



Artificial Intelligence and Unmanned Aerial Vehicles in Digital Livestock Farming: Hair Goat Detection, Tracking and Counting in Mountainous and Rough Terrain Using Deep Learning and Computer Vision

Cihan Çakmakçı^{1,a,*}

¹Department of Agricultural Biotechnology, Faculty of Agriculture, Van Yüzüncü Yıl University, Van, Türkiye

*Corresponding author

ARTICLE INFO	ABSTRACT
<p><i>Research Article</i></p> <p>Received : 02.02.2024 Accepted : 18.03.2024</p> <p>Keywords: Deep Learning Unmanned Aerial Vehicles (UAV) Goat Detection YOLOv8 Precision Livestock Farming</p>	<p>The need to increase the production of high-quality animal products due to the rapid increase in global food demand has brought about the need for the use of technology in modern animal husbandry practices. Automatic monitoring and management of animals is of great importance in increasing productivity, especially in small ruminant farming under extensive conditions. At this point, combining high-resolution images obtained from unmanned aerial vehicles (UAV) and deep learning algorithms has the potential to provide effective solutions in remote monitoring of flocks. In this study, it was aimed to automatically detecting, tracking and counting hair goats using deep learning algorithms on high-resolution images obtained from UAV. In this context, five different models, namely YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l and YOLOv8x, which are among the most current state-of-the-art You Only Look Once (YOLOv8) architecture, were trained on UAV images obtained from real animal monitoring flights. According to the findings, the YOLOv8s architecture showed the highest performance in terms of both bounding box detection and segmentation performance, with an F1 score of 0.95 and mAP50 value of 0.99. Consequently, it has been revealed that the proposed deep learning-based approach can be an effective, low-cost and sustainable solution for UAV-supported precision livestock farming applications.</p>

Türk Tarım – Gıda Bilim ve Teknoloji Dergisi, 12(7): 1162-1173, 2024

Dijital Hayvancılıkta Yapay Zekâ ve İnsansız Hava Araçları: Derin Öğrenme ve Bilgisayarlı Görme İle Dağlık ve Engbeli Arazide Kıl Keçisi Tespiti, Takibi ve Sayımı

MAKALE BİLGİSİ	ÖZ
<p><i>Araştırma Makalesi</i></p> <p>Geliş : 02.02.2024 Kabul : 18.03.2024</p> <p>Anahtar Kelimeler: Derin Öğrenme İnsansız Hava Araçları (İHA) Keçi Tespiti YOLOv8 Hassas Hayvancılık</p>	<p>Küresel gıda talebindeki hızlı artış nedeniyle yüksek kaliteli hayvansal ürün üretiminin artırılması gerekliliği, modern hayvancılık uygulamalarında teknoloji kullanımı ihtiyacını beraberinde getirmiştir. Özellikle ekstansif koşullarda küçükbaş hayvan yetiştiriciliğinde hayvanların otomatik olarak izlenmesi ve yönetilmesi, verimliliğin artırılmasından büyük öneme sahiptir. Bu noktada, insansız hava araçlarından elde edilen yüksek çözünürlüklü görüntüler ile derin öğrenme algoritmalarının birleştirilmesi, sürülerin uzaktan takip edilmesinde etkili çözümler sunma potansiyeli taşımaktadır. Bu çalışmada, insansız hava araçlarından (İHA) elde edilen yüksek çözünürlüklü görüntüler üzerinde derin öğrenme algoritmaları kullanılarak kıl keçilerinin otomatik olarak tespit edilmesi, takip edilmesi ve sayılması amaçlanmıştır. Bu kapsamda, en güncel You Only Look Once (YOLOv8) mimari varyasyonlarından YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x olmak üzere beş farklı model gerçek hayvan izleme uçuşlarından elde edilen İHA görüntüleri üzerinde eğitilmiştir. Elde edilen bulgulara göre, 0,95 F1 skoru ve 0,99 mAP50 değeri ile hem sınırlayıcı kutu tespiti hem de segmentasyon performansı açısından en yüksek başarıyı YOLOv8s mimarisi göstermiştir. Sonuç olarak, önerilen derin öğrenme tabanlı yaklaşımın, İHA destekli hassas hayvancılık uygulamalarında etkili, düşük maliyetli ve sürdürülebilir bir çözüm olabileceği öngörülmektedir.</p>

^a cakmakcician@gmail.com

<https://orcid.org/0000-0001-6512-9268>



Giriş

Dünya nüfusunun 2030 yılına kadar 8,5 milyara ulaşması beklenirken, bu artışın sadece genel gıda talebini değil, aynı zamanda yüksek kaliteli hayvansal protein talebini de önemli ölçüde artırması beklenmektedir (Çakmakçı ve ark., 2023; OECD ve ark., 2022). Küresel gıda talebinin 2050 yılına kadar %56 oranında artması beklenirken, bu artışın büyük bir kısmının hayvansal proteinlere yönelik olacağı tahmin edilmektedir (Daszkiewicz, 2022; Henchion ve ark., 2017; van Dijk ve ark., 2021). Önümüzdeki on yıl içinde küresel et kaynaklı protein tüketiminin, gelir ve nüfus artışına bağlı olarak 2018-2020 dönemi ortalamasına göre %14 artması beklenmektedir (OECD ve ark., 2022). Artan hayvansal ürün talebi, hayvancılık sektörü üzerinde baskı oluşturarak çiftçileri faaliyetlerini genişletmeye ve büyümeye yönlendirmektedir (Morrone ve ark., 2022). Bu durum, ölçek ekonomilerinin etkisiyle daha büyük çiftliklerin ortaya çıkmasına neden olmaktadır (Morrone ve ark., 2022). Ancak, büyük ölçekli çiftliklerin ortaya çıkmasıyla birlikte, geleneksel gözlem ve deneyimlere dayalı sürü yönetimi zorlaşmaktadır (Gezici ve ark., 2023).

Tarım sektöründe dijitalleşme ve hassas tarım uygulamalarının kullanımı, verimliliği ve sürdürülebilirliği artırmak için giderek daha fazla önem kazanmaktadır. Yapay zekâ ve derin öğrenme yöntemleri, tarımsal faaliyetlerin izlenmesi, analizi ve otomasyonu için güçlü araçlar sunmaktadır (Beyaz ve Gül, 2023; Yu ve ark., 2022). Modern hayvancılık, yapay zekâ (AI) ve insansız hava aracı (İHA) teknolojilerindeki gelişmelerin etkisiyle hızlı bir dönüşüm geçirmektedir. Bu bağlamda, hassas hayvancılık teknoloji ve uygulamaları sürü izleme, takip ve yönetimi uygulamalarının optimize edilmesi için çok önemli bir alan olarak karşımızda durmaktadır (Halachmi, 2015). Hassas hayvancılık, sensör tabanlı bireysel olarak hayvanları ele alan yaklaşım olarak da bilinen yönetilebilir en küçük üretim birimini yönetmeyi amaçlayan gerçek zamanlı izleme teknolojileri olarak tanımlanmaktadır (Halachmi ve ark., 2019). Hassas hayvancılık teknolojileri arasında otomatik tartım sistemleri (Brown ve ark., 2015; Song ve ark., 2018), bilgisayarlı görme ile bireysel hayvan tespiti ve tanıma (Billah ve ark., 2022; Kumar ve Singh, 2019), davranışların izlenmesi ve takibi (Cheng ve ark., 2022; Fuentes ve ark., 2020), mizaç özelliklerinin tespiti (Çakmakçı ve ark., 2023), duyu durumu (Neethirajan ve ark., 2021) ve ağrı seviyelerinin belirlenmesi (Lencioni ve ark., 2021), vücut sıcaklığının izlenmesi (Sellier ve ark., 2014; Shu ve ark., 2022), sürü yönetimi için İHA'ların kullanımı (Porto ve ark., 2021; Sarwar ve ark., 2021) ve otlama yönetimi için sanal çitlerin kullanımı (Campbell ve ark., 2019) gibi bir çok uygulama yer almaktadır.

