

Tarım ve Hayvancılık Alanında Dijital Dönüşüm: Evrişimsel Sinir Ağları ve Regresyon Modelleri Kullanılarak Sığırlarda Canlı Ağırlık Tahmini

Mustafa Zahid GÜRBÜZ^{1*}, Oğuzhan KIVRAK², Ayşe Berna ALTINEL GİRGIN³, Ali DEĞİRMENCİOĞLU⁴

¹Doğuş Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul Türkiye

²Bandırma Onyedi Eylül Üniversitesi, Bilgisayar Programcılığı Pr., 10200, Balıkesir Türkiye

³Marmara Üniversitesi, Teknoloji Fakültesi., Bilgisayar Mühendisliği Bölümü, 34854, İstanbul Türkiye

⁴Bandırma Onyedi Eylül Üniversitesi, Laborant ve Veteriner Sağlık Pr., 10200, Balıkesir Türkiye

Article Info

Research article
Received: 01/09/2024
Revision: 03/12/2024
Accepted: 19/02/2025

Keywords

Cattle Weight Estimation
Cattle Breed Detection
Object Segmentation
Deep Learning
Digital transformation in
Livestock farming
Precision Livestock
farming

Graphical/Tabular Abstract (Grafik Özet)

Bu çalışma, sığırların ağırlığını temassız şekilde yan profilden çekilen bir fotoğraf vasıtasıyla birden fazla ırk göz önüne alınarak, görüntü işleme ve makine öğrenmesi teknikleri kullanılarak yüksek doğrulukla tahmin eden bir model sunar. /This study presents a model that estimates the weight of cattle with high accuracy using a non-contact, side profile photograph, considering multiple breeds, using image processing and machine learning techniques.




Figure A: Live weight estimation in cattle using image processing and machine learning techniques / **Şekil A:** Görüntü işleme ve makine öğrenmesi teknikleri kullanılarak sığırlarda canlı ağırlık tahmini

Makale Bilgisi

Araştırma makalesi
Başvuru: 01/09/2024
Düzeltilme: 03/12/2024
Kabul: 19/02/2025

Anahtar Kelimeler

Sığır Ağırlık Tahmini
Büyükbaş İrk Tespiti
Nesne Segmentasyonu
Derin Öğrenme
Hayvancılıkta Dijital
Dönüşüm
Hassas Tarım ve
Hayvancılık

Highlights (Önemli noktalar)

- Mobil cihaz üzerinden temassız, stressiz ve gerçek zamanlı tahmin modeli oluşturulmuştur. / A contactless, stress-free and real-time prediction model has been created via mobile device.
- Vücut segmentasyonuna dayalı, çoklu ırk bazında yüksek doğruluk elde edilmiştir. / High accuracy has been achieved on a multi-breed basis based on body segmentation.
- Hassas tarım ve hayvancılık alanında dijital dönüşüme katkı sağlamaktadır. / Contributes to digital transformation in the field of precision agriculture and animal husbandry.

Aim (Amaç): This study aims to estimate the live weight and breed of cattle using a contactless method based on body segmentation from side-view images captured via mobile devices. /Bu çalışma, mobil cihazlarla yandan çekilen görüntülerden vücut segmentasyonuna dayalı olarak sığırların canlı ağırlık ve ırkını temassız şekilde tahmin etmeyi amaçlamaktadır.

Originality (Özgünlük): Unlike previous studies, this research uses a single side-view image and covers multiple cattle breeds. It also prioritizes mobile usability instead of fixed camera systems. / Bu çalışma, tek yandan görüntüyle ve birden fazla sığır ırkı üzerinde yapılmış ilk uygulamadır. Sabit kamera yerine mobil kullanıma odaklanılmıştır.

Results (Bulgular): The system achieved 96% accuracy in weight prediction using Mask-RCNN for segmentation and linear regression. The results highlight the importance of body segmentation. /Mask-RCNN ve doğrusal regresyon ile %96 ağırlık tahmin doğruluğu elde edilmiştir. Sonuçlar, vücut segmentasyonunun tahmin sürecindeki önemini ortaya koymaktadır.

Conclusion (Sonuç): The study contributes to the digital transformation of precision agriculture by using a user-friendly, real-time mobile application in livestock management. / Çalışma, hayvancılıkta kullanıcı dostu, gerçek zamanlı mobil uygulama kullanarak hassas tarımın dijital dönüşümüne katkı sağlamaktadır.



Tarım ve Hayvancılık Alanında Dijital Dönüşüm: Evrişimsel Sinir Ağları ve Regresyon Modelleri Kullanılarak Sığırlarda Canlı Ağırlık Tahmini

Mustafa Zahid GÜRBÜZ^{1*} , Oğuzhan KIVRAK² , Ayşe Berna ALTINEL GİRGIN³ , Ali DEĞİRMENCİOĞLU⁴

¹Doğuş Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul Türkiye

²Bandırma Onyedil Eylül Üniversitesi, Bilgisayar Programcılığı Pr., 10200, Balıkesir Türkiye

³Marmara Üniversitesi, Teknoloji Fakültesi., Bilgisayar Mühendisliği Bölümü, 34854, İstanbul Türkiye

⁴Bandırma Onyedil Eylül Üniversitesi, Laborant ve Veteriner Sağlık Pr., 10200, Balıkesir Türkiye

Article Info

Research article
Received: 01/09/2024
Revision: 03/12/2024
Accepted: 19/02/2025

Keywords

Cattle Weight Estimation
Cattle Breed Detection
Object Segmentation
Deep Learning
Digital transformation in
Livestock farming
Precision Livestock
farming

