

Rüzgar Türbinlerinde Kuş Çarpışmalarının Azaltılmasına Yönelik Derin Öğrenme Tabanlı Hibrit Algılama Yaklaşımı

A Deep Learning-Based Hybrid Detection Approach for Reducing Bird Collisions in Wind Turbines

Uğur Cira¹, Abdulkadir Karacı^{2*}, Adem Bayraktar³

^{1*} Ahmet Yesevi Üniversitesi Türtep, Ankara, Türkiye

² Samsun Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Samsun, Türkiye

³ Trabzon İl Milli Eğitim Müdürlüğü, Trabzon, Türkiye

ÖZET

Günümüzde rüzgar türbinleri nedeniyle yılda yaklaşık 300.000 kuşun yaşamını yitirdiği tahmin edilmektedir. Bu çalışmada, türbinlerin ekosisteme zarar vermeden çalışmasını sağlamak amacıyla yapay zekâ destekli bir kuş tespit ve müdahale sistemi tasarlanmıştır. Web üzerinden farklı hava koşulları ve uzaklıkları içeren 100 kuş görüntüsünden veri seti oluşturulmuş; YOLOv4-tiny modeli bu veriyle 2000 epok eğitilerek %95,8 mAP başarımları elde edilmiştir. Eğitilmiş model NVIDIA Jetson Nano üzerinde gerçek zamanlı olarak çalıştırılmış ve OpenCV tabanlı görüntü işleme ile kuş tespiti sağlanmıştır. Tespit durumunda Arduino kontrollü motor sistemi türbin pervanelerini durdurmakta, HC-SR04 sensörü ise kuş-türbin mesafesini ölçerek karar mekanizmasını desteklemektedir. Sistem, yüksek ışııkta ve 30 cm mesafede en iyi sonuçları (18 tespit), düşük ışııkta ve 42 cm mesafede ise en düşük performansı (7 tespit) göstermiştir.

Anahtar Kelimeler: Rüzgar türbini, YOLOv4-tiny, derin öğrenme, otonom sistemler, çevresel sürdürülebilirlik

ABSTRACT

It is estimated that approximately 300,000 birds die annually worldwide due to collisions with wind turbines. In this study, an AI-assisted detection and intervention system was developed to minimize such collisions and enable wind turbines to operate without disrupting ecological balance. A dataset of 100 bird images under varying weather conditions and distances was collected, and the YOLOv4-tiny model was trained for 2000 epochs, achieving a mean average precision (mAP) of 95.8%. The trained model was deployed on an NVIDIA Jetson Nano and used with OpenCV-based image processing for real-time bird detection. When a bird is detected, an Arduino-controlled motor system stops the turbine blades, while an HC-SR04 ultrasonic sensor measures the bird's distance to enhance decision stability. Testing under different lighting and distance conditions showed the best performance at high light and 30 cm (18 detections), and the lowest performance under low light and 42 cm (7 detections).

Keywords: Wind turbine, YOLOv4-tiny, deep learning, autonomous systems, environmental sustainability

1. GİRİŞ

Rüzgar enerjisi, fosil yakıtların yol açtığı karbon emisyonlarını azaltma ve enerji üretiminde sürdürülebilir çözümler sunma açısından küresel olarak kritik bir rol oynamaktadır. Ancak, bu yenilenebilir enerji biçiminin çevresel etkileri arasında özellikle kuşların türbin kanatlarına çarpması sonucu meydana gelen ölümler, biyolojik çeşitliliğin korunması açısından önemli bir kaygı doğurmaktadır (Vattenfall, 2025). Kanatların dönme hızı, rotor geometrisi, yerleşim stratejileri, yerel kuş popülasyonlarının göç alışkanlıkları ve habitat kullanımı gibi birçok faktör çarpışma riskini belirleyici unsurlardır.