Çiftlik hayvanlarında sürü yönetimi ve izlenmesi çiftçiler için kritik öneme sahiptir ancak manuel gözlem, takip veya sayım gibi işlemler, özellikle kırsal ve dağlık arazilerde son derece zaman alıcı ve zordur. Özellikle ekonomik ve işgücü kısıtlamaları, üreticilerin ekstansif koşullarda yetiştirilen sürülerde her hayvanı ayrı ayrı değerlendirmesini zorlaştırmaktadır. Özellikle, kırsal ve dağlık arazilerin yarattığı yapısal zorluklar, kıl keçileri gibi bu gibi engebeli arazilerde otlayan hayvanların tespitini, takibini ve sayımını karmaşık bir görev haline getirmektedir. İHA teknolojileri ve derin öğrenme

algoritmalarındaki son gelişmeler, otomatik hayvan izleme sistemleri için yeni fırsatlar sunmaktadır (Akyuzlu ve ark., 2023; Borges ve ark., 2021; Moradeyo ve ark., 2023; Xu ve ark., 2020).

Bu çalışma, İHA ile elde edilen görüntüleri kullanarak, derin öğrenme tabanlı yapay zekâ yöntemlerinden biri olan, nesnelerin otomatik tespiti ve segmentasyonu için hızı ve doğruluğuyla bilinen You Only Look Once (YOLO) (Joseph ve ark., 2016) algoritmalarından biri olan Ultralytics tarafından geliştirilen YOLOv8 (You Only Look Once version 8) (Glenn ve ark., 2023) ile mera ortamındaki kıl keçilerinin otomatik olarak tespitini, takibini ve sayımını yaparak bu alana katkıda bulunmayı amaçlamaktadır. Ultralytics YOLOv8, önceki YOLO versiyonlarının başarısını temel alan ve performansı daha da artırmak için yeni özellikler ve iyileştirmeler sunan en gelişmiş ve en güncel derin öğrenme tabanlı gerçek zamanlı nesne tespiti ve takibi, görüntü segmentasyonu (bölütleme), görüntü sınıflandırma ve poz tahmini gibi görevlerde üst düzey performans sağlamak amacıyla geliştirilmiş ve 2023 yılında kullanıma sunulmuş modellerden biridir (Glenn ve ark., 2023). Yaygın bilgisayarlı görme uygulamalarında iyi sonuçlar vermesine rağmen, YOLOv8, küçük, çok sayıda hedefler ve karmaşık arka planlar gibi ek zorlukları barındıran İHA ile elde edilmiş çiftlik hayvanı görüntüleri üzerinde henüz kapsamlı bir şekilde değerlendirilmemiştir.

Bu bağlamda, bu çalışmanın temel araştırma sorusu, YOLOv8 algoritması kırsal dağlık ve engebeli alanlarda İHA ile elde edilen görüntülerden kıl keçilerini etkili bir şekilde tespit ederek takip ve sayımını başarılı bir şekilde gerçekleştirip gerçekleştiremeyeceğini değerlendirmektir. Temel hedef, kıl keçi tespiti, takibi ve sayımı için en uygun YOLOv8 algoritmasının belirlenmesi ve İHA ile kıl keçilerinin izlenmesi ve yönetimi için daha etkili bir araç sağlanmasıdır. Bu amaçla, bu çalışmada gerçek sürü izleme uçuşlarından elde edilen İHA kıl keçisi görüntüleri üzerinde çeşitli YOLOv8 nesne tespiti ve görüntü bölütleme mimarileri eğitilmiş ve bunların kıl keçisi tespit, takip ve sayım performansları değerlendirilmiştir.

Materyal ve Yöntem

Verilerin Elde Edilmesi ve Ön İşlenmesi

Bu çalışmanın verileri, Van İli'nin Gevaç ilçesine bağlı Altınışık Köyünde (38° 24' 24.4764'' K, 42° 53' 30.1236'' D) yetiştiriciliği yapılan yaklaşık 1500 başlık kıl keçi sürüsünün otlatıldığı meralarda İHA kullanılarak elde edilen görüntülerden oluşmaktadır. Görüntüler, 20-30 metre irtifadan, 4K (3840×2160 piksel) çözünürlükte ve saniyede 30 kare (fps) hızında görüntü yakalama kapasitesine sahip bir İHA (DJI Mini 2 Fly More Combo, Çin) ile elde edilmiştir. Video görüntüleri, keçilerin havadan farklı konumlardan başarılı bir tespit yapabilmek amacıyla merada farklı açılardan çekilmiştir. Etkili bir neste tespiti ve sınıflandırması için veri kümesi hazırlama ve verilerin etiketlenmesi önemli faktörlerdir (Ravi ve El-Sharkawy, 2022). Bu çalışmada, yüksek oranda benzerlik gösteren ardışık kareler ayıklanıp yalnızca daha az benzerlik gösteren kareler seçilerek kaydedilmiştir. Bu amaçla, OpenCV kütüphanesi ile birlikte skimage


kütüphanesinde bulunan yapısal benzerlik indeksi fonksiyonu kullanılarak %50 benzerlik gösteren kareler ayıklanmıştır. Ayrıca belirli sayıda kare atlanarak (30 karede bir) hesaplama yükü azaltılmıştır. Böylelikle etiketleme için gereken zaman ve iş yükünün önemli ölçüde azaltılması amaçlanmıştır. Elde edilen kareler Tagged Image File Format (TIFF) formatında kaydedilerek etiketlenme işlemi için dosyalanmıştır. Bu çalışma Van Yüzüncü Yıl Üniversitesi, Hayvan Denepleri Yerel Etik Kurulu'nun 30/11/2023 tarih ve 2023/13-11 sayılı kararı ile yürütülmüştür.

Verilerin Etiketlenmesi (Labeling)

Etiketleme, görüntülerde nesnelere sınırlarını çizilerek belirli sınıf isimleri ile tanımlanması işlemi ifade eder. Bu çalışmada, görüntüler üzerindeki ilgili bölgeleri seçmek ve etiketlemek için açık kaynaklı bir grafiksel görüntü etiketleme aracı olan Labelme (Wada, 2018) kullanılmıştır. Etiketleme için, Labelme'nin poligon özelliği kullanılarak görüntülerdeki her bir kıl keçisinin vücudunun dış kenarı boyunca, başlangıç noktasına bağlanana kadar noktalar seçilmiştir (Şekil 1). Her poligon "Keçi-Goat" sınıf etiketiyle işaretlenmiştir. Labelme ile etiketlenen her bir görüntü karesinde nesnelere (keçilerin) yerini bildiren koordinatlar JSON dosya formatında kaydedilmiştir. Daha sonra labelme2yolo kütüphanesi kullanılarak bu etiketleme bilgileri YOLO formatına dönüştürülerek, YOLO modelinin eğitilmesi için gerekli olan veri formatı oluşturulmuştur. Her birinde birden fazla nesne (keçi) içeren 107 etiketli görüntü (1139 keçi) YOLO modellerini eğitmek için kullanılmıştır. Bu veri setindeki görüntülerin 81 görüntü (803 keçi) eğitim, 26 görüntü (336 keçi) ise test veri seti olarak kullanılmıştır. Görüntülerin işleme sürecini adım adım açıklayan bir iş akışı diyagramı Şekil 2'de verilmiştir.