Öz

Sığırlarda ağırlık ölçüm yöntemlerinden biri olan kantar kullanımı, hayvanların strese girmesine ve yaralanmaların meydana gelmesine neden olmaktadır. Bu çalışma, hayvana temas etmeden görüntü alınarak ve sığırların vücut bölümlerine dayalı bir model kullanarak canlı ağırlığının tahmin edilmesini sağlayan bir yöntem önerilmiştir. Önerilen yaklaşımda veri toplamak üzere anlaşmalı çiftlikte geliştirilen mobil uygulama vasıtasıyla görüntüler alınmış ve gerçek ağırlık değerleri kayıt altına alınmıştır. Görüntüler labelme etiketleme aracıyla etiketlenmiş, PyTorch'un detectron2 kütüphanesinde faster Bölge-tabanlı Evrişimsel Sinir Ağları (Eng. transl.: Region-based Convolutional Neural Networks (R-CNN)) algoritması çalıştırılmıştır. Doğrusal regresyon modeli ile ağırlık tahmini Ortalama mutlak yüzde hatası (Eng. transl.: Mean absolute percentage error (MAPE)) ölçeğine göre %96 oranında, Ortalama karesel hata (Eng. transl.: Mean squared error (MSE)) ölçeğine göre ise %94 oranında başarılı olmuştur. Literatürde bu konudaki çalışmalarda genelde tek bir cins üzerine ya da cins belirtilmeden yapılan uygulamalarla karşılaşılmaktadır. Bu çalışma birden fazla ırk üzerinde hayvanın ağırlığını tahmin etmeye çalışan ilk çalışmadır. Veri kümesi çalışma kapsamında teker teker görüntü çekimleri ile oluşturuldu. Yine bildiğimiz ve literatürden görebildiğimiz kadarıyla bu çalışma, aynı hayvan için yandan çekilmiş sadece tek bir görüntü kullanılarak ve vücut parçalarının görüntü üzerinde kapladığı alandan yola çıkarak yapılmış ilk çalışmadır. Gerek yurt içinde gerekse de yurt dışında, özellikle de pandemi sürecinden sonra tarım ve hayvancılığın dijital dönüşüm sürecinin hızlandığı günümüzde, bu çalışmada raporlanan sonuçların bu alanda çalışan diğer araştırmacılar için ve tarım ve hayvancılık sektörü için oldukça anlamlı olduğu değerlendirilebilir.

Digital Transformation in Agriculture and Livestock: Live Weight Estimation in Cattle Using Convolutional Neural Networks and Regression Models

Makale Bilgisi

Araştırma makalesi
Başvuru: 01/09/2024
Düzeltilme: 03/12/2024
Kabul: 19/02/2025

Anahtar Kelimeler

Sığır Ağırlık Tahmini
Büyükbaş Irk Tespiti
Nesne Segmentasyonu
Derin Öğrenme
Hayvancılıkta Dijital
Dönüşüm
Hassas Tarım ve
Hayvancılık

Abstract

The use of scales, one of the methods of measuring weight in cattle, causes stress in the animals and causes injuries. In this study, a method is proposed to estimate the live weight of cattle by taking images without touching the animal and using a model based on body parts. In the proposed approach, images were taken and actual weight values were recorded through the mobile application developed on the contracted farm to collect data. Images were tagged with the labelme tagging tool, and the faster r-cnn algorithm was run in the detectron2 library. Weight prediction with the linear regression model was 96% successful according to the Mean absolute percentage error (MAPE) scale and 94% successful according to the Mean squared error (MSE) scale. In the literature, studies on this subject are generally conducted on a single breed or without specifying the breed. This study is the first to attempt to estimate the weight of an animal on more than one breed. The dataset was created by taking images one by one within the scope of the study. Again, as far as we know and can see from the literature, this study is the first study to use only a single image taken from the side of the same animal and based on the area covered by the body parts on the image. It can be evaluated that the results reported in this study are quite meaningful for other researchers working in this field and for the agriculture and livestock sector, especially in today's world where the digital transformation process of agriculture and livestock has accelerated after the pandemic process, both in Turkey and abroad.

1. GİRİŞ (INTRODUCTION)

Hayvancılık, insanoğlunun köklü ekonomik faaliyetlerinden biri olup günümüzde artan dünya nüfusuyla birlikte protein ihtiyacının karşılanması, sanayiye hammadde temini ve istihdam alanlarının oluşturulması gibi kritik işlevleri üstlenmektedir. Sığırların performans takibi, sağlık durumu takibi, beslenme düzeni ve rasyon ayarlama ve etin kalitesi için ağırlık ölçümü elzemdir. Ayrıca, hayvan refahı günümüz işletmelerinin temel standartlarından birini oluştururken tüketicilerin de yakından takip ettiği bir konu haline gelmiştir.

Ağırlık, sığırların genel sağlık durumu, büyüme hızı ve et kalitesi üzerinde belirgin bir etkiye sahiptir. Canlı ağırlık, hayvanların beslenme ve genetik performansının değerli bir göstergesidir ve bu nedenle hayvanların belirli dönemlerde ağırlığının ölçülmesi, besicilere besleme etkinliği ve verimliliği hakkında önemli bilgiler sunar [1-2].

Artan dünya nüfusunun beslenme ihtiyaçlarını karşılamak amacıyla et ve süt ürünleri talebinin artışı, sığır yetiştiriciliği işletmelerinin küresel ölçekte hızla büyümesine yol açmıştır. Bu genişleme ile birlikte hayvancılık endüstrisinin büyümesi, hayvan refahına verilen önemi daha da vurgulamıştır. İnsanlar, hayvanlarla kurdukları ilişkiler ve hayvanların bakımına verdikleri özenle hayvan refahını iyileştirme sorumluluğunu üstlenmektedirler. Günümüzdeki üretim ölçeğinde, geleneksel izleme yöntemlerinin yetersiz kaldığı görüldüğünden, izleme ve takip için yeni dijital teknolojilerin benimsenmesine yönelik bir farkındalık artmaktadır [3]. Ancak, her besi işletmesinin güncel teknolojiye erişimi olmayabilir.

Dijital dönüşümün etkisiyle besi çiftliklerinde canlı ağırlıklarının izlenmesi ve takip edilmesi önemli bir konu haline gelmiştir. Hayvanların canlı ağırlıkları farklı dönemlerde ölçülerek, besi performansının ve yem değerlendirmesinin karlılık açısından nasıl etkilendiği besicilere fikir vermektedir [1]. Sığırların düzenli olarak ağırlığının izlenmesi, diyet düzenlemeleri, sağlık sorunları ve genetik seçim gibi faktörlere zamanında müdahale imkanı sunar. Bu aynı zamanda hayvanların en uygun zamanlarda pazarlanması için kesim ağırlığına ulaşmalarının belirlenmesine de yardımcı olur. Çünkü kesim ağırlığına ulaşan hayvanlar, besi işletmeleri için ekstra maliyet oluşturabilir. Bu nedenle, düzenli periyodik ağırlık ölçümlerinin yapılması önemlidir

[4]. Bu bağlamda, ağırlık ölçümünün belirli aralıklarla gerçekleştirilmesi gereklidir.