Son yıllarda, türbin kanatlarının görünürlüğünü artırmayı amaçlayan boya uygulamaları laboratuvar ve saha çalışmalarıyla incelenmektedir. Örneğin, Norveç'teki bir çalışmada üç kanatlı rüzgar türbinlerinden bir kanadın siyaha boyanması, "motion smear" etkisini azaltarak yıllık kuş ölümlerinde yaklaşık %70'lik düşüş göstermiştir (May vd., 2020). Oregon State Üniversitesi'nden araştırmacılar benzer bir uygulamayı geniş kapsamlı tür analizleriyle tekrarlayarak, bu yöntemin farklı kuş türleri üzerindeki etkisinin ve potansiyel sınırlamaların daha netleşmesini hedeflemektedir (Oregon, 2024). Ayrıca, kanatlara "uyarı desenleri" (örneğin kırmızı, siyah ve sarı kombinasyonları) eklemenin kuş çarpışmalarını azaltabileceğini öne süren çalışmalar da bulunmaktadır (Kekkonen vd., 2025). Görsel algı dışında, hareket halindeki kuş sürülerini tespit edip erken uyarı sağlayan yapay zekâ temelli izleme sistemleri de geliştirilmiştir. Örneğin Almanya merkezli BirdRecorder projesi, radar, kamera ve gelişmiş nesne tespiti (SSD gibi) yöntemlerini kullanarak tehlikeye kuş türlerini türbin kanatlarına 800 m'ye kadar yaklaşımdan sınıflandırabilmekte ve çarpışma riskini azaltmayı amaçlamaktadır (Klar vd., 2025). Benzer şekilde, offshore (deniz üstü) rüzgar enerji sahalarında şamandıra tabanlı kameralar ile yapay zekâ analizi yapılarak kuşların yoğunluk, uçuş yönü ve yükseklik gibi parametreler gerçek zamanlı izlenmekte; bu sayede türbin operasyonlarının çevresel risklere göre uyarlanması mümkün olmaktadır (Pallanich, 2025).

Bu literatür, görsel iyileştirme (kanat boyama, desen uygulamaları) ile kamera + yapay zekâ temelli izleme ve erken tepki mekanizmalarının (örneğin türbin hız ayarlama veya durdurma) çarpışma riskini azaltmada umut verici olduğunu göstermektedir. Ancak hâlâ, farklı kuş türleri, coğrafi bölgeler, iklim koşulları ve türbin yerleşim konfigürasyonları dikkate alındığında evrensel uygulanabilirliği ve etkinliği doğrulanmamış birçok yöntem bulunmaktadır.

Bu çalışmanın amacı, rüzgar türbinlerinin ekolojik etkisini en aza indirmek için gerçek zamanlı yapay zekâ destekli algılama sistemi içeren entegre bir çözüm tasarlamak ve test etmektir. Böylece, kuş mortalitesini azaltırken enerji üretim verimliliğini koruyarak rüzgar enerjisinin sürdürülebilirliğine katkı sağlanması hedeflenmektedir.

2. LİTERATÜR TARAMASI

Son yirmi yılda araştırmacılar, görsel ve akustik algılama yöntemlerinden radar tabanlı takip sistemlerine ve otomatik türbin durdurma yaklaşımlarına kadar çeşitli izleme ve önleme stratejilerini incelemişlerdir. Son dönemde, derin öğrenme (DL) teknikleri bu yöntemlere giderek daha fazla entegre edilmekte ve tespit doğruluğu ile operasyonel verimliliği artırmayı amaçlamaktadır. Bu bölümde, önceki çalışmalar; yöntem, bulgu ve katkıları açısından karşılaştırmalı olarak incelenmektedir.

Görüntü tabanlı algılama yöntemleri, RGB ve termal kameraların bilgisayarla görme ve derin öğrenme algoritmaları ile kullanılmasına dayanmaktadır. Gündüz izlemeleri için RGB, gece için ise termal kameraları bir araya getiren bir sistem geliştirmiştir. Happ vd. (2021) otomatik bilgisayarla görme yöntemleri sayesinde 24 saat kesintisiz gözlemin mümkün olduğu gösterilmiş, ancak sis ve yağmur gibi çevresel koşulların performansı düşürdüğü belirtilmiştir. Yarbrough vd. (2023) Rüzgâr santralleri yakınında toplanan termal video verilerini derin öğrenme ile analiz etmiş, YOLO tabanlı modeller kullanarak kuş, yaras ve böcekleri başarılı biçimde sınıflandırmıştır. Bu çalışma, gece ve göç hareketlerinin daha hassas tespit edilebileceğini ortaya koymuştur. Liu vd. (2024) gri tonlu video akışlarında YOLOv4 tabanlı tespit algoritması uygulamış ve küçük kuş türlerinin yüksek doğrulukla tespit edilebildiğini, yanlış pozitif oranının ise düşük tutulabildiğini göstermiştir. Bu çalışmalar, görüntü tabanlı ve DL destekli sistemlerin tür düzeyinde yüksek doğruluk sunduğunu ortaya koymaktadır. Bununla birlikte, hava koşullarına duyarlılık ve sınırlı görüş alanı gibi kısıtlar bulunmaktadır.