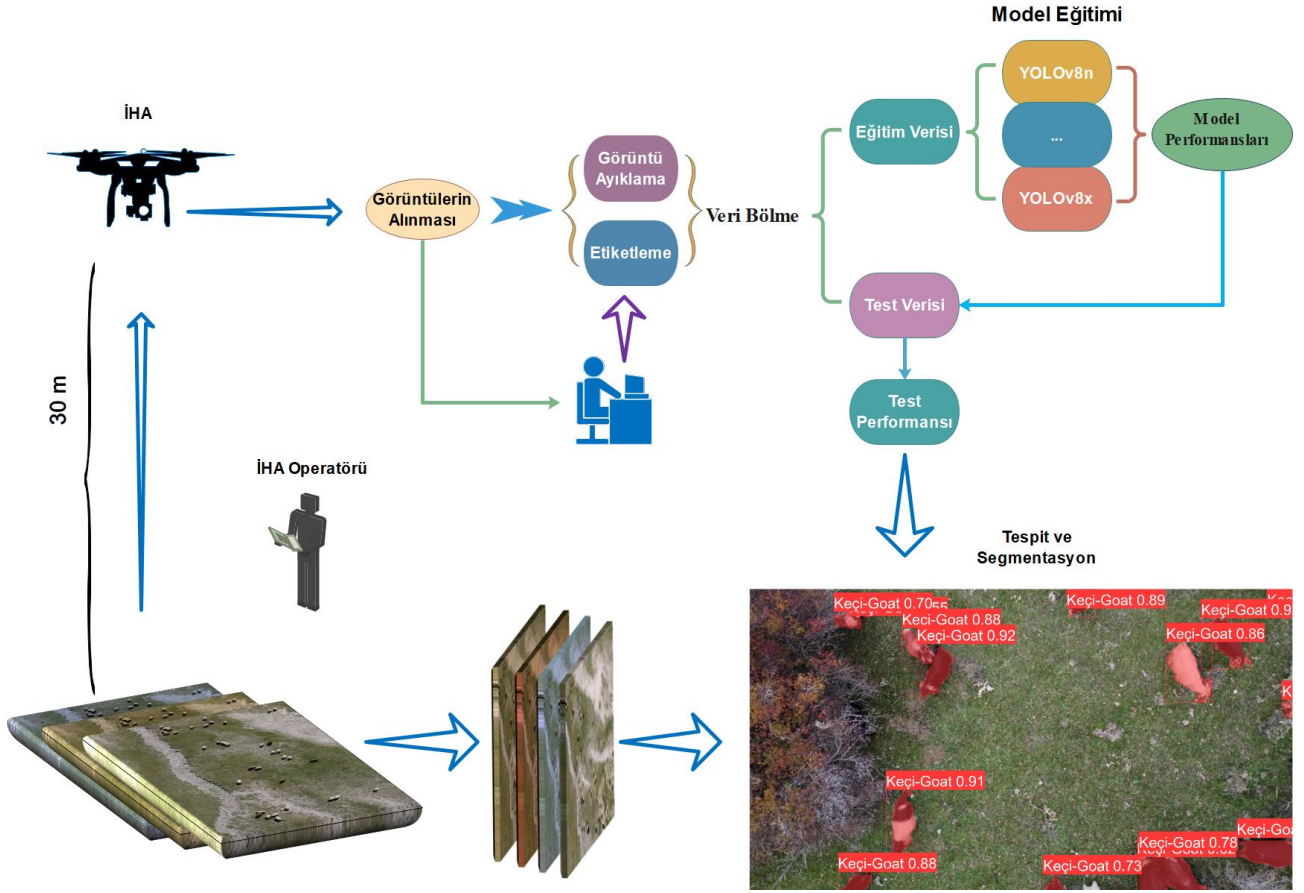
YOLOv8 modellerinin eğitimi

Nesne tespiti için geliştirilmiş popüler bir derin öğrenme algoritması olan YOLO, tek aşamalı bir mimariye sahiptir ve nesnelere sınırlayıcı kutularını doğrudan tahmin ederek gerçek zamanlı nesne tespiti için oldukça uygundur (Redmon ve ark., 2015). YOLOv8, önceki YOLO sürümlerine göre performansı ve esnekliği daha da artırmak için yeni özellikler ve iyileştirmeler sunan ve nesne tespit ve takibi, segmentasyon, görüntü sınıflandırma ve poz tahmini gibi görevleri daha hızlı ve etkili bir şekilde gerçekleştirebilen bir modeldir (Glenn ve ark., 2023). YOLOv8 mimarisinin detayları için resmi websitesi (<https://github.com/ultralytics/ultralytics>) incelenebilir (Glenn ve ark., 2023). Bu çalışmada, YOLOv8 modellerinin eğitimi, aktarım öğrenmesi yöntemi kullanılarak gerçekleştirilmiştir (Pan ve Yang, 2010). Bu yöntemle, COCO veri seti (Lin ve ark., 2014) üzerinde önceden eğitilmiş beş farklı YOLOv8 mimarisine ait ağırlıklar (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l ve YOLOv8x) kullanılmıştır. Bu sayede, modelin belirli bir görevdeki performansı artırılmış ve önceki öğrenmelerden elde edilen bilgiler transfer edilmiştir. Eğitim ve doğrulama aşamalarında, görüntüler 640x640 boyutunda kullanılmıştır. Modellerin eğitimi için 100 epok (epoch) değeri ve model güncellemede kullanılan örnek sayısı (batch size) 8 olarak belirlenmiştir (daha büyük değerler, model mimarilerinden dolayı bellek sorunlarına neden olduklarından bu değer düşük tutulmuştur). Modellerin nesne tespiti ve segmentasyon performansını değerlendirmek için kesinlik (precision), duyarlılık (recall), F1 skoru ve genel ortalama kesinlik (mAP50, mAP50-95) ölçütleri kullanılmıştır (Tablo 1). Ayrıca, sistem tarafından gerçekleştirilen sayım sonuçları, manuel sayım sonuçları ile karşılaştırılmış ve sayım hatası hesaplanmıştır.



Şekil 1. Görüntülerin etiketlenmesi ve JSON formatında kaydedilmesi. Burada, "label" etiketini adını, "points" ise etiketin köşelerinin koordinatlarını içerir.

Figure 1. Labeling the images and saving them in JSON format. Here, "label" contains the name of the object, and "points" contains the coordinates of the corners of the label.



Şekil 2. Görüntülerin işleme sürecini adım adım açıklayan bir iş akışı diyagramı.
Figure 2. A workflow diagram explaining the step-by-step image processing pipeline.

Tablo 1. Derin öğrenme modellerinde kullanılan performans ölçütleri.
Table 1. Performance metrics used in deep learning models.

Ölçütler	Hesaplama
Kesinlik (Precision - P)	$\frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}}$
Duyarlılık (Recall - R)	$\frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}}$
F1 Skoru	$\frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$
mAP: Genel Ortalama Kesinlik (Mean Average Precision)	$\frac{\sum_{i=1}^n AP}{n}$ n: toplam sınıf sayısı
AP: Ortalama Kesinlik (Average Precision)	$\int_0^1 P(R) dR$
Doğru Pozitif	Modelin doğru bir şekilde pozitif olarak tahmin ettiği örnek sayısı.
Yanlış Pozitif	Modelin yanlış bir şekilde pozitif olarak tahmin ettiği örnek sayısı.
Yanlış Negatif	Modelin pozitif olarak tahmin etmesi gereken ancak yanlış bir şekilde negatif tahmin ettiği örnek sayısı.

Çalışma için PyTorch ve torchvision kütüphanelerinin GPU sürümü Python ortamına kurularak model eğitimleri gerçekleştirilmiştir. YOLOv8 modellerinin eğitimi, NVIDIA GeForce RTX3050 ekran kartı, 12. Nesil Intel(R)

Core(TM) i7-12700H 2.30 GHz işlemci ve 16 GB RAM'e sahip bir Windows bilgisayarda Python 3.10 kullanılarak yapılmıştır.