Her besi işletmesinde kantar bulunmayabilir ve özellikle büyük ölçekli çiftliklerde ölçüm işlemleri sırasında hayvanların strese girebileceği ve bu durumun ölçüm hatalarına neden olabileceği belirtilmiştir [5]. Bu durumda, geleneksel yöntemler olarak mezura veya ölçü bastonu kullanarak hayvanların vücut ölçülerinin belirlenmesi ve bu ölçülerin canlı ağırlıkla ilişkilendirilmesi, besicilere hayvanın ağırlığı hakkında önemli bilgiler sağlar [6]. Yapılan araştırmalar, sığırların otomatik olarak alınan morfolojik ölçümlerinin canlı ağırlıklarını tahmin etme yeteneğine sahip olduğunu doğrulamaktadır [7-9]. Bu bağlamda, hayvanın farklı yönlerinden mümkün olduğunca çok sayıda ölçüm alarak ve bu verilere dayanarak bir regresyon modeli oluşturmak, biyometrik ölçümler ve ağırlık arasındaki ilişkinin daha detaylı bir analizini sağlar [10].

Hayvancılık alanında, hayvanlarla ilgili problemlerin çözümünde görüntülerin özelliklerinin çıkarılması konusunda zengin bir literatür bulunmaktadır. Nasirahmadi vd. [11], sığırlar ve domuzlar gibi hayvanların davranışlarına ilişkin bilgisayarlı görü uygulamaları üzerine bir inceleme yapmışlardır. Ayrıca, Wurtz vd. [12], hayvan görüntülerini otomatik algılama temelli üretim ve refah çalışmalarında kullanımını ele alan bir literatür taraması yapmışlar ve 108 yayının hedeflerini ve metodolojilerini belgelemişlerdir. Qiao vd. [13] ile Xu vd. [14], derin öğrenme teknolojilerini kullanarak çiftlik hayvanlarının otomatik segmentasyonu üzerine çalışmalar gerçekleştirmişlerdir.

Ağırlık tahmini konusunda ise, Jun vd. [15], domuzların ağırlığını belirlemek amacıyla eğrilik özelliklerinin kullanılmasını önermişlerdir. Bercovich vd. [16], sağrı bölgesinin analizi ve vücut şeklinin imzasıyla hayvan sınıflandırması yaparken, Spoliansky vd. [17] ise 3 boyutlu görüntülerden vücut koşullarını belirlemişlerdir. Song vd. [18], 3D görüntülerde otomatik olarak ölçülen morfolojik özelliklerin sığır ağırlığı tahminindeki hata payını doğrulamışlardır. Cozler vd. [19], emziren Holştayn ineklerinin vücut ağırlığını tahmin etmek amacıyla beş farklı regresyon modeli geliştirmişlerdir.

Üç boyutlu görüntülerle yapılan hayvan kütlesi tahmini çalışmaları olumlu sonuçlar göstermiş olsa da [19-21], çalışmalar hayvanların dorsal alanının 2

boyutlu görüntülerinin ağırlıkları ile daha güçlü bir korelasyon taşıdığını göstermiştir [10].

Bu çalışmada, büyükbaş hayvanların yan perspektifinden alınmış görüntüleri kullanarak bilgisayarlı görü teknikleri ile otomatik ölçümler yapıldı ve regresyon algoritmaları aracılığıyla bu ölçümlere dayalı olarak hayvanların ağırlıkları tahmin edildi. Çalışmanın literatüre katkısı şöyledir:

- Literatürdeki araştırmalarımıza göre; bu çalışma, hayvana temas etmeden görüntü alınarak ve sığırların vücut bölümlerine dayalı makine öğrenmesi yaklaşımlarını kullanarak birden fazla ırk üzerinde hayvanın ağırlığını tahmin etmeye çalışan ilk çalışmadır. Yapılan çalışmaların genellikle tek bir hayvan ırkı üzerinde yoğunlaştığı görülmektedir. Bu çalışma özellikle ülkemiz gibi ırk çeşitliliğinin fazla olduğu lokasyonlar için oldukça değerli analizler barındırmaktadır.
- Gerçek hayata ait veri kümesini oluşturmak için Bandırma Çiftliği'ne gidilip yoğun mesai ve emek harcanarak hayvanların teker teker görüntü çekimleri gerçekleştirildi.
- Yine bildiğimiz ve literatürden görebildiğimiz kadarıyla bu çalışma, aynı hayvan için yandan çekilmiş sadece tek bir görüntü kullanılarak ve vücut parçalarının görüntü üzerinde kapladığı alandan yola çıkarak yapılmış ilk çalışmadır.
- Ayrıca yine literatürdeki araştırmalarımıza göre, hayvanların vücut parçalarının tespiti için detectron2 kütüphanesinin kullanılarak istatistik analizlerin ve tahminlerin yapıldığı ilk ve tek çalışmadır.

Bu makalenin geri kalanı şu şekilde organize edilmiştir: İkinci bölümde çalışma kapsamında kullanılan veri kümesinin nasıl oluşturulduğu ve veri kümesi üzerinde uygulanan görüntü işleme ve makine öğrenmesi teknikleri anlatılmaktadır. Üçüncü bölümde , çalışma kapsamında alınan deney sonuçları ve bunlarla ilgili tartışmalara; sonuç bölümünde ise sonuç ve gelecek çalışmalar bulunmaktadır.

2. MATERYAL VE METOD (MATERIAL AND METHOD)

Bu çalışmada, canlı hayvanların görüntülerinin işlenmesi ve analiz edilmesi aşamasında YOLO (You Only Look Once) tabanlı bir derin öğrenme modeli olan Mask-RCNN algoritması ve hayvanların ağırlıklarının tahmin edilmesi

aşamasında ise 5 farklı makine öğrenmesi algoritması kullanılmaktadır. Veri seti, sahada toplanan, kesime gitmeden önce tartılan sığırların görüntülerinden oluşmaktadır ve bu bakımından çalışmanın sonuçları gerçek dünya senaryolarına uygun bir şekilde test edilmiş ve tahminleme algoritmalarının performansları karşılaştırılmıştır. Deneyler, farklı tahminleme algoritmalarının canlı hayvan ağırlığının tespiti için etkili olup olmadığını belirlemek için tasarlanmıştır. Bu bölümde, kullanılan veri seti, deney tasarımı ve kullanılan makine öğrenmesi algoritmaları ayrıntılı olarak açıklanmaktadır.