Radar ve akustik izleme yöntemleri, farklı hava ve ışık koşullarında dayanıklılıkları nedeniyle geniş ölçüde test edilmiştir. Desholm ve Kahlert (2005) açık deniz ortamında radar kullanarak kuşların uçuş yüksekliği ve göç rotalarını incelemişlerdir. Bulgular, radar verilerinin rüzgâr santrali yer seçimini ve risk değerlendirmelerini destekleyebileceğini göstermiştir. Arnett vd. (2011) yarasalara yönelik akustik tetiklemeli akıllı durdurma stratejileri önermiştir. Çalışma, türbinlerin yalnızca yaras etkinliğinin yoğun olduğu zamanlarda durdurulmasıyla yaras ölümlerinin ciddi oranda azaldığını, enerji kaybının ise sınırlı kaldığını göstermiştir. Radar geniş alan kapsamı sağlarken, akustik algılama özellikle gece etkinliklerinde etkilidir. Ancak her iki yaklaşım da tür bazlı

tanımlamada sınırlı kalmaktadır. Bu nedenle, radar ve kamera verilerinin hibrit olarak kullanıldığı sistemler öne çıkmıştır.

Hibrit algılama sistemleri, çoklu sensörleri derin öğrenme ve karar mekanizmalarıyla birleştirerek hem erken uyarı hem de doğru sınıflandırma imkânı sunmaktadır. McClure vd. (2021) çok kameralı İdentiFlight sistemini Before-After-Control-Impact (BACI) tasarımıyla değerlendirmiştir. Çalışmada, kartal ölümlerinde %82 oranında azalma raporlanmış ve otomatik hedefli durdurmanın etkinliği kanıtlanmıştır. De Lucas (2020) kamera tabanlı tespit, caydırıcı cihazlar ve türbin durdurma modüllerini entegre eden DTBird sistemini incelemiş ve özellikle Avrupa'daki sahalarda çarpışma riskini önemli ölçüde düşürdüğünü göstermiştir. Ballester (2024) otomatik algılama sistemleri için tarafsız saha değerlendirme protokolü önermiştir. Tespit oranı, yanlış alarm oranı, yanıt süresi ve durdurma etkinliği gibi standart metriklerle projeler arasında karşılaştırılabilirlik sağlamıştır. Bu çalışmalar, hibrit sistemlerin ve otomatik durdurmanın ekolojik koruma ile enerji üretim verimliliğini dengeleyen en etkili yöntemler olduğunu göstermektedir.

Literatürde üç temel bulgu öne çıkmaktadır: Görüntü + DL sistemleri tür düzeyinde yüksek doğruluk sağlar, fakat hava koşullarına duyarlıdır. Radar ve akustik sistemler geniş alan kapsar, gece/göç tespitinde güçlüdür, ancak tür ayrımı sınırlıdır. Hibrit + otomatik durdurma sistemleri en yüksek etkinliği göstermektedir; saha verileri, mortalitede %50–85 arasında azalma sağlarken enerji kaybı <%1 seviyesinde tutulur. Bu bulgular, gelecekteki çalışmalarda derin öğrenme destekli hibrit algılama sistemlerinin en umut verici yönelim olduğunu ortaya koymaktadır.


3. YÖNTEM

Çalışma kapsamında geliştirilen sistem kamera tabanlı görüntü işleme birimi, ultrasonik sensör tabanlı mesafe ölçüm modülü, motor kontrol mekanizması ve 3D yazıcı ile üretilen prototip gövdesinden oluşmaktadır. Türbin gövdesi ve modül yuvaları TinkerCAD ortamında tasarlanmış, ardından PLA malzeme kullanılarak 3D yazıcıda üretilmiştir. Donanım bileşenleri bu gövdeye entegre edilerek işlevsel bir prototip elde edilmiştir. Türbin çevresine konumlandırılan USB kamera, gerçek zamanlı görüntüleri NVIDIA Jetson Nano (Quad-core ARM A57 CPU, 128-core Maxwell GPU, 4 GB RAM, JetPack 4.6.1, Ubuntu 18.04, CUDA 10.2, cuDNN 8.0) üzerinde çalışan Python tabanlı yazılıma aktarmaktadır. Bu yazılımda, OpenCV kütüphanesi ile ön işleme adımlarından geçirilen görüntüler YOLOv4-tiny derin öğrenme modeli aracılığıyla analiz edilmekte ve kuş tespiti yapılmaktadır. Model çıktıları, seri haberleşme protokolü ile Arduino Uno'ya gönderilmektedir. Arduino, aldığı komutlara bağlı olarak L298N motor sürücü üzerinden DC motoru kontrol ederek türbin kanatlarının durdurulmasını veya yeniden çalıştırılmasını sağlamaktadır.