Bulgular

Beş farklı YOLOv8 mimarisinin kıl keçisi tespiti ve segmentasyonunda karşılaştırmalı performans analiz sonuçları Tablo 2’de verilmiştir. Eğitim süresi bakımından en hızlı model YOLOv8n modeli sınırlayıcı kutular açısından en yüksek kesinliğine (0,98) sahip olurken duyarlılık değeri en düşük model olmuştur. Buna karşın büyük model olan YOLOv8x ise hem sınırlayıcı kutular hemde segmentasyon maskeleri açısından yüksek performans gösterirken hesaplama süresi bakımından (6,305 saat) en yavaş model olmuştur. Bununla birlikte, genel performansı değerlendiren F1 skorunda 0,95 ile YOLOv8s modeli öne çıkmaktadır. Bu, hem yüksek kesinlik hem de yüksek duyarlılık sağlayarak dengeli bir performans gösterdiğine işaret etmektedir. YOLOv8s aynı zamanda 0,99 mAP50 ile sınırlayıcı kutu tespiti için diğer modellere kıyasla daha yüksek bir ortalama kesinliğe sahip olmuştur. Özellikle 0,78’lik mAP50-95 skoru, zorlu durumlarda bile tutarlı bir performans gösterdiğine işaret etmektedir. Benzer şekilde 0,98 mAP50 ve 0,70 mAP50-95 değerleri ile segmentasyon işleminde de yüksek performans göstermiştir. Ayrıca, oldukça hızlı bir eğitim süresine (0,357 saat) sahip olması, YOLOv8s’in verimli bir mimariye sahip olduğunu göstermektedir. Bu sonuçlar,

hem sınırlayıcı kutu hem de piksel düzeyindeki segmentasyon tahmininde modelin yüksek başarı elde ettiğine göstermektedir.

Şekil 3A YOLOv8s modelinin eğitimi sırasında kullanılan mozaiklenmiş veri setine ilişkin örnekleri göstermektedir. Mozaikleme tekniği, birden fazla görüntüyü birleştirerek tek bir görüntü oluşturur. Bu yöntem, her bir eğitim grubundaki (model güncellemede kullanılan örnek sayısı - batch size) nesne ve sahne çeşitliliğini artırarak modelin genel performansını artırmayı sağlamaktadır. Şekil 3B doğrulama veri setinden seçilmiş örnek görüntülere ait tahmin edilen segmentasyon maskelerini gösterir. Şekil 3B’de YOLOv8s modelinin görüntülerdeki nesnelere başarılı bir şekilde tespit ettiğini ve bu nesnelere ait segmentasyon maskelerini başarılı bir şekilde tahmin ettiği görülmektedir.

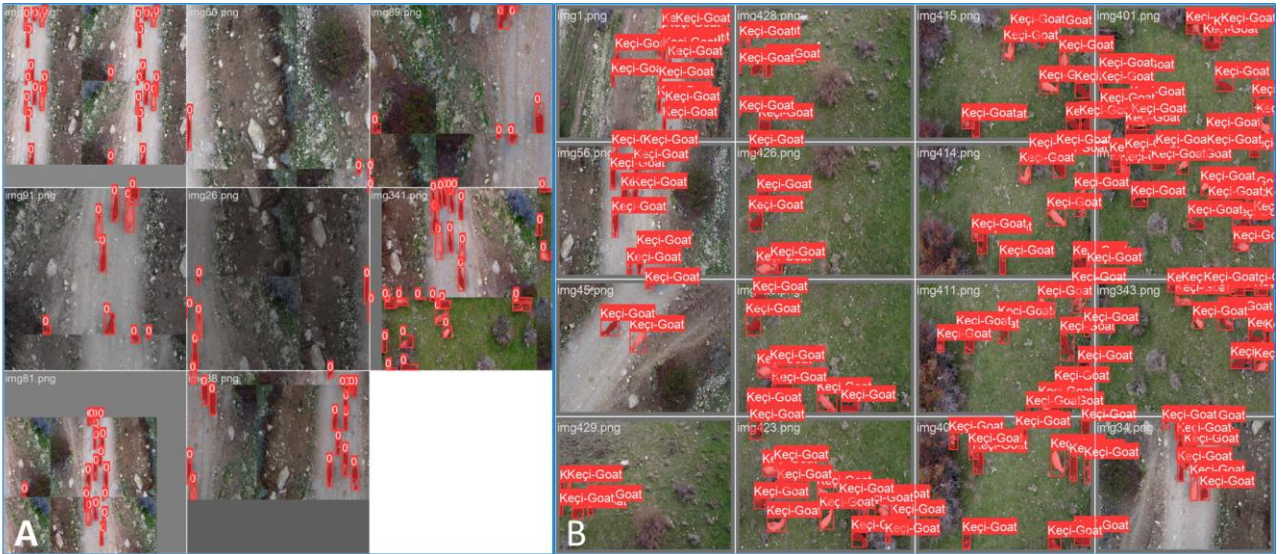
Modelin karmaşık ortamlardaki keçileri tespit yeterliliğini değerlendirmek için test veri seti sonuçlarına dayalı olarak karmaşıklık matrisi oluşturulmuştur (Şekil 4A). Bu karmaşıklık matrisi Kesinlik-Duyarlılık eğrisi (Şekil 4B) ile birlikte keçi tespiti için modelin fizibilitesini doğrulamaktadır.

Tablo 2. Kıl keçisi tespiti ve segmentasyonu için farklı yolov8 modellerinin karşılaştırmalı performans analizi.

Table 2. Comparative performance analysis of different YOLOv8 models for hair goat detection and segmentation.


Model	Kesinlik	Sınırlayıcı Kutular				Kesinlik	Segmentasyon Maskeleri				Eğitim Süresi (saat)
		Duyarlılık	F1	mAP50*	mAP50-95		Duyarlılık	F1	mAP50*	mAP50-95	
YOLOv8n	0,98	0,92	0,95	0,97	0,72	0,95	0,93	0,94	0,97	0,66	0,185
YOLOv8s	0,95	0,95	0,95	0,99	0,78	0,97	0,93	0,95	0,98	0,70	0,357
YOLOv8m	0,94	0,95	0,94	0,98	0,80	0,95	0,93	0,94	0,97	0,69	1,145
YOLOv8l	0,97	0,94	0,95	0,98	0,79	0,97	0,92	0,94	0,96	0,68	3,029
YOLOv8x	0,96	0,93	0,94	0,97	0,78	0,95	0,93	0,94	0,96	0,69	6,305

*mAP: genel ortalama kesinlik (mean average precision).




Şekil 3. YOLOv8s modelinin eğitimi sürecinde kullanılan mozaiklenmiş veri setini (A) ve doğrulama veri setinden seçilmiş örnek görüntüleri ile bu görüntülere ait tahmin edilen segmentasyon maskelerini (B) göstermektedir.

Figure 3. The mosaic dataset (A) used during the training process of the YOLOv8s model, along with example images selected from the validation dataset and their corresponding predicted segmentation masks (B).



Şekil 4. YOLOv8s modelinin A) karmaşıklık matrisi ve B) Kesinlik-Duyarlılık eğrisi.
Figure 4. A) Confusion matrix and B) Precision-Recall curve of the YOLOv8s model.




Şekil 5. YOLOv8s modelinin sınır kutusu tespiti ve segmentasyon performansına ilişkin elde edilen kayıpların (loss) epoklar boyunca seyrini gösteren grafikler.

Figure 5. Figure illustrates the graphs depicting the loss trends of YOLOv8s model's bounding box detection and segmentation performance across epochs.


YOLOv8s modelinin eğitim sırasında sınırlayıcı kutu tespiti ve segmentasyon tahminine ilişkin elde edilen eğitim ve doğrulama kayıp (loss) değerleri epok sayısı artıkça azalış göstermiştir (Şekil 5). Toplam kayıp özellikle ilk epoklarda 1'in üzerinde seyrederken, sonraki epoklarda istikrarlı bir düşüşle 1'in altına inmiştir. Modelin sınırlayıcı kutu tespiti ve segmentasyon performansına ilişkin kesinlik, duyarlılık ve mAP değerlerinde de epok ilerledikçe belirgin artışlar gözlenmiştir (Şekil 6). Tüm bu bulgular ışığında, YOLOv8s modelinin kıl keçisi tespit ve segmentasyon görevleri için etkili şekilde çalıştığı söylenebilir.