2.1. Veri Toplama (Data Collection)

Veri toplama, görüntü işleme uygulamalarının temelini oluşturur ve bu sürecin niteliği, algoritmanın performansına önemli ölçüde etki etmektedir. Elde edilen veriler, 2022 yılında Türkiye'nin Balıkesir şehrinde bulunan büyük ölçekli bir besi çiftliğinde kaydedilmiştir. Çiftlikte yaklaşık 2000 adet sığır arasından farklı ırklardan toplamda 500 adet sığırın görüntüleri toplanmıştır. Bu görüntüler, mobil cihaz kamerası ile 1920 × 1080 piksel çözünürlüğünde çekilmiştir. Kabul kriteri olarak sadece yan cepheden alınmış görüntüler seçilmiş ve uygunsuz olanlar elemine edilerek toplamda 210 adet sığır görüntüsü elde edilmiştir.

Bu çalışmanın amacına uygun, kaliteli ve standart veri toplamak amacıyla Dart programlama dili kullanılarak iki ayrı Android tabanlı mobil uygulama geliştirilmiştir. Birinci uygulama, kamera modunda çalışırken diğer uygulama ise veri toplayan cihazın uzaktan kontrolünü sağlamak amacıyla ara yüz olarak kullanılmıştır.

Birinci uygulamanın kamera modunda çalışan amacı, belirli bir mesafeden ve yükseklikten gelen komutlar aracılığıyla sığırların seri bir şekilde 10 adet görüntüsünü çekmek ve her bir görüntü üzerine meta verileri kaydetmektir. Aynı zamanda elde edilen görüntüleri meta verileriyle birlikte sunucuya yedeklemek de sorumluluğundadır. İkinci uygulama ise kumanda modunda çalışır ve tartılan sığırların küpe numarası, cinsiyeti, ağırlığı gibi bilgilerin girilmesinden sorumludur. Bu uygulama ayrıca kamera modundaki uygulamaya komut göndererek tartım sırasında sığırın kantardan çıkması esnasında görüntü alınmasını sağlar.

Bu çalışmanın veri toplama süreci, Balıkesir'in Susurluk ilçesinde faaliyet gösteren bir besi çiftliğinde gerçekleştirilmiştir. Kantardan çıkan sığırların çevresel etkilerini göz önünde

bulundurarak, kamera modunda çalışan telefon yerden 80 cm yükseklikte ve tartım alanına yaklaşık 250 cm mesafede konumlandırılmıştır. Çekim öncesi, görüntü çözünürlüğü 1920x1080 olarak

belirlenmiştir. Elde edilen meta verilerin bir örneği Tablo 1'de sunulmuştur. Bu çalışmanın metodolojisi, yüksek kaliteli veri toplama ve bu verilerin analizi üzerine odaklanmıştır.

Tablo 1. Örnek veri kümesi (Sample dataset)

Cins/Irk	Padok No	Küpe No	Cinsiyet	Canlı Ağırlık (kg)
Limuzin / #001	3B-4	0211	Düve	627
Limuzin / #002	3B-4	0436	Düve	678
Limuzin / #003	3B-4	8987	Dana	720
Limuzin / #004	3B-4	0236	Düve	611
Limuzin / #005	3B-4	4117	Dana	744
Holstein / #001	3B-2	2618	Dana	714
Holstein / #002	3B-2	5447	Düve	605
Holstein / #003	3B-2	2599	Dana	696
Holstein / #004	3B-2	9276	Dana	668
Holstein / #005	3B-2	9285	Düve	635

Veri toplama süreci, farklı sığır cinslerine ait (Holstein, Simental, Sarole, Limuzin, Montofon ve RedAngus) ineklerin görüntülerinin alınmasıyla gerçekleştirilmiştir. Ancak, belirli kalite ve standart uygunluğu gereksinimleri göz önüne alındığında, toplanan görüntülerin bazıları manuel olarak veri setinden çıkarılmıştır. Görüntülerin çıkarılma nedenleri arasında, ineğin tam vücudunun görünmediği, yan görünümün eksik olduğu, düşük görüntü netliği ve çekim sırasında hayvanın hareket etmesi nedeniyle görüntünün bulanık olduğu durumlar bulunmaktadır.

Tablo 2. Veri kümesindeki ırk dağılımı (Breed distribution of the dataset)

Limuzin	Holstein	Montofon	RedAngus	Şarole	Simental
76	60	11	6	25	32

Toplamda 210 adet görüntü kullanılarak oluşturulan veri setinde farklı kategorilerde kabul edilen ve reddedilen görsel örnekler mevcuttur. Tablo 2'de görüntülerin kategori bazındaki dağılımları gösterilmektedir. Kabul edilen örnekler, araştırmanın hedefleri doğrultusunda yeterli kalite ve içerik kriterlerini sağlayan görüntüleri içermektedir. Öte yandan, reddedilen örnekler

çekilen görüntülerdeki ineklerin tüm vücudu, yan görünümü veya görüntü netliği gibi gereksinimleri taşımadığı durumları yansıtmaktadır. Kabul edilen ve reddedilen örnekler, Şekil 1'de görsel olarak sunulmuştur. Bu dikkatli veri seçimi ve ayıklama işlemi, elde edilen veri setinin kalitesini ve güvenilirliğini artırmayı amaçlamaktadır.



Şekil 1. Kabul / ret edilen görüntülerden örnekler (Examples of accepted / rejected images)

Çalışmamız kapsamında geliştirilmiş olan her iki mobil uygulamanın temel hedefi projenin geliştirilmesi aşamasında verinin daha hızlı, sağlıklı ve gerçekçi biçimde toplanmasıdır. Bununla beraber projemiz kapsamında; son kullanıcının kullanmasını planladığımız gerçek zamanlı olarak

müşteriye, alınan görüntünün doğruluk oranı hakkında geri-besleme verebilecek kabiliyette bir mobil uygulamanın geliştirilmesi ve test çalışmaları büyük bir motivasyon ve titizlikle ile devam etmektedir.

2.2. Görüntü İşleme (Image Processing)

Derin öğrenme yöntemleri, bilgisayarlı görü, nesne tanıma, nesne sınıflandırma gibi bir çok yapay zeka uygulamasında yaygın olarak kullanılmaktadır [22]. Evrişimli sinir ağları, birçok evrişim, dense, dropout gibi katmanlardan veriyi geçirerek özellik çıkartmaya yarayan bir derin öğrenme yöntemidir [23]. İleri beslemeli bir mimariye sahip olan bu ağlar, tam ilişkili katmanlarla oluşturulan yapay sinir ağlarına kıyasla daha iyi özellik belirleme yeteneğine sahiptir [24,25]. Günümüzde nesne algılama alanında en etkili ve yaygın olarak

kullanılan yöntemlerden biri Evrişimli Sinir Ağları'dır [26].


