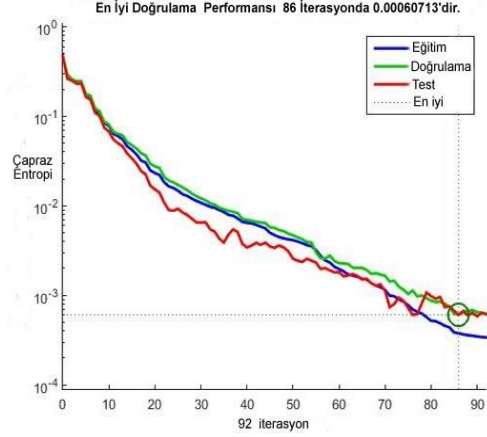
%E hata değeri olup hatanın eğitim ve test için %0 çıkması sınıflandırmanın %100 doğru yapıldığını gösterir. CE değeri çapraz entropi değeri olup bu değer en aza indirilmesi iyi sınıflandırmaya neden olur. Düşük CE değeri modelin tahmin kabiliyetinin yüksek olması anlamına gelir. YSA'nın gizli katmandaki nöron sayısı farklı değerlerde alınarak başarım sonuçları gözlemlenmiştir. Farklı nöron sayılarında %100 doğruluk elde edilmiştir. Fakat düşük CE değeri ve %100 doğru sınıflandırma başarısı için gizli katmandaki nöron sayısı 22 olarak tespit edilmiştir.

Şekil 25'te görüldüğü gibi 9 giriş ve 4 çıkışa sahip YSA'nın gizli katmanında aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmıştır.



Şekil 25: Genel başarı oranı %100 olan eğitilmiş YSA Sınıflandırıcının yapısı.

Şekil 26'da görüldüğü gibi ağ eğitimi toplam 92 iterasyonda tamamlanmıştır. Performans grafiğindeki doğrulama çizgisi ağ genelmesini ölçer ve genelleme iyileştirilmediğinde eğitimi durdurur. Ağ en iyi performansa 10^{-3} 'den düşük bir çapraz entropi değeri olan 86 iterasyonda ulaşmaktadır.



Şekil 26: Genel başarı oranı %100 olan eğitilmiş YSA sınıflandırıcının performans grafiği.

4 Sonuçlar

Görüntü işlemenin en temel konusu hareketli nesne tespiti ve nesne tanınması üzerinedir. Özellikle görüntü işleme ile nesne tespiti konusunda nesnenin yüksek başarım ile tanınması için farklı yöntemler geliştirilmiştir. Literatürde yabancı tanıma üzerine farklı yöntemlerle farklı çalışmalar yapılmış ve türlü başarım oranları elde edilmiştir. Bu makale çalışmasında yabancı hayatta ilkel yöntemlere nazaran daha etkili kontrolün sağlanması üzerine görüntü işleme tabanlı uygulanabilir bir sistem geliştirilmiştir.

Alan testi (yöntem-1) ve öznelik testi (yöntem-2) ile en zor sahnelerde sahip yabancı hayatı videolarında hedeflenen nesnenin tespiti başarı ile gerçekleştirilmiştir. Bu iki yöntem ile dinamik arka plana sahip yabancı hayatı videolarında arka plan hareketlileri bertaraf edilmiştir. Geliştirilen yaklaşımlardan bir diğeri olan renksel öznelik testi (yöntem-3) aşılması mümkün olmayan en zor yabancı hayatı video sahnelerinde hedeflenen hareketli yabancı hayvanı tespiti başarı gerçekleştirilmiştir. Yöntem 1, 2 ve 3'ü görüntü işleme ile dinamik nesne tespitinde tüm çalışmalara uygulanabileceği ve nesne tespitinde başarım oranını arttıracığı görülmüştür.

Dinamik nesne tanıma konusunda nesneye ait sadece fiziksel veya renksel özelliklerin kullanılması ile tanınabilirliğin düşük başarım oranlarında gerçekleştiği ortaya konulmuştur. Renk faktörünün nesne tespitinde ne kadar önemli olduğu vurgulanmıştır. Nesne tespitinde hazır nesne tanıma algoritmaları yerine basit matematiksel hesaplamalar ile nesneye ait fiziksel ve renk özelliklerinin tespit edilmesi çerçeve başına düşen işlem süresinin kısılmasına olanak sağlamıştır. Nesne tanımda nesneye ait fiziksel özelliğe ilaveten renksel özelliklerin kullanılmasının başarım oranını olumlu şekilde arttıracığı kanıtlanmıştır.