3.1. Sistem Mimarisi

Geliştirilen sistemin genel mimarisi Şekil 1'de gösterilmektedir. Nvidia Jetson Nano, USB portu üzerinden Arduino UNO bağlıdır. Arduino UNO bu bağlantı ile hem 5V güç beslemesini hem de seri haberleşmeyi yapmaktadır. Seri haberleşme, Jetson Nano'daki YOLO tabanlı kararın Arduino'ya aktarılması için kullanılır. Jetson Nano, tespit akışında tek baytlık kontrol komutları gönderir. 'S' (Stop) kuş tespitinde motoru anında durdurur. 'R' (Run) zamanlayıcı dolduğunda motoru yeniden çalıştırır.


Komutlar düşük gecikmeyle L298N üzerinden motor durumunu değiştirir. Motor sürücü ile dc motorun dönüş yönünü belirlemek için IN1 ve IN2 pinleri, Arduino UNO'da 2 ve 3 dijital pinlerine; motorun hızını PWM sinyali ile ayarlamak için de ENA pini 5 no'lu dijital pine bağlanmıştır. HC-SR04 mesafe sensörü ile ses dalgası göndermek için kullanılan tetikleme sinyali Arduino UNO'da 6 no'lu dijital pine; yansıyan ses dalgasının süresini ölçmek için de kullanılan Echo, Arduino UNO'da 7 no'lu dijital pine bağlanmıştır. Sensörün güç beslemesi için de VCC ve GND sırasıyla Arduino UNO'da 5V ve GND pinlerine bağlanmıştır.



Şekil 1. Sistem genel mimarisi ve prototip

3.2. YOLO ile Kuş Tespiti ve Ölçeklendirme

Bu çalışmada yalnızca “kuş (bird)” sınıfını içerecek şekilde özgün bir nesne tespit modeli YOLOv4-tiny mimarisi ile oluşturulmuştur. YOLOv4-tiny sürümü, Jetson Nano’nun 128 CUDA çekirdekli GPU mimarisiyle en uyumlu ve gerçek zamanlı çalışmaya elverişli yapıdadır. Daha yeni YOLO sürümleri (v5, v8) daha yüksek donanım gereksinimlerine sahip olduğundan, gömülü sistem koşullarında gecikmesiz performans elde etmek amacıyla YOLOv4-tiny tercih edilmiştir. İlk adımda, Şekil 2.a’da örnekleri sunulan ve farklı hava koşullarında, değişen uzaklıklarda ya da sürü hâlinde uçan kuş görüntülerinden oluşan 100 resimden oluşan bir veri seti hazırlanmıştır. Bu resimler LabelImg uygulaması ile YOLO için etiketlenmiştir. Darknet için gerekli dosyalar hazırlanarak obj.names, obj.data ile birlikte görüntü yollarını içeren train.txt ve valid.txt oluşturulmuştur. Veri kümesi %80 eğitim, %20 test olacak şekilde dışarda tutma doğrulama yöntemi ile bölünmüştür. yolov4-tiny.cfg dosyası tek sınıfa uyarlanarak son katmanlarda filters=(classes+5)*3 ve classes=1 ayarları yapılmıştır. YOLOv4-tiny mimarisinde son katmandaki filtre sayısı (classes + 5) × 3 formülüyle hesaplanır. Bu çalışmada yalnızca tek sınıf (‘bird’) bulunduğu için filters = (1 + 5) × 3 = 18 olarak ayarlanmıştır. Eğitim, COCO veri kümesiyle önceden eğitilmiş yolov4.conv.137 ağırlıkları kullanılarak başlatılmıştır. Bu ağırlıklar, geniş ölçekli nesne çeşitliliği içeren bir veri kümesinden türediği için, sınırlı sayıda özgün kuş görüntüsüyle yapılan yeniden eğitim sürecinde modelin daha hızlı ve kararlı öğrenmesi sağlanmıştır. Her 100 iterasyonda mAP değerleri izlenerek ilerleme takip edilmiştir. mAP’in tepe yaptığı iterasyonda üretilen en iyi ağırlıklar nihai model olarak seçilmiştir. Eğitime ait mAP ve kayıp eğrileri Şekil 2.b’de gösterilmektedir. Başlangıçta oldukça yüksek olan kayıp (loss) değerinin iterasyon sayısı arttıkça düzenli bir şekilde azaldığı görülmektedir. Yaklaşık 2000 iterasyon sonunda ortalama kayıp değeri 0,90 seviyesine kadar düşmüştür. YOLOv4-tiny modeli ile yüksek (%95-97) mAP ile kararlı hâle gelmiştir. Son aşamada eğitilen bu model Jetson Nano üzerine entegre edilerek, thresh=0.5 ve nms=0,45 parametreleri ile kuş tespitinde kullanılmıştır.