Evrişimli sinir ağları eğitim aşamasında ağın karmaşık ve veri setinin büyük olması gibi işlemci gücünü zorlayıcı etmenler nedeni ile merkezi işlem birimi (cpu) yerine genellikle grafik işlemci birimi (gpu) kullanılır [27]. Görüntü işleme aşamasında ana hedef, öncelikle hayvanın görüntü üzerindeki konumunu belirlemektir. Bu amaçla, poligon seçim tekniği kullanılarak etiketleme aşamasında Şekil 2'de görüldüğü gibi sığırın vücut hatları genel olarak belirlenmiştir.



Şekil 2. Sığır çevresi etiketleme işlemi (Cattle girth labeling process)

Genel hatları belirlenen sığırın vücut parçaları 7 segmente ayrılmıştır. Bu segmentler baş bölgesi, sağ ön bacak, sağ arka bacak, sol ön bacak, sol arka

bacak, gövde ve kuyruktur. Bu segmentler etiketleme yapılırken belirli renklerle temsil edilmiştir (Şekil 3).



Şekil 3. Sığır vücut segmentasyonlarına göre etiketleme işlemi (Cattle body segmentations labeling process)

Elde edilen etiketli görüntüleri kaydederken dosya ismi olarak hayvanın metadata bilgisi "[hayvanNo]_[ırkı]_[dana|duve]_ağırlık_[sol|sağ]_[000].jpg" formatında kaydedilmiştir.

hayvanNo, her hayvan için benzersiz bir kimlik numarasıdır ve sıralı bir numara ya da kulak küpe numarası yazılabilir. *ırkı*, hayvanın ırk bilgisidir. *dana|duve*, hayvanın cinsiyetidir. *ağırlık*, hayvanın canlı ağırlığıdır. *sol|sağ*, hayvanın kafasının bakış yönüdür. 000: aynı hayvanın birden fazla görüntüsü var ise her birinin benzersiz sıra numarasıdır.

Oluşturulan metadatalar, Mask-RCNN algoritması ile işlenmiş ve nesne tespit işlemi gerçekleştirilmiştir. Mask-RCNN, bir nesne tanıma algoritmasıdır ve He vd. [28] tarafından 2018 yılında geliştirilmiştir. Bu algoritma sayesinde her bir görüntüdeki, hayvanın varlığı, varsa konumu ve segmentleri belirlenmiştir. Elde edilen bu veriler piksel yoğunlukları hesaplanarak makine öğrenmesinde girdi olarak kullanılmıştır. *Mask-RCNN* algoritması çalışmamızda mevcut varsayılan parametre değerleri ile kullanıldı, herhangi bir değişiklik yapılmadı. Deney ortamında kullanılan modelin adı "*mask_rcnn_R_50_FPN_3x.yaml*"


olarak ifade edilmektedir. Deney ortamında kullanılan parametre değerleri Şekil 4'te verilmektedir.

Çalışma kapsamındaki deney ortamında *mask_rcnn* algoritması için bazı input ve output görüntülerinden örnekler Şekil 5'te verilmektedir.

```
MODEL:
  META_ARCHITECTURE: "GeneralizedRCNN"
  BACKBONE:
    NAME: "build_resnet_fpn_backbone"
  RESNETS:
    OUT_FEATURES: ["res2", "res3", "res4", "res5"]
  FPN:
    IN_FEATURES: ["res2", "res3", "res4", "res5"]
  ANCHOR_GENERATOR:
    SIZES: [[32], [64], [128], [256], [512]] # One size for each in feature map
    ASPECT RATIOS: [[0.5, 1.0, 2.0]] # Three aspect ratios (same for all in feature maps)
  RPN:
    IN_FEATURES: ["p2", "p3", "p4", "p5", "p6"]
    PRE_NMS_TOPK_TRAIN: 2000 # Per FPN level
    PRE_NMS_TOPK_TEST: 1000 # Per FPN level
    # Detectron1 uses 2000 proposals per-batch,
    # (See "modeling/rpn/rpn_outputs.py" for details of this legacy issue)
    # which is approximately 1000 proposals per-image since the default batch size for FPN is 2.
    POST_NMS_TOPK_TRAIN: 1000
    POST_NMS_TOPK_TEST: 1000
  ROI_HEADS:
    NAME: "StandardROIHeads"
    IN_FEATURES: ["p2", "p3", "p4", "p5"]
  ROI_BOX_HEAD:
    NAME: "FastRCNNConvFCHead"
    NUM_FC: 2
    POOLER_RESOLUTION: 7
  ROI_MASK_HEAD:
    NAME: "MaskRCNNConvUpsampleHead"
    NUM_CONV: 4
    POOLER_RESOLUTION: 14
  DATASETS:
    TRAIN: ("coco_2017_train",)
    TEST: ("coco_2017_val",)
  SOLVER:
    IMS_PER_BATCH: 16
    BASE_LR: 0.02
    STEPS: (60000, 80000)
    MAX_ITER: 90000
  INPUT:
    MIN_SIZE_TRAIN: (640, 672, 704, 736, 768, 800)
  VERSION: 2
```

Şekil 4. Çalışma kapsamında kullanılan *mask_rcnn* algoritmasına ait parametre değerleri¹ (Parameter values of the *mask_rcnn* algorithm used in the study)

¹ <https://github.com/facebookresearch/detectron2/blob/main/configs/Base-RCNN-FPN.yaml>



Şekil 5. *Mask rcnn* algoritması ile deney ortamındaki input ve output görüntülerinden örnekler (Examples of input and output images from experimental setup using the *mask r-cnn* algorithm)

2.3. Makine Öğrenmesi (Machine Learning)

Görüntü işleme sonucunda elde edilen piksel yoğunluklarına karşılık gelen canlı ağırlığı içeren veri kümesi titizlikle oluşturulmuştur ve bu veri kümesi, makine öğrenmesi tekniklerinde kullanılmaktadır. Veri kümesi üzerindeki metadata bilgilerinde yer alan canlı ağırlık bilgisi, çıktısı olarak ele alınmışken görüntü işleme adımından elde edilen alanlar ve metadata bilgilerinde yer alan ırk, yön, cinsiyet bilgileri ise girdi olarak kullanılmıştır. Hazırlanan veri kümesi üzerinde "lineer regresyon", "polinomal regresyon", "destek vektör regresyonu", "karar ağacı regresyonu" ve "rassal orman regresyonu" olmak üzere toplamda beş farklı regresyon algoritması denenmiştir. Bu algoritmalar kullanılarak canlı ağırlık tahminlemesi gerçekleştirilmiştir.