Yabancı hayvanlarının tanınmasında DVM ye nazaran YSA sınıflandırıcının daha yüksek başarım oranında sonuç verdiği ortaya konulmuştur. Dolayısı ile Görüntü işleme tekniği ile yabancı hayvanı tür tespiti ve sınıflandırılması çalışmalarında YSA sınıflandırıcı önerilmiştir. Eğitim verileri arasındaki orantısızlığın fazla olduğu durumlarda YSA'nın DVM'ye kıyasla

eğitim verilerine olan fazla hasasiyetinden dolayı Literatürdeki sınıflandırma çalışmalarında da YSA önerilmiştir. DVM'nin YSA'ya nazaran sınıflandırma çalışmalarında her zaman daha yüksek performans vereceği kanısı bertaraf edilmiştir.

Yaban hayatında kaynak değeri olan yaban hayvanlarının %100 başarımla ile tür tespiti ve sayımının yapılması için geliştirilen tüm yöntemler ile yaklaşımların yer aldığı yazılım 694 çerçeveden oluşan 1280*720 piksel HD çözünürlükte bir yaban hayatı videosuna uygulandığı Tablo 9'da ki performans kriterleri elde edilmiştir.

Tablo 9: Yaban hayvanı tür tespiti ve sayım programı performansı.

Kullanılan Yöntemler	CPU yükü (%)	Bellek kapasitesi (MB)	Çerçeve başına düşen işlem süresi (sn.)
-GMM yöntemi ile arka planı çıkarımı yapılması	43.2	64	0.033
-Yöntem 1,2,3 ile video sahnesinde hedeflenen dinamik nesnenin tespitinin yapılması	37.5	366	0.149
-Fiziksel ve renksel öznelik ile nesne tanıma	36.6	485	0.234
-YSA ile nesne sınıflandırma	35.2	600	0.242

Tablo 9'da görüldüğü üzere 694 çerçeveden oluşan video sahnelerinde her bir çerçevedeki tüm hareketli piksellerin arka planı görüntüsü GMM metodu çıkarılmış ve CPU yükü %43.2 olarak tespit edilmiştir. Daha sonra yazılımsal olarak Yöntem 1, 2, 3 ile videonun tüm çerçevelerinde tespit edilen bütün hareketli pikselere işlem yapılmasının önüne geçilmiştir. Bu sayede sadece hedefteki dinamik nesne tespitinin yapılmasına olanak sağlanarak CPU'nun sürekli işlem yapmasının önüne geçilmiş olup CPU'nun işlem yükü %37.5'e düşürülmüştür. Hedef doğrultusunda tespit edilen video sahnesindeki tüm dinamik nesnelerin fiziksel ve renksel öznelikleri ile tanınması sağlanarak CPU yükü %36.6'ya düşürülmüştür.

En son YSA ile nesne sınıflandırılması yapılarak %35.2 CPU yükü ile 0.242 sn gibi kısa bir zamanda %100 başarımla sonucu ile yaban hayvanı tespiti, takibi ve sınıflandırılması yapılmıştır.

%100 başarımla ile yaban hayvanı tür ve sayı tespitinin insan gücüne gerek duymadan, daha düşük maliyetli kamera sistemleri ve bilgisayar yazılımı ile yapılabileceği görülmüştür.

5 Kaynaklar

- [1] T.C. Doğa Koruma ve Milli Parklar Genel Müdürlüğü. "Türkiye'deki Korunan Alan Sistemi Hakkında Bilgiler". <http://www.milliparklar.gov.tr/korunanalanlar/korunanalan1.htm> (12.06.2017).
- [2] TMMOB Orman Mühendisleri Odası. "Büyük Memeli Av Hayvanı Sayım Teknikler ve Ülkemizdeki Populasyon Durumu". <http://ormuh.org.tr/arsiv/files/Av%20Hayvanlari%20Evnanteri.pdf> (15.06.2017).