Şekil 7, farklı YOLOv8 modellerinin belirli bir nesneyi tahmin etme başarılarını karşılaştıran örnekleri göstermektedir. YOLOv8s modelinin kıl keçilerini tespit etme ve segmentasyon maskelerini tahmin etme konusundaki üstünlüğü göze çarpmaktadır (Şekil 7B). Buna karşın, YOLOv8m modeli aynı görüntüdeki iki kıl keçisini tespit edememiştir (Şekil 7C). Öte yandan, YOLOv8x modeli, sınırlayıcı kutu tahmininde YOLOv8s ile benzer sayıda tahmin yapabilmişken piksel düzeyinde segmentasyon maskelerini tahmin etme konusunda YOLOv8s kadar başarılı olamamıştır (Şekil 7D).



Şekil 6. YOLOv8s modelinin sınır kutusu tespiti ve segmentasyon performansına ilişkin hesaplanan ölçütleri (kesinlik, duyarlılık ve mAP) epoklar boyunca seyrini gösteren grafikler.

Figure 6. Figure illustrates the graphs depicting the trends of calculated metrics (precision, recall, and mAP) for bounding box detection and segmentation performance of the YOLOv8s model across epochs.



Şekil 7. Modellerin tahmin başarılarına ilişkin örnekler, A) Orijinal görüntü, B) YOLOv8s, C) YOLOv8m ve D) YOLOv8x.

Figure 7. Examples of prediction successes of the models: A) Original image, B) YOLOv8s, C) YOLOv8m, and D) YOLOv8x.

Şekil 8'de, YOLOv8s modelinin gerçek bir uçuş videosundan alınan bir kare örneği görülmektedir. Bu kare, modelin keçileri tespit ve takip etme yeteneğini göstermektedir. Model, yüksek doğruluk ve güvenilirlikle keçileri tanımlayabilmekte ve hareketlerini takip edebilmektedir. Bu sonuçlar, YOLOv8s modelinin gerçek dünya uygulamalarında etkili bir şekilde kullanılabileceğini göstermektedir, özellikle de hayvanların izleme ve takibinde hassas ve hızlı bir çözüm arayışına yönelik olarak çiftçiler için önemli bir gelişme sunmaktadır.

Şekil 9, keçi sayım işlemi için gerçek keçi izleme uçuşlarından elde edilen İHA görüntülerine ait video akışını göstermektedir. Uçuş esnasında elde edilen video akışı üzerinde, YOLOv8s modeli aracılığıyla keçiler başarılı bir şekilde tespit edilmekte ve her bir tespit edilen keçiye benzersiz bir takip numarası atanmaktadır. Keçilerin segmentasyon maske çerçeveleri, görüntü üzerinde renkli konturlarla işaretlenmekte ve bu sayede takip edilebilmektedir. Bu görüntü, keçi sayım işleminin video akışı üzerinden başarılı bir şekilde gerçekleştirilebildiğini göstermektedir. YOLOv8s modelinin keçi tespiti ve takibindeki başarısı, yatay çizgi kullanımıyla birlikte, keçilerin ilgi alanını geçip geçmediğinin doğru bir şekilde belirlenmesini ve sayılmasını mümkün kılmaktadır.

Modelin sayım performansı bağımsız bir test veri kümesi üzerinde değerlendirilmiştir. Test veri kümesi, mera koşullarında, İHA ile gerçek keçi izleme uçuşlarından elde edilen 4 farklı video görüntüsünden oluşmaktadır. Her video için, manuel olarak sayılan keçi sayıları referans alınmış ve otomatik sistemin tahminleri bu referanslarla karşılaştırılmıştır. Elde edilen sayım hatası ve doğruluk kriterlerine ilişkin sonuçlar Tablo 3'te sunulmuştur. Sonuçlar, sistemin gerçek dünya koşullarında oldukça iyi bir performans sergilediğini görmektedir. Video 2 için %100 doğruluk elde edilmiştir. Diğer videolarda da yüksek doğruluk oranları (%84,2 ile %92,3 arasında) gözlemlenmiştir. Sayım hatalarının çoğunlukla 1-3 aralığında olduğu görülmektedir. Ancak, modelin geneleme potansiyelini artırmak için daha fazla sayıda görüntü üzerinde ve farklı koşullar altında performansının test edilmesi gerektiği vurgulanmıştır.

Tartışma

Derin öğrenme algoritmaları, hayvancılıkta kullanılan bilgisayarlı görme sistemlerinde başarıyla uygulanmakta ve bu sayede hayvan düzeyinde gerçek zamanlı ve doğru bilgiler elde edilebilmektedir (Borges ve ark., 2021). Bu uygulamalar, çiftlik hayvanlarının otomatik takibi, davranış analizi, hastalık ve stres belirtilerinin erken tespiti gibi çeşitli alanlarda önemli bir rol oynamaktadır (Jiang ve ark., 2022; Kang ve ark., 2021; Lencioni ve ark., 2021; Morrone ve ark., 2022; Okinda ve ark., 2020). Ancak, bu uygulamalarda ilk ve en kritik adım, hedef nesnelerin doğru bir şekilde tespit edilmesidir (Kaur ve Singh, 2022). Hedef nesnelerin diğer nesnelere ayırtılması, sonraki analizlerin doğruluğunu etkileyebilmektedir (Wu ve ark., 2020).

Çalışmamızda, kıl keçilerinin İHA görüntülerinden tespiti ve segmentasyonu için çeşitli YOLOv8 mimarileri eğitilmiş ve karşılaştırılmıştır. Elde edilen sonuçlar, en yüksek performansı gösteren mimarinin YOLOv8s olduğunu göstermektedir. Bu mimari, özellikle sınırlayıcı kutu tespiti konusunda 0,95 kesinlik ve 0,95 duyarlılık değerleriyle yüksek bir başarı elde etmiştir. Ayrıca, segmentasyon başarımı da 0,97 kesinlik ve 0,93 duyarlılık ile yine yüksek düzeydedir. YOLOv8s modelinin eğitim süresi açısından da daha derin mimarilere göre avantajlı olduğu tespit edilmiştir.

Diğer çalışmalarla karşılaştırıldığında, YOLO tabanlı yöntemlerin Fast R-CNN ve Mask R-CNN yöntemlerine kıyasla hız bakımından gerçek zamanlı uygulamalara daha uygun olduğu bilinmektedir (Jiang ve ark., 2019; Qiao ve ark., 2023). Ayrıca, hem nesne tespiti hem de segmentasyon konusunda yüksek performans gösterdiği görülmüştür (Moradeyo ve ark., 2023). Örneğin, Song ve ark. (2022), koyunlarda yüz tespiti için YOLOv3 algoritmasını kullanarak %96,84'lük bir mAP değeri elde etmişlerdir. Evangelista ve ark. (2022), YOLOv7 kullanarak bıldırcınların tespiti ve takibinde %85,28 mAP'ye ve test verisetinde ise %90,49'luk bir doğruluk elde etmişlerdir. Zhang ve ark. (2022) ise keçilerde yüz tanıma için YOLOv4 tabanlı modellerinde %96,7 mAP değerine ulaşmışlardır.



Şekil 8. Yolov8s modelinin keçileri A) tespit ve B) takip başarısına ilişkin gerçek bir uçuş videosu kare örneği.

Figure 8. A frame example from a real flight video demonstrating the success of the YOLOv8s model in detecting and tracking goats.