Tüm algoritmalarda ortak bir yaklaşım olarak veri seti, test ve eğitim olmak üzere iki ayrı bölüme ayrılmıştır. Eğitim veri seti, modelin öğrenilmesi için kullanılan veri setidir. Test veri seti ise eğitim veri setinde geliştirilen modelin değerlendirilmesi amacıyla kullanılmıştır. Test verisinden elde edilen sonuçlar, "Ortalama Mutlak Yüzde Hata" (Mean Absolute Percentage Error) metriği ile değerlendirilmiştir. Bu metrik kullanılarak hesaplanan hata değeri, 1'den çıkartılarak algoritmanın doğruluk oranı belirlenmiştir.


Doğrusal (lineer) regresyon, iki değişken arasındaki ilişkiyi modellemek için gözlemlenen verilere dayalı olarak doğrusal bir denklem oluşturmaya çalışan istatistiksel bir yöntemdir. Bu yöntemde bir değişken bağımsız değişken olarak kabul edilirken diğer değişken bağımlı değişken olarak ele alınır. Bağımsız değişkenlere (X) adı verilirken bağımlı değişkene (Y) adı verilir. Bağımlı ve bağımsız değişken ilişkisi Denklem (1) şeklindeki doğrusal bir denklemle ifade edilir.

$$Y = aX + b \quad (1)$$

Polinomal Regresyon, doğrusal olmayan ilişkilerin incelendiği durumlarda kullanılan bir analiz yöntemidir. Polinom regresyon, istatistik alanında bağımsız değişken x ile bağımlı değişken y arasındaki ilişkinin, x'in n'inci dereceden bir polinomu olarak Denklem (2) formülü ile ifade edilir.

$$Y = a_0 + a_1x + a_2x^2 + a_3x^3 + \dots + a_nx^n \quad (2)$$

Destek Vektör Regresyonu (DVR), problem uzayının boyutundan bağımsız olarak optimizasyon yaptığı için yüksek boyutlu doğrusal olmayan problemler için daha başarılı olmaktadır [29, 39]. Diğer regresyon modelleri bir eğri uydurma üzerinde çalışırken, DVR hesaplanan eğrinin gerçek veriye yakın olması için ϵ uzaklıkta paralel iki eğri şeklinde bir çıkartım yapar (Şekil 6) ve hata değerlerini minimize eder.

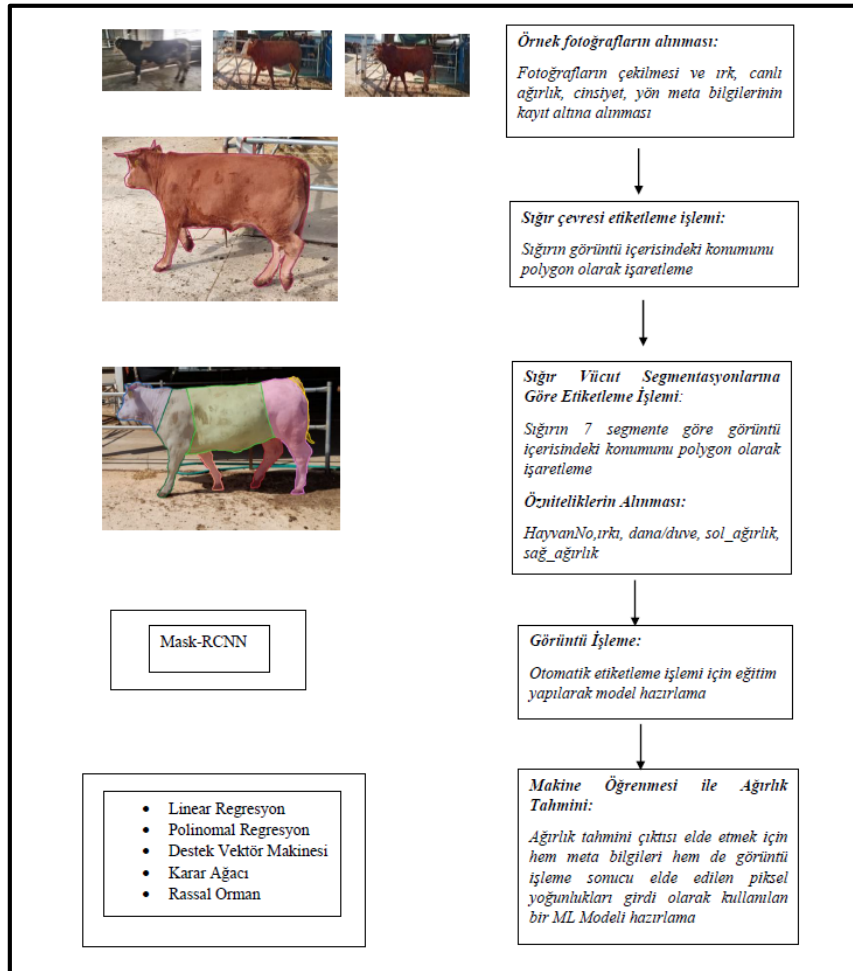


Şekil 6. Destek vektör regresyonu parametreleri (Support vector regression parameters)

Karar ağacı, regresyon veya sınıflandırma modellerini oluşturmak için ağaç yapısı şeklinde bir yaklaşım sunar. Veri kümesini giderek daha küçük alt kümelerle ayırırken ilgili bir karar ağacı aşamalı olarak geliştirilir. Bu ağaç yapısı hem kategorik hem de sayısal verileri işleme yeteneğine sahiptir [41].