- [3] Andreopoulos A, Tsotsos JK. "50 years of object recognition: Directions forward". *Computer Vision and Image Understanding*, 117, 827-891, 2013.
- [4] Buğday A. Gerçek Zamanlı Videolarda Ön Plan ve Arka Plan Ayrımı. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, Türkiye, 2010.
- [5] Karasulu B. Videolarda Hareketli Nesne Tespiti ve Takibi için Benzetimli Tavlama Tabanlı Bir Başarım Eniyileme Yaklaşımı. Doktora Tezi, Ege Üniversitesi, İzmir, Türkiye, 2010.
- [6] XU Y, Dong J, Zhang B, Xu D. "Background modeling methods in video analysis: A review and comparative evaluation". *CAAI Transactions on Intelligence Technology*, 1, 43-60, 2016
- [7] Stauffer C, Grimson, WEL. "Adaptive background mixture models for real-time tracking". *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Fort Collins, CO, USA, 23-25 June 1999.
- [8] Alparslan N. Gradyan Tabanlı Heterojen Öznelik Çıkarma Yöntemlerine Yeni Yaklaşımlar. Yüksek Lisans Tezi, İnönü Üniversitesi, Malatya, Türkiye, 2013.
- [9] Yılboğa H. Büyük Veri Tabanlarında Özneliklerin Etiketlere İndirgenmesine Dayalı İçerik ve Metin Tabanlı Görüntü Erişimi. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul, Türkiye, 2015.
- [10] Kocaman Ç. Yapay Us Yöntemleri Kullanarak Enerji Kalitesi Bozucularının Belirlenmesi. Doktora Tezi, 19 Mayıs Üniversitesi, Samsun, Türkiye, 2010.
- [11] Matuska S, Hudec R, Kamencay P, Benco M, Zachariasova M. "Classification of Wild Animals Based on DVM and Local Descriptors". *AASRI Procedia*, 9, 25-30, 2014.
- [12] Yu X, Wang J, Kays R, Jansen PA, Wang T, Huang T. "Automated identification of animal species in camera trap images". *EURASI Journal on Image and Video Processing*, 52, 2-10, 2013.
- [13] Ali MN, Viriri S. Animal Identification Based on Footprint Recognition". *IEEE Computer Society*, Pretoria, South Africa, 25-27 November 2013.
- [14] Boniecki P, Koszela K, Piekarska H, Weres J, Zaborowicz M, Kujawa S, Majeswski A, Raba B. "Neural identification of selected apple pests". *Computers and Electronics in Agriculture*. 110, 9-16, 2015.
- [15] Risse B, Mangan M, Barbara W. "Visual Tracking of Small Animals in Cluttered Natural Environments Using a Freely Moving Camera". 2017 IEEE International Conference on Computer Vision Workshop, Venice, Italy, 22-27 October 2017.
- [16] Jasko G, Giosan L, Nedevschi S. "Animal detection from traffic scenarios based on monocular color vision". *13th IEEE International Conference on Intelligent Computer Communication and Processing (ICCP)*, Cluj-Napoca, Romania, 7-9 September 2017.
- [17] Nguyen H, Maclagan SJ, Nguyen TD, Nguyen. "Animal Recognition and Identification with Deep Convolutional Neural Networks for Automated Wildlife Monitoring". International Conference on Data Science and Advanced Analytics (DSAA), Tokyo, Japan, 19-21 October 2017.
- [18] Villa AG, Salazar A, Vargas F. "Towards automatic wild animal monitoring: Identification of animal species in camera-trap images using very deep convolutional neural networks". *Ecological Informatics*, 4, 24-32, 2017.

- [19] Bacham S. *Editorial Introduction*. Editors: Graves M, Batchelor M. *Machine Vision for the Inspection of Natural Products*, 35-85, UK, Springer Science & Business Media, 2006.
- [20] Sonugör G. İnsansız Kara Araçları için Dinamik Nesnelerin Tanınması amacıyla Görüntü İşleme Tabanlı Bir Sistem Geliştirilmesi. Doktora Tezi, Kocatepe Üniversitesi, Afyonkarahisar, Türkiye, 2016.
- [21] Savaş K. Kontrol Sistemleri için Matlab'ta Gui Uygulamaları Tasarımı. Yüksek Lisans Tezi, Marmara Üniversitesi, İstanbul, Türkiye, 2007.
- [22] Xiong Y, Zhang Z, Chen F. "Comparison of ANN and SVM Methods for Urban Land Use/Cover Classifications from Remote Sensing Images". *International Conference on Computer and System Modeling (ICCSM 2010)*, Taiyuan, China, 22-24 October 2010.
- [23] Moraes R, Valiati JF, Neto WPG. "Document-Level Sentiment Classification: An Empirical Comparison Between SVM and ANN". *Expert Systems with Application*, 40, 621-633, 2013.
- [24] Ren J. "ANN vs. SVM: Which one performs "better in Classification of MCCs in mammogram imaginig". *Knowledge-Based Systems*, 26, 144-153, 2012.
- [25] You Tube. "Deer, Fox, Rabbit Bushnell Trophy Cam HD Aggressor".
<https://www.youtube.com/watch?v=rvOagfFM6Cg>
(12.04.2017).
- [26] You Tube. "Cam Two Active Buck Scrape".
https://www.youtube.com/watch?v=Ka2WH_22D5s
(12.04.2017).
- [27] You Tube. "Buck Battling the Raccoons".
<https://www.youtube.com/watch?v=6DnZgU3fpA>
(12.05.2017)
- [28] You Tube. "red-fox-on-trail-camera".
<https://www.youtube.com/watch?v=xMLUAgEaC0w>
(12.05.2017).