Şekil 9. Keçi sayım işleminde gerçek uçuş esnasında çekilen video akışındaki keçiler tespit edilir, takip edilir ve belirlenen bir alanı geçen bu keçilerin sayımı yapılır. Görüntünün alt kısmında yer alan yatay kırmızı çizgi, ilgi alanını tanımlamakta ve keçilerin bu bölgeyi geçip geçmediğini belirlemek için bir eşik görevi görmektedir. Bir keçinin segmentasyon maske çerçevesi bu çizgiyi geçtiğinde, sayaç artırılmakta ve daha önce sayılmamış keçiler toplam geçiş sayısına eklenmektedir. Bu yaklaşım, belirlenen alanı geçen keçi sayısının doğru bir şekilde hesaplanmasını sağlamaktadır. Ekranın sol üst köşesinde, o anki tespit edilen keçi sayısı ve toplam geçen keçi sayısı kümülatif olarak görüntülenmektedir. Ekranın sağ üst köşesi saniyedeki kare sayısını (Frames Per Second - FPS), yani uygulamanın ne kadar hızlı çalıştığını göstermektedir. Ekranın sol alt köşesi ise her karenin işleme süresini ve karenin boyutunu göstermektedir. Bu sayaçlar, her video karesi için gerçek zamanlı olarak güncellenmektedir. Böylece kullanıcı, işlemin ilerleyişini anlık olarak takip edebilmektedir.

Figure 9. Illustrates the process of goat counting during real-flight video streams, where goats are identified, tracked, and counted as they traverse a predefined area. A horizontal red line at the bottom delineates the region of interest and acts as a threshold to ascertain whether goats have crossed this area. When a goat's segmentation mask frame intersects this line, the counter increments, and previously uncounted goats contribute to the overall passage count. This methodology ensures precise counting of goats passing through the designated area. In the upper-left corner of the screen, the current count of detected goats and the cumulative count of goats passing through are displayed. The top-right corner indicates the Frames Per Second (FPS), reflecting the application's processing speed. The bottom-left corner provides information on processing time per frame and frame dimensions. These counters are continuously updated in real-time for each video frame, allowing the user to monitor the progress of the process in real-time.

Tablo 3. Test veri kümesi 4 adet görüntüden oluşmaktadır ve her görüntüdeki keçilerin manuel sayım ve otomatik sayım sonuçlarını aşağıdaki şekilde tespit edilmiştir.

Table 3. The test dataset consists of 4 videos, and the results of the manual and automatic counting of goats in each video have been determined as follows.

Görüntü No	Manuel Sayım	Otomatik Sayım	Sayım Hatası	Doğruluk (%)	Genel Ortalama Doğruluk (%)
Video 1	18	16	2	88,9	91,4
Video 2	14	14	0	100,0	
Video 3	16	19	3	84,2	
Video 4	12	13	1	92,3	

Buna ek olarak, Guo ve ark. (2023) tarafından önerilen YOLOv5 mimarisinin, büyük ve doğruluğu yüksek ancak yavaş sürümünden (YOLOv5x) edinilen bilgilerin, daha hızlı çalışan küçük modele (YOLOv5s) aktarılmasıyla elde edilen yeni bir model önerilmiştir. Bu model, yüksek mAP 50-95 (%94,67) ve hızlı çıkarım (12,63 ms) sağlayarak gerçek zamanlı ve kesintisiz koyun ırkı tanıma için güçlü bir çözüm sunmaktadır.

İHA'lerden elde edilen görüntüler de bu tür sistemlerde sıklıkla kullanılmaktadır (Alanezi ve ark., 2022; Barbedo ve ark., 2019; Mücher ve ark., 2022). İHA'lar, büyük çiftlik alanlarının hayvanların uzaktan takibi ve sayımı gibi işlemleri otonom olarak gerçekleştirebilmektedir. Örneğin, Xu ve ark. (2020) İHA görüntülerinde Mask R-CNN modelini kullanarak hayvanları %96 doğrulukla sınıflandırırken, sığır ve koyun sayısını %92'lik bir oranla

başarılı bir şekilde tahmin edebilmişlerdir. Barbedo ve ark. (2020), derin öğrenme kullanarak İHA görüntülerinden çeşitli koşullar ve arka planlar altında sığırları sayma işlemini %90'ın üzerinde bir doğruluk oranıyla başarılı bir şekilde gerçekleştirmişlerdir. Benzer şekilde de Lima Weber ve ark. (2023), YOLOv4 ve YOLOv5 mimarilerini karşılaştırdıkları çalışmalarında, İHA görüntülerinden Nelore ırkı sığırların tespit ve sayımında her iki mimarinin de yüksek başarı gösterdiğini belirtmişlerdir. YOLOv4 mimarisini %90 kesinlik değeri elde ederken, YOLOv5'in farklı varyasyonları %90'ın üzerinde kesinlik değerleri ile Nelore sığırları başarılı bir şekilde tespit edebilmiş ve sayımları gerçekleştirebilmiştir.

Çalışmamızda kullandığımız yöntem, gerçek keçi izleme uçuşlarından elde edilen İHA görüntüleri üzerinde test edildi ve elde edilen sonuçlar, YOLOv8s modelinin keçilerin tespit ve sayımında yüksek doğruluk oranlarına sahip olduğunu göstermiştir. Bu sonuçlar, İHA görüntüleri kullanarak YOLO gibi derin öğrenme tabanlı bilgisayarlı görme uygulamalarının çiftlik hayvanlarının tespit, tanıma, takip ve sayma işlemlerini başarılı bir şekilde gerçekleştirebileceğini ortaya koymaktadır.

Elde edilen sonuçlar, çalışmada kullanılan YOLOv8 mimarisinin en güncel sürümlerinden olan YOLOv8s'in İHA tabanlı otomatik kıl keçisi izleme, takip ve sayım sistemlerinin geliştirilmesine etkili olabileceğini göstermektedir. Bu model, yüksek doğruluk ve hızlı çıkarım avantajları sunarak gerçek zamanlı hayvancılık uygulamalarında etkili bir çözüm olarak öne çıkmaktadır. Derin öğrenme yöntemlerinin hayvancılık uygulamalarındaki başarısı göz önüne alındığında, bu alanlardaki kullanımlarının gelecekte daha da artması beklenmektedir.

Her ne kadar umut verici sonuçlar elde edilmiş olsa da, sistemin bazı sınırlılıkları bulunmaktadır. Gelecekteki çalışmalarda, daha geniş ve çeşitli veri kümeleri, farklı hayvan türleri ve zorlu çevre koşullarının dikkate alınması, modelin genelleştirme kabiliyetini artıracaktır. Ayrıca, gerçek zamanlı video işlemeye entegrasyon ve maliyet analizleri yapılarak, sistemin uygulanabilirliği daha da ileriye taşınabilir. Ancak, büyük veri ve yüksek hesaplama gücü gereksinimi gibi bazı zorlukların aşılması için veri toplama, etiketleme ve model eğitimi gibi işlemler için gereken altyapı maliyetlerinin azaltılması önemlidir.

Sonuç

Çalışmamızda, İHA görüntülerinden YOLOv8 derin öğrenme mimarileri kullanılarak kıl keçilerinin otomatik tespit ve segmentasyonu başarıyla gerçekleştirilmiştir. Özellikle YOLOv8s mimarisinin yüksek doğruluk, hızlı çıkarım ve gerçek zamanlı performansı, bu yöntemin İHA tabanlı hayvan tespiti, takibi, sayımı ve yönetim sistemleri için etkili bir çözüm olduğunu göstermektedir. Engeli ve dağlık arazi, keçi tespiti ve segmentasyonu için önemli zorluklar oluşturmaktadır. Bu bağlamda, gerçek dünya görüntülerine nesne tespiti için başarılı bir şekilde entegre edilebilen modellerin belirlenmesi oldukça önemlidir. Dolayısıyla, keçilerin farklı pozisyonlarda, boyutlarda ve aydınlatma koşullarında görünebileceği bu karmaşık ortamlarda en uygun derin öğrenme modelinin seçilmesi kritik bir öneme sahiptir. Ayrıca, modellerin genelleme performansını artırmak için farklı aydınlatma düzeylerinde ve arka plan koşullarında elde edilen görüntüler üzerinde

test edilmesi önemlidir. Gelecekte, daha büyük ve çeşitli veri setleri ile farklı ırklar ve türler üzerinde yapılan çalışmalar, bu yöntemin hayvancılıkta uygulanabilirlik alanlarını genişletebilir. Bu, modelin çeşitli senaryo ve koşullara ne kadar iyi adapte olduğunun daha kapsamlı bir şekilde değerlendirilmesine olanak sağlayacaktır.