Rassal ormanlar (RO), birçok bağımsız ve rastgele oluşturulmuş karar ağacının birleşimidir [40]. Genelleme hatası, ormandaki ağaç sayısı arttıkça belirli bir sınıra kadar düşer. Bu hata oranı,

ormandaki bireysel ağaçların doğruluğu (gücü) ve bu ağaçlar arasındaki tahmin benzerliği (korelasyon) ile ilişkilidir. Güçlü ve birbirinden bağımsız (düşük korelasyonlu) ağaçlar, daha düşük genelleme hatası sağlar [30]. RO algoritması, birden fazla karar ağacının çıktılarının oranlanmasıyla aşırı öğrenme ve ezberlemenin önüne geçerken, her bir ağaç için farklı veri setleri kullanarak aykırı veri sorununu da minimuma indirir [31]. Çalışmanın akış diyagramı Şekil 7’de gösterilmektedir.



Şekil 7. Akış diyagramı (Flowchart)

3. BULGULAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Yapılan çalışmalar, güçlü ekran kartı özelliklerine sahip görüntü işleme sunucusunda

gerçekleştirilmiştir. Ayrıca veri toplama için de mobil cihaz kullanılmış olup, cihazlara ait bilgiler Tablo 3'te yer almaktadır

Tablo 3. Deney için kullanılan donanım özellikleri (Hardware specifications used for the experiment)

İşlemci	Ekran Kartı	Ram	Sabit Disk
Görüntü İşleme Sunucusu (MAGNETAR CONN Workstation)			
Ubuntu 18.04 Desktop Edition			
INTEL CORE i9 10900X 4.50GHz, 10 Çekirdek	2 Adet Nvidia RTX 3090 24GB 384Bit	16GB 3000MHz DDR4	512GB NVMe
Mobil Cihaz (Xaomi redmi note 7)			
Android			
SnapDragon 660, 2.20 GHz, 8 Çekirdek	-	4 GB	64 GB

Çalışma için 210 adet görüntüden oluşan bir veri seti kullanılmıştır. Verilerde herhangi bir veri artırma tekniği kullanılmamıştır. Eldeki veri kümesi uygulanacak tüm algoritmalar için %80'i eğitim kümesi, %20'si ise test kümesi için kullanılmıştır. Makine öğrenmesinde 5 farklı algoritma çalıştırılarak elde edilen sonuçlar tablo olarak paylaşılmıştır.

Tüm algoritmalar 10 farklı kez koşturularak test edilmiş ve en iyi sonuçlar ortalama hesaplanarak "yüzde doğruluk oranı" olarak Tablo 4'te sunulmuştur. Doğruluk oranları hesaplanırken, öncelikle Mean Absolute Percentage Error değeri hesaplanmış ve elde edilen bu değer 1'den çıkartılarak doğruluk oranı hesaplanmıştır. Bu deneyler sonucunda elde edilen sonuçların en küçük, en büyük, ortalama ve standart sapma değerleri Tablo 4'te verilmiştir.

Çalışmamızın sonuçlarını analiz etmek için hem MAPE hem de MSE değerleri hesaplanmıştır. MAPE modelin ürettiği tahmin değerleri ile gerçek değerler arasındaki mutlak yüzde farklarının ortalamasını hesaplar. Bu nedenle, bu metrik ortalama hatayı gerçek değer yüzdesi olarak ifade etmektedir. MSE ise orijinal ve tahmin edilen değerler arasındaki karesel farkların ortalamasını temsil eder. MAPE ve MSE denklemleri sırasıyla Denklem (3) ve Denklem (4)'te verilmiştir [42].

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

n yapılan ölçüm sayısını, y_i gerçek değeri ve $\hat{y}_i$ ise modelin ürettiği tahmin değerini temsil etmektedir.

Tablo 4 üzerinde raporlanan deney sonuçlarına göre, sığırlar üzerindeki en başarılı ağırlık tahmini %96 başarı yüzdesi ile doğrusal regresyon algoritması ile alındı. Doğrusal regresyon algoritmasını, %93 başarı oranı ile destek vektör makinesi ve rassal orman algoritması, %90 başarı oranı ile karar ağacı algoritması ve %47 başarı oranı ile polinomal regresyon algoritması izlemektedir. Doğrusal regresyondna daha yüksek dereceli olan polinomal regresyon modellerinin bağımsız değişkenlerden ötürü bazı tahminleme modellerinde doğrusal regresyone kıyasla başarısız olabileceklerine yönelik literatürde bazı analizler bulunmaktadır [36-38]. Regresyon modellerinden özellikle doğrusal regresyon algoritmasının tahmin sistemleri üzerindeki başarısı bilinmektedir. Sınıflandırma için oldukça iyi sonuçlar alınabilen destek vektör makineleri algoritmasının regresyon versiyonu olan destek vektör regresyon algoritmasının literatürdeki başka tarımsal çalışmalarda da [29, 31-32] kullanıldığı ve iyi sonuçlar alındığı görülmektedir. Destek vektör regresyonu uyguladığımızda, destek vektör algoritmasındaki gibi çizeceğimiz aralığın en küçük hata oranı ile maksimum noktayı içerisine alması hedeflenmektedir [29]. Sığırların ağırlıklarını tahmin ettiğimiz çalışmamızda, karar ağaçları algoritmasının literatürdeki pekçok tahminleme çalışmalarında [34-35] iyi sonuçlar verdiği gibi burada da iyi sonuçlar vermesini, bu algoritmanın çalıştığı veri kümesi üzerinde özellik ve hedefe göre karar vermeye çalışan karakteristik yapısından kaynaklandığını yorumlayabiliriz. Yine, rassal orman algoritması da oluşturduğu çok sayıda ağaç yapısından çıkan sonuçlardan en iyi sonuçları oylama yaparak bulmaya çalıştığından dolayı tahminleme modellerinde [30-31] yüksek başarı verdiği gözlenmektedir. Özetlemek gerekirse Tablo 4'te sunulan deney sonuçlarına göre görüntü işleme

algoritmalarından Mask-RCNN algoritması ve makine öğrenmesi algoritmalarından doğrusal regresyon modeli ile %96'lık bir tahmin başarısı

elde edilmiştir. Makine öğrenmesi algoritmalarının başarı yüzdeleri Tablo 5'te gösterilmektedir.