Şekil 2. (a) Kuş görsellerinden oluşan özgün veri seti, (b) Yolo modeli mAP-epok ve Kayıp-epok grafiği

3.3. Yazılım

Çalışma kapsamın pervane kontrolü için Arduino ortamında bir yazılım geliştirilmiştir. Bu yazılımın akış şeması Şekil 3'te gösterilmektedir. Bu akış şemasında görülen "Manuel kontrol" Jetson Nano'dan gelen komutlarla motorun doğrudan kontrol edilmesi anlamına gelir. Bu modda, mesafe sensörü verileri dikkate alınmaz. Böylece YOLO tabanlı kuş tespiti yapıldığında motorun otomatik olarak durdurulması sağlanır. Sistem çalışmaya başladığında motorDurumu=true ve manuelKontrol=false değerleri atanır. Bu, motorun varsayılan olarak çalıştığını ve kontrolün otomatik (sensör tabanlı) modda olduğunu ifade eder. Eğer manuel kontrol aktif değilse (!manuelKontrol), ultrasonik mesafe sensöründen alınan değer değerlendirilir. Ölçülen mesafe eşik değerin (örneğin 20 cm) altına düşerse motor durdurulur, 4 saniye beklenir ve ardından tekrar çalıştırılır. Bu aşama, kuşların veya herhangi bir cismin türbine çok yaklaşması durumunda otomatik güvenlik mekanizması işlevi görür. Ancak manuel kontrol aktif olmaması sadece sensör tabanlı algılamının aktif olduğu anlamına gelmemektedir. Çünkü bu modda Jetson Nano'dan gelen komutlar da değerlendirilmektedir. Eğer Jetson Nano'dan seri haberleşme ile komut gelirse sistem manuel kontrol moduna geçer. Komut 'S' olduğunda motor durdurulur, manuelKontrol=true yapılır ve böylece sensör devre dışı bırakılarak karar tamamen görüntü işleme tabanlı sisteme bırakılır. Aksi halde sensöre yakın nesne olmadığı için sensör tabanlı kontrol tarafından pervane çalıştırılabilir. Bu da hatalı çalışmaya sebep olur. Komut 'R' olduğunda motor tekrar çalıştırılır, manuelKontrol=false yapılır ve hem sensör hem de yapay zeka temelli kontrol aktif edilmiş olur.


Kamera akışı, cap.isOpened() fonksiyonu true olduğu sürece sürekli devam etmektedir. Her iterasyonda cap.read() fonksiyonu ile yeni bir kare okunmakta, kare alınamadığı durumlarda döngü sonlandırılmaktadır. Kamera döngüsünde her kare cap.read() ile alınır. Okuma başarısız olduğunda geçersiz görüntü işlenmez; sistem güvenli moda alınarak (motor durdurulur) kamera akışı yeniden başlatılır. Böylece bozuk/boş karelerden kaynaklanabilecek beklenmedik davranışlar engellenir. Bu yöntem sayesinde sistem, gerçek zamanlı kuş algılamasını motor kontrolü ile entegre ederek çarpışma riskini en aza indirmektedir.



Şekil 3. Yazılım akış şeması

4. BULGULAR

Geliştirilen sistem prototipi farklı deneysel çalışmalarla test edilmiştir. Bu testlere ait bir görüntü ve test düzeneği Şekil 4'te gösterilmektedir. Bu sistemde NVIDIA Jetson Nano üzerindeki JetPack sistem yazılımı üzerinde çalıştırılan, Python tabanlı yazılım OpenCV, ve YOLOv4 Tiny algoritması kullanarak türbin çevresindeki kuşları tespit etmektedir.



Şekil 4. Gerçek zamanlı görüntü tespiti

Sistemi test etmek için farklı deneysel tasarımlar gerçekleştirilmiştir. İlk deneysel tasarımda mesafe sensörü sistemden çıkarılmış ve sadece YOLO ile görüntülerden kuş tespiti yapılarak sistemin performansı test edilmiştir. Bu deneysel tasarımda elde edilen bulgular Tablo 1’de gösterilmektedir. Testler yaklaşık 50 lux (düşük), 200 lux (orta) ve 500 lux (yüksek) aydınlatma düzeylerinde gerçekleştirilmiştir. Aydınlatmanın yüksek seviyede olduğu ortamlarda kuş çarpma oranı %30 ile %35 arasında, aydınlatmanın orta seviye ortamlarda bu oran %45 ile %50 arasında, aydınlatmanın düşük seviye olduğu ortamlarda ise %75 ile %80 arasında ölçülmüştür.