Teşekkür

Yazar, Van İli'nin Gevaş ilçesine bağlı Altınca Köyü'ndeki kıl keçisi yetiştiricilerine, keçi sürülerinden görüntü alınması konusunda yardımlarından dolayı şükranlarını sunar.

Kaynaklar

- Akyuzlu, M., Ozmen, N. E., Saygili, A., & Cihan, P. (2023). Identification and Recognition of Animals from Biometric Markers Using Computer Vision Approaches: A Review. *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*. <https://doi.org/10.9775/kvfd.2023.30265>
- Alanezi, M. A., Shahriar, M. S., Hasan, M. B., Ahmed, S., Sha'aban, Y. A., & Bouckekara, H. R. E. H. (2022). Livestock Management With Unmanned Aerial Vehicles: A Review. *IEEE Access*, 10, 45001-45028. <https://doi.org/10.1109/access.2022.3168295>
- Barbedo, J. G. A., Koenigkan, L. V., Santos, P. M., & Ribeiro, A. R. B. (2020). Counting Cattle in UAV Images—Dealing with Clustered Animals and Animal/Background Contrast Changes. *Sensors*, 20(7), 2126. <https://www.mdpi.com/1424-8220/20/7/2126>
- Barbedo, J. G. A., Koenigkan, L. V., Santos, T. T., & Santos, P. M. (2019). A Study on the Detection of Cattle in UAV Images Using Deep Learning. *Sensors (Basel)*, 19(24). <https://doi.org/10.3390/s19245436>
- Beyaz, A., & Gül, V. (2023). YOLOv4 and Tiny YOLOv4 Based Forage Crop Detection with an Artificial Intelligence Board. *Brazilian Archives of Biology and Technology*, 66. <https://doi.org/10.1590/1678-4324-2023220803>
- Billah, M., Wang, X., Yu, J., & Jiang, Y. (2022). Real-time goat face recognition using convolutional neural network. *Computers and Electronics in Agriculture*, 194, 106730. <https://doi.org/10.1016/j.compag.2022.106730>
- Borges Oliveira, D. A., Ribeiro Pereira, L. G., Bresolin, T., Pontes Ferreira, R. E., & Rebouças Dorea, J. R. (2021). A review of deep learning algorithms for computer vision systems in livestock. *Livestock Science*, 253, 104700. <https://doi.org/10.1016/j.livsci.2021.104700>
- Brown, D. J., Savage, D. B., Hinch, G. N., & Hatcher, S. (2015). Monitoring liveweight in sheep is a valuable management strategy: a review of available technologies. *Animal Production Science*, 55(4), 427. <https://doi.org/10.1071/an13274>
- Campbell, D. L. M., Lea, J. M., Keshavarzi, H., & Lee, C. (2019). Virtual Fencing Is Comparable to Electric Tape Fencing for Cattle Behavior and Welfare. *Front Vet Sci*, 6, 445. <https://doi.org/10.3389/fvets.2019.00445>
- Cheng, M., Yuan, H., Wang, Q., Cai, Z., Liu, Y., & Zhang, Y. (2022). Application of deep learning in sheep behaviors recognition and influence analysis of training data characteristics on the recognition effect. *Computers and Electronics in Agriculture*, 198, 107010. <https://doi.org/10.1016/j.compag.2022.107010>
- Çakmakçı, C., Magalhaes, D. R., Pacor, V. R., Almeida, D. H. S. D., Çakmakçı, Y., Dalga, S., Szabo, C., Maria, G. A., & Titto, C. G. (2023). Discovering the hidden personality of lambs: Harnessing the power of Deep Convolutional Neural Networks (DCNNs) to predict temperament from facial images. *Applied Animal Behaviour Science*, 267, 106060. <https://doi.org/10.1016/j.applanim.2023.106060>