Tablo 1. Prototip kamera ile kuş tespit verileri

Ortam Işık Seviyesi	Gözlenen Kuş Sayısı	Tespit Edilen Kuş Sayısı
Yüksek	20	13
Orta		10
Düşük		4
Düşük		5
Orta		9
Yüksek		14

İkinci deneysel tasarımda sistemin performansını artırmak amacıyla mesafe sensörü ve kameranın birlikte kullanılmıştır. Bu deneysel tasarımda elde edilen bulgular Tablo 2’de gösterilmektedir. Ortam ışık seviyesinin yüksek seviyede olduğu ortamlarda kuş çarpma oranı mesafe değerinin artmasına göre %10-%25 arasında, ışık seviyesinin orta seviyede olduğu ortamlarda mesafe değerinin artmasına göre kuş çarpma oranı %30-%45 arasında, ortam ışık seviyesinin düşük seviyede olduğu ortamlarda mesafe değerinin artmasına düşük seviyede çarpma oranı %55-%65 arasında kaydedilmiştir. Bulgulardan hareketle, kameranın kısa mesafelerde daha hızlı ve doğru çalıştığını, mesafe arttıkça hem algılama süresinin uzadığını hem de başarı oranının azaldığını göstermektedir. Aynı zamanda ortam ışık değerinin yükselmesi kuş tespit oranını anlamlı oranda artmıştır.

Tablo 2. Prototip mesafe sensörü ve kamera ile kuş tespit verileri

Ortam Işık Seviyesi	Mesafe(cm)	Gözlenen Kuş Sayısı	Tespit Edilen Kuş Sayısı
Yüksek	30	20	18
Yüksek	50	20	15
Düşük	20	20	10
Düşük	40	20	9
Orta	35	20	13
Orta	45	20	12
Düşük	25	20	9
Düşük	42	20	7
Orta	32	20	14
Orta	44	20	12
Yüksek	33	20	18
Yüksek	49	20	16

5. SONUÇLAR VE TARTIŞMA

Bu çalışmada geliştirilen kamera ve mesafe sensörü tabanlı algılama sistemi, özellikle aydınlık koşullarda yüksek doğrulukla çalışmış, kısa mesafelerde hızlı tepki vererek kuşların türbin kanatlarına yaklaşmadan önce algılanmasını mümkün kılmıştır. Ancak karanlık ortamlarda performansın zayıflaması ve mesafe arttıkça doğruluk oranında düşüş gözlenmesi, sistemin tek başına tüm koşullarda yeterli olmadığını göstermektedir.

Elde edilen bu bulgular, literatürde rapor edilen sonuçlarla paralellik göstermektedir. Happ vd. (2021) görüntü

tabanlı izleme sistemlerinin gündüz koşullarında etkinliğini vurgulamışlar, ancak düşük ışık koşullarında performansın belirgin şekilde düştüğünü bildirmişlerdir. Yarbrough vd. (2023) termal kameraların gece koşullarında tespit başarısını artırabileceğini göstermişlerdir. Bu durum, mevcut çalışmada kamera tabanlı sistemin sınırlılıklarının radar veya termal sensörlerle entegre edilmesi gerektiğini ortaya koymaktadır.

Ayrıca, bu çalışmada kısa mesafelerde YOLOv4 ile yüksek tespit ve başarı oranı elde edilmesi Liu vd., (2024)'nin çalışmasında elde edilen sonuçlarla uyumludur. Bununla birlikte, uzak mesafelerde doğruluğun azalması, yalnızca görsel sistemlere dayalı yaklaşımların sınırlı kapsama alanına sahip olduğunu bir kez daha doğrulamaktadır.

Çalışmanın bütüncül yaklaşımı, yani görsel iyileştirme ile yapay zekâ destekli algılama sistemlerinin birlikte kullanımı, hibrit çözümlerin daha etkili olduğunu savunan çalışmalara da paralel bulgular sunmaktadır. McClure, (2021) tarafından sunulan IdentiFlight sistemi, kamera tabanlı otomatik durdurma ile kartal ölümlerinde %82 oranında azalma sağlamıştır. Benzer şekilde De Lucas (2020) tarafından geliştirilen DTBird sistemi, kamera tabanlı tespit ile caydırıcı ve otomatik durdurma modüllerini bir arada kullanarak kuş çarpışma riskini önemli ölçüde azaltmıştır.

Bu sonuçlar, mevcut çalışmada kullanılan yaklaşımın da benzer biçimde etkili olabileceğini göstermektedir. Özellikle, görsel iyileştirme yöntemlerinin yapay zekâ tabanlı algılama sistemleriyle entegre edilmesi, çarpışma riskini daha da azaltabilecek kapsamlı bir strateji sunmaktadır (May, 2020). Genel değerlendirme sonucunda, bu çalışma rüzgâr türbinlerinin kuş ölümlerine neden olan etkilerini azaltmaya yönelik mevcut bilimsel yaklaşımları desteklemekte ve bu alanda bütünsel bir çözüm modelinin gerekliliğini ortaya koymaktadır. Elde edilen sonuçlar, sürdürülebilir enerji üretimi ile ekolojik dengenin korunması arasındaki hassas ilişkinin sağlanmasında önemli bir katkı sunmaktadır.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle, kamera tabanlı sistemin düşük ışık koşullarındaki performansı, sensörün dinamik aralığı ve gürültü seviyesi nedeniyle azalmaktadır. RGB kameralar belirli bir lux seviyesinin altına inildiğinde yeterli kontrast üretemediğinden, kuşların silüetleri arka planla bütünleşmekte ve tespit başarısı düşmektedir. Bu durum, özellikle gece veya sisli hava koşullarında sistemin güven skorlarını olumsuz etkilemektedir. Eğitimde kullanılan veri seti sınırlı sayıda (100 görüntü) özgün kuş görselinden oluşmaktadır. Veri setinin küçük boyutu, derin öğrenme modelinin farklı tür, açı veya arka plan kombinasyonlarında genelleme yeteneğini kısıtlamaktadır. Bu nedenle model, sahadan elde edilecek daha geniş ve çeşitlendirilmiş veri setleriyle yeniden eğitildiğinde daha yüksek doğruluk potansiyeline ulaşabilir. Testlerin laboratuvar ölçekli ortamda yapılmış olması, sistemin açık arazideki rüzgâr, yağış, yansıma ve hareketli arka plan gibi karmaşık koşullarda denenmemiş olduğu anlamına gelmektedir. Bu da sonuçların saha koşullarında birebir aynı performansla tekrarlanamayabileceğini göstermektedir. Son olarak, donanım olarak kullanılan NVIDIA Jetson Nano enerji verimliliği açısından avantajlı olsa da daha karmaşık ağların (YOLOv5, YOLOv8 vb.) çalıştırılmasında işlem gücü sınırlayıcı olabilmektedir. Gelecekte yapılacak saha testlerinde daha güçlü gömülü platformların (örneğin Jetson Xavier veya Orin serisi) ve farklı sensörlerin (IR, termal, radar) entegrasyonu, bu sınırlılıkların önemli bir kısmını ortadan kaldıracaktır.

Ayrıca, bu çalışma gelecekte yapılacak araştırmalara yön verebilecek bazı öneriler sunmaktadır:

- **Sensör Entegrasyonu:** Kamera tabanlı sistemlerin radar ve termal sensörlerle entegre edilmesi, farklı sensörlerin güçlü yönlerini bir araya getirerek daha kapsamlı ve güvenilir bir tespit altyapısı oluşturacaktır.
- **Algoritma Özelleştirme:** Kuş sürülerini tanımlayan derin öğrenme algoritmalarının farklı coğrafi bölgeler ve kuş türlerine uyarlanması, sistemin genel doğruluk düzeyini artıracaktır. Bu kapsamda, çeşitlendirilmiş veri setleriyle algoritmaların yeniden eğitilmesi önem taşımaktadır.
- **Çevresel Faktörlerin Analizi:** Rüzgâr hızı, hava koşulları ve mevsimsel değişimlerin kuş davranışları üzerindeki etkilerinin derinlemesine incelenmesi, sistemlerin farklı iklim koşullarına uyum sağlayabilmesi açısından kritik öneme sahiptir. Özellikle göç dönemlerinde türbin sahalarında uygulanabilecek özel stratejiler geliştirilmelidir.
- **Saha Uygulamaları:** Çalışmada önerilen yöntemlerin farklı coğrafi bölgelerde ve ekosistemlerde test edilmesi, yöntemin uyarlanabilirliğini artıracak ve daha geniş ölçekli bir veri tabanı oluşturulmasına katkı sağlayacaktır.
- **Uzun Süreli İzleme:** Sistem performansının mevsimsel ve yıllık değişimlere karşı değerlendirilmesi amacıyla uzun vadeli saha çalışmalarının yürütülmesi önerilmektedir.
- **Düşük ışık koşullarında sistem performansındaki düşüş,** RGB kameraların sınırlı dinamik aralık ve düşük lux duyarlılığından kaynaklanmaktadır. Bu nedenle, gelecekteki uygulamalarda kızılötesi (IR) ve termal görüntüleme destekli gece görüş kameralarının sisteme entegre edilmesi planlanmaktadır. IR kameralar,

görünür ışık bulunmadığında dahi kızılötesi dalga boylarında görüntü alabilmekte ve bu sayede kuşların hareketini karanlık ortamlarda tespit etmeye olanak sağlamaktadır. Termal kameralar ise canlıların vücut ısını algılayarak tamamen karanlık koşullarda bile ısı kontrastına dayalı algılama yapabilir.