- Çakmakçı, C., Turan, M., Çakmakçı, Y., Assis Ferraz, P., Bülbüller, F., Dalga, S., Olcar, B., & Şireli, H. D. (2023). Akıllı Hayvancılık Teknolojileri: Yapay Zekâ Destekli Hayvan İzleme Çözümleri. In A. F. DEMİREL, O. YILMAZ, & Ö. ORUNÇ KILINÇ (Eds.), *Uygulamalı Bilimlerde Güncel Çalışmalar -I* (pp. 23-35). İKSAD. <https://doi.org/https://dx.doi.org/10.5281/zenodo.10413426>
- Daszkiewicz, T. (2022). Food Production in the Context of Global Developmental Challenges. *Agriculture*, 12(6), 832. <https://www.mdpi.com/2077-0472/12/6/832>
- de Lima Weber, F., de Moraes Weber, V. A., de Moraes, P. H., Matsubara, E. T., Paiva, D. M. B., de Nadai Bonin Gomes, M., de Oliveira, L. O. F., de Medeiros, S. R., & Cagnin, M. I. (2023). Counting cattle in UAV images using convolutional neural network. *Remote Sensing Applications: Society and Environment*, 29, 100900. <https://doi.org/10.1016/j.rsase.2022.100900>
- Evangelista, I. R. S., Concepcion, R., Palconit, M. G. B., Bandala, A. A., & Dadios, E. P. (2022). YOLOv7 and DeepSORT for Intelligent Quail Behavioral Activities Monitoring. 1-5. <https://doi.org/10.1109/hnicem57413.2022.10109608>
- Fuentes, A., Yoon, S., Park, J., & Park, D. S. (2020). Deep learning-based hierarchical cattle behavior recognition with spatio-temporal information. *Computers and Electronics in Agriculture*, 177, 105627. <https://doi.org/10.1016/j.compag.2020.105627>
- Gezici, M., Ünay, E., Üstün, K., & Coşkun, M. İ. (2023). Hayvancılık İşletmelerinde Teknoloji Kullanımı ve Ekonomik Verimlilik. *Ziraat Mühendisliği*(377), 26-32. <https://doi.org/10.33724/zm.1281613>
- Glenn, J., Ayush, C., & Jing, Q. (2023). Ultralytics YOLOv8. <https://github.com/ultralytics/ultralytics>.
- Guo, Y., Yu, Z., Hou, Z., Zhang, W., & Qi, G. (2023). Sheep face image dataset and DT-YOLOv5s for sheep breed recognition. *Computers and Electronics in Agriculture*, 211, 108027. <https://doi.org/10.1016/j.compag.2023.108027>
- Halachmi, I. (2015). *Precision livestock farming applications*. Wageningen Academic Publisher <https://doi.org/10.3920/978-90-8686-815-5>
- Halachmi, I., Guarino, M., Bewley, J., & Pastell, M. (2019). Smart Animal Agriculture: Application of Real-Time Sensors to Improve Animal Well-Being and Production. *Annu Rev Anim Biosci*, 7, 403-425. <https://doi.org/10.1146/annurev-animal-020518-114851>
- Henchion, M., Hayes, M., Mullen, A. M., Fenelon, M., & Tiwari, B. (2017). Future Protein Supply and Demand: Strategies and Factors Influencing a Sustainable Equilibrium. *Foods*, 6(7), 53. <https://www.mdpi.com/2304-8158/6/7/53>
- Jiang, B., Song, H., Wang, H., & Li, C. (2022). Dairy cow lameness detection using a back curvature feature. *Computers and Electronics in Agriculture*, 194, 106729. <https://doi.org/10.1016/j.compag.2022.106729>
- Jiang, B., Wu, Q., Yin, X., Wu, D., Song, H., & He, D. (2019). FLYOLOv3 deep learning for key parts of dairy cow body detection. *Computers and Electronics in Agriculture*, 166, 104982. <https://doi.org/10.1016/j.compag.2019.104982>
- Joseph, R., Santosh, D., Ross, G., & Ali, F. (2016). You Only Look Once: Unified, Real-Time Object Detection. arXiv:1506.02640. <https://doi.org/10.48550/arXiv.1506.02640>
- Kang, X., Zhang, X. D., & Liu, G. (2021). A Review: Development of Computer Vision-Based Lameness Detection for Dairy Cows and Discussion of the Practical Applications. *Sensors (Basel)*, 21(3). <https://doi.org/10.3390/s21030753>
- Kaur, J., & Singh, W. (2022). Tools, techniques, datasets and application areas for object detection in an image: a review. *Multimed Tools Appl*, 81(27), 38297-38351. <https://doi.org/10.1007/s11042-022-13153-y>
- Kumar, S., & Singh, S. K. (2019). Cattle Recognition: A New Frontier in Visual Animal Biometrics Research. *Proceedings of the National Academy of Sciences, India Section A: Physical Sciences*, 90(4), 689-708. <https://doi.org/10.1007/s40010-019-00610-x>
- Lencioni, G. C., de Sousa, R. V., de Souza Sardinha, E. J., Correa, R. R., & Zanella, A. J. (2021). Pain assessment in horses using automatic facial expression recognition through deep learning-based modeling. *PLoS One*, 16(10), e0258672. <https://doi.org/10.1371/journal.pone.0258672>
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014, 2014/). Microsoft COCO: Common Objects in Context. Computer Vision – ECCV 2014, Cham.
- Moradeyo, O. M., Olaniyan, A. S., Ojoawo, A. O., Olawale, J. A., & Bello, R. W. (2023). YOLOv7 Applied to Livestock Image Detection and Segmentation Tasks in Cattle Grazing Behavior, Monitor and Intrusions. *Journal of Applied Sciences and Environmental Management*, 27(5), 953-958. <https://doi.org/10.4314/jasem.v27i5.10>
- Morrone, S., Dimauro, C., Gambella, F., & Cappai, M. G. (2022). Industry 4.0 and Precision Livestock Farming (PLF): An up to Date Overview across Animal Productions. *Sensors (Basel)*, 22(12). <https://doi.org/10.3390/s22124319>
- Mücher, C. A., Los, S., Franke, G. J., & Kamphuis, C. (2022). Detection, identification and posture recognition of cattle with satellites, aerial photography and UAVs using deep learning techniques. *International Journal of Remote Sensing*, 43(7), 2377-2392. <https://doi.org/10.1080/01431161.2022.2051634>
- Neethirajan, S., Reimert, I., & Kemp, B. (2021). Measuring Farm Animal Emotions-Sensor-Based Approaches. *Sensors (Basel)*, 21(2). <https://doi.org/10.3390/s21020553>
- OECD, Food, & Nations, A. O. o. t. U. (2022). *OECD-FAO Agricultural Outlook 2022-2031*. <https://doi.org/doi:https://doi.org/10.1787/flb0b29c-en>
- Okinda, C., Nyalala, I., Korohou, T., Okinda, C., Wang, J., Achieng, T., Wamalwa, P., Mang, T., & Shen, M. (2020). A review on computer vision systems in monitoring of poultry: A welfare perspective. *Artificial Intelligence in Agriculture*, 4, 184-208. <https://doi.org/10.1016/j.aiaa.2020.09.002>
- Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359. <https://doi.org/10.1109/TKDE.2009.191>
- Porto, J. V. d. A., Rezende, F. P. C., Astolfi, G., Weber, V. A. d. M., Pache, M. C. B., & Pistori, H. (2021). Automatic counting of cattle with Faster R-CNN on UAV images. 1-6. <https://doi.org/10.5753/wvc.2021.18880>
- Qiao, Y., Guo, Y., & He, D. (2023). Cattle body detection based on YOLOv5-ASFF for precision livestock farming. *Computers and Electronics in Agriculture*, 204, 107579. <https://doi.org/10.1016/j.compag.2022.107579>
- Ravi, N., & El-Sharkawy, M. (2022). Real-Time Embedded Implementation of Improved Object Detector for Resource-Constrained Devices. *Journal of Low Power Electronics and Applications*, 12(2), 21. <https://www.mdpi.com/2079-9268/12/2/21>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. arXiv:1506.02640v5. <https://doi.org/https://doi.org/10.48550/arXiv.1506.02640>
- Sarwar, F., Griffin, A., Rehman, S. U., & Pasang, T. (2021). Detecting sheep in UAV images. *Computers and Electronics in Agriculture*, 187, 106219. <https://doi.org/10.1016/j.compag.2021.106219>
- Sellier, N., Guettier, E., & Staub, C. (2014). A Review of Methods to Measure Animal Body Temperature in Precision Farming. *American Journal of Agricultural Science and Technology*. <https://doi.org/10.7726/ajast.2014.1008>

- Shu, H., Li, Y., Fang, T., Xing, M., Sun, F., Chen, X., Bindelle, J., Wang, W., & Guo, L. (2022). Evaluation of the Best Region for Measuring Eye Temperature in Dairy Cows Exposed to Heat Stress. *Front Vet Sci*, 9, 857777. <https://doi.org/10.3389/fvets.2022.857777>
- Song, S., Liu, T., Wang, H., Hasi, B., Yuan, C., Gao, F., & Shi, H. (2022). Using Pruning-Based YOLOv3 Deep Learning Algorithm for Accurate Detection of Sheep Face. *Animals (Basel)*, 12(11). <https://doi.org/10.3390/ani12111465>
- Song, X., Bokkers, E. A. M., van der Tol, P. P. J., Groot Koerkamp, P. W. G., & van Mourik, S. (2018). Automated body weight prediction of dairy cows using 3-dimensional vision. *J Dairy Sci*, 101(5), 4448-4459. <https://doi.org/10.3168/jds.2017-13094>
- van Dijk, M., Morley, T., Rau, M. L., & Saghai, Y. (2021). A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. *Nature Food*, 2(7), 494-501. <https://doi.org/10.1038/s43016-021-00322-9>
- Wada, K. (2018). Labelme: Image Polygonal Annotation with Python. <https://github.com/labelmeai/labelme>.
- Wu, X., Sahoo, D., & Hoi, S. C. H. (2020). Recent advances in deep learning for object detection. *Neurocomputing*, 396, 39-64. <https://doi.org/10.1016/j.neucom.2020.01.085>
- Xu, B. B., Wang, W. S., Falzon, G., Kwan, P., Guo, L. F., Sun, Z. G., & Li, C. L. (2020). Livestock classification and counting in quadcopter aerial images using Mask R-CNN. *International Journal of Remote Sensing*, 41(21), 8121-8142. <https://doi.org/10.1080/01431161.2020.1734245>
- Yu, Z., Liu, Y., Yu, S., Wang, R., Song, Z., Yan, Y., Li, F., Wang, Z., & Tian, F. (2022). Automatic Detection Method of Dairy Cow Feeding Behaviour Based on YOLO Improved Model and Edge Computing. *Sensors (Basel)*, 22(9). <https://doi.org/10.3390/s22093271>
- Zhang, F., Wang, S., Cui, X., Wang, X., Cao, W., Yu, H., Fu, S., & Pan, X. (2022). Goat-Face Recognition in Natural Environments Using the Improved YOLOv4 Algorithm. *Agriculture*, 12(10), 1668. <https://doi.org/10.3390/agriculture12101668>