Çıkar Çatışması Beyanı

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

Yazar Katkısı Beyanı

Yazar-1, Yazar-3: Fikir, Orijinal Taslak Oluşturma, Yazım, Metot Oluşturma, Deneysel çalışma, Sonuç ve Tartışma

Yazar-2: Kontrol etme ve düzeltme, Makalenin yapısının düzenlenmesi, Sonuç ve Tartışma

KAYNAKLAR

- Arnett, E. B., Huso, M. M. P., Schirmacher, M. R., & Hayes, J. P. (2011). Altering turbine speed reduces bat mortality at wind-energy facilities, *Frontiers in Ecology and the Environment*, 9(4), 209–214. <https://doi.org/10.1890/100103>
- Ballester, P., May, R., & Reusch, C. (2024). A standardized protocol for evaluating automated detection systems to reduce wildlife collisions at wind farms, *Journal of Environmental Management*, 352, 119723. <https://doi.org/10.1016/j.jenvman.2024.119723>
- De Lucas, M., Ferrer, M., Bechard, M. J., & Muñoz, A. R. (2020). Griffon vulture mortality at wind farms in southern Spain: Distribution of fatalities and active mitigation measures, *Biodiversity and Conservation*, 29(2), 397–414. <https://doi.org/10.1007/s10531-019-01895-0>
- Desholm, M., & Kahlert, J. (2005). Avian collision risk at an offshore wind farm, *Biological Conservation*, 131(3), 312–322. <https://doi.org/10.1016/j.biocon.2006.04.006>
- Happ, J., Gorresen, P. M., & Cryan, P. M. (2021). Automated daytime and nighttime monitoring of wildlife activity at wind turbines using visual and thermal cameras, *Ecological Informatics*, 64, 101367. <https://doi.org/10.1016/j.ecoinf.2021.101367>
- Kekkonen, J., et al. (2025). Biologically inspired warning patterns: Adding red, black, and yellow to wind turbine blades could reduce bird collisions (preprint), *bioRxiv*. <https://doi.org/10.1101/2025.04.14.648692>
- Klar, N., Gifary, N., Ziegler, F. P. G., et al. (2025). BirdRecorder's AI on Sky: Detection and classification of endangered birds around wind turbines. *arXiv preprint*, arXiv:2508.18136*. <https://arxiv.org/abs/2508.18136>
- Liu, Y., Zhang, H., & Chen, X. (2024). Bird detection near wind turbines using YOLOv4 in grayscale video, *Sensors*, 24(7), 2885. <https://doi.org/10.3390/s24072885>
- May, R., Nygård, T., Falkdalen, U., Åström, J., Hamre, Ø., & Stokke, B. G. (2020). Paint it black: Efficacy of increased wind turbine rotor blade visibility to reduce avian fatalities. *Ecology and Evolution*, 10(16), 8927–8935. <https://doi.org/10.1002/ece3.6592>
- McClure, C. J. W., Martinson, L., & Allison, T. D. (2021). Automated curtailment programs reduce eagle fatalities at wind energy facilities, *Journal of Applied Ecology*, 58(4), 858–868. <https://doi.org/10.1111/1365-2664.13804>
- Oregon State University. (2024, August 20). Scientists studying impact of painting wind turbine blade black to reduce bird collisions. OSU Newsroom. <https://news.oregonstate.edu/news/scientists-studying-impact-painting-wind-turbine-blade-black-reduce-bird-collisions>
- Pallanich, J. (2025, June). AI-Driven bird monitoring reduces wind turbine collision risk. *Journal of Petroleum Technology*. <https://jpt.spe.org/avian-intelligence-ai-driven-bird-monitoring-reduces-wind-turbine-collision-risk>
- Vattenfall. (2025, January). AI sheds light on bird collisions at offshore wind farms. Press release. <https://group.vattenfall.com/press-and-media/newsroom/2025/ai-sheds-light-on-bird-collisions-at-offshore-wind-farms>
- Yarbrough, L., Farnsworth, A., & Sheldon, D. (2023). Automated classification of animals in thermal videos at wind energy facilities using deep learning (preprint), *bioRxiv*. <https://doi.org/10.1101/2023.05.20.541556>