Tablo 4. Makine öğrenmesi algoritmalarının en küçük, en büyük, ortalama ve standart sapma değerleri (Minimum, maximum, mean, and standard deviation values of the machine learning algorithms)

Makine Öğrenmesi Algoritması	En Küçük	En Büyük	Ortalama Değer	Standart Sapma
Gerçek Değer				
Canlı Ağırlık	537	696	634,421	50,816
Tahmini Değer				
Doğrusal Regresyon	544	712	626,816	45,760
Polinomal Regresyon	-50	1285	523,010	376,905
Destek Vektör Regresyonu	626	632	628,867	1,851
Karar Ağacı	565	696	660,895	48,156
Rassal Orman	563	676	638,563	31,419

Tablo 5. Makine öğrenmesi algoritmalarının başarı yüzdeleri (Performance accuracy percentages of the machine learning algorithms)

Doğrusal Regresyon	Polinomal Regresyon	Destek Vektör Regresyonu	Karar Ağacı	Rassal Orman
%96	%47	%93	%90	%93

Aynı veri kümesi üzerinde Tablo 4'te sıralanan algoritmalarla ilaveten XGBRegressor ve GradientBoostingRegressor algoritmalarını da çalıştırdık ve MAPE ölçeğine göre sırasıyla %91.77 ve %93.86 oranında, MSE ölçeğine göre sırasıyla %90.95 ve %92.86 oranında başarılı olduklarını gözlemledik.

Çalışma kapsamında özellikle veri toplama aşamasında bazı kısıtlar ve varsayımlar bulunmaktadır. Bu çalışma boyunca hayvanlardan alınan tüm görüntülerin çekimleri, 3 mt uzaklıktan ve 1,5 mt yükseklikten ve yan profilden yani hayvan sağa ya da sola gider iken yapıldı. Modelin eğitimleri "Limuzin, Holstein, Montofon, RedAngus, Şarole ve Simental" isimli 6 ırk için yapıldı. Başka ırklar için model eğitimlerinin yenilenmesi de yine oluşturduğumuzun tasarımın kısıtları arasındadır.

4. SONUÇLAR (CONCLUSIONS)

Hayvanların ağırlık ve ırklarını belirlemek için çeşitli yöntemler mevcuttur. Bu çalışmada, sığırların vücut segmentasyonuna göre deneyler yapıldı ve elde edilen sonuçlar, sığırların ırkı ve ağırlığı değerlendirilirken vücut segmentasyonunun önemli bir rol oynadığını göstermektedir. Ancak, bu sistemin pratik uygulamasında, kamera konumu, arka plan aydınlatması gibi çiftlik koşullarının dikkate alınması gerekmektedir.

Sığırların vücut ağırlığı ölçümü; izleme, verimlilik, hastalık tespiti ve özellikle kesime gönderilecek sığırların hedef alındığı bir süreçtir. Bu çalışma, otomatik bir şekilde ağırlık ve ırk tahminleme sisteminin temelini atmaktadır. Her ne kadar sabit bir noktaya kamera koymak ve görüntüleri o şekilde toplamak güneş ışınları ve aydınlatma koşulları açısından daha verimli gibi görünse bu çalışmanın amacı kullanıcıların sahip olduğu mobil cihaz üzerinden bu işlemleri yapabilmektir. Bu amaçla Görüntü işleme algoritmalarından Mask-RCNN algoritması ve makine öğrenmesi algoritmalarından doğrusal regresyon modeli ile %96'lık bir tahmin başarısı elde edilmiştir.

Gelecek çalışmalara öneri olarak, veri seti genişletilerek ağırlığı daha az ve fazla olan hayvanların da eğitim setine eklenmesi ve deneylerin tekrarlanması tavsiye edilir. Ayrıca daha farklı ırkların da verileri toplanarak deneyler yapılabilir. Her ne kadar son teknoloji algoritmalar kullanılmış olsa da diğer algoritmaların da test edilip sonuçları karşılaştırılabilir.

Bu alanda yeni teknolojilerin ve metodolojilerin kullanılması hayvancılık sektörü için büyük bir potansiyele sahiptir. Tarım ve hayvancılığın dijital dönüşüm sürecine ayak uydurabilmesi için başlatılmış bir çalışmanın bir ürünüdür.

Yeni hayvan ırkları için model eğitimlerimizin yapılması ve modelimizin yeni hayvan ırklarına adaptasyonunun hızlı olması planladığımız gelecek

çalışmalarımız arasındadır. Ayrıca son kullanıcının kullanmasını planladığımız gerçek zamanlı olarak müşteriye, alınan görüntünün doğruluk oranı

hakkında geri-besleme verebilecek kabiliyette bir mobil uygulamanın hayata geçirilmesi de yine hedeflerimizin arasındadır

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışma 7220768 no'lu proje ile TÜBİTAK tarafından desteklenmiştir. Ayrıca desteklerinden ötürü Doğu Üniversitesi ve OGZA Teknoloji Anonim Şirketine teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

The authors of this article declare that the materials and methods they use in their work do not require ethical committee approval and/or legal-specific permission.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Yazarlar eşit oranda katkı sağlamıştır.

The authors contributed equally.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

There is no conflict of interest in this study.

KAYNAKLAR (REFERENCES)

- [1] Koç, A., & Akman, N. (2003). Farklı Ağırlıkta Besiye Alınan İthal Edilmiş Siyah-Alaca Tosunların Besi Gücü Ve Karkas Özellikleri. *Hayvansal Üretim*, 44(1), 26-36.
- [2] Kumlu, S. (2000). Damızlık Ve Kasaplık Sığır Yetiştirme. Ankara: Türkiye Damızlık Sığır Yetiştiricileri Merkez Birliği Yayınları. Yayın No: 3.
- [3] Demir, C., & Aydın, A. (2021). Büyükbaş Hayvancılıkta Görüntü İşleme İle Sağlık Ve Refah Tespiti. *Lapseki Meslek Yüksekokulu Uygulamalı Araştırmalar Dergisi*, 2(4), 1-15. <https://Dergipark.Org.Tr/En/Pub/Ljar/Issue/67817/1015944>
- [4] Gjergji, M., Weber, V. A. M., Silva, L. O. C., Gomes, R. C., Araújo, T. L. A. C., Pistori, H., & Alvarez, M. (2020). Deep Learning Techniques For Beef Cattle Body Weight Prediction. In *Ieee Computational Intelligence Society, 2020 International Joint Conference On Neural Networks* (Ijcnnc 2020). Glasgow, Scotland, United Kingdom, 1–11.
- [5] Zehender, G., Cordella, L. P., Chianese, A., Ferrara, L., Del Pozzo, A., Barbera, S., Tonielli, R. (1996). Image Analysis In Morphological Animal Evaluation: A Group For The Development Of New Techniques In Zoometry. *Animal Genetic Resources/Resources Génétiques Animales/Recursos Genéticos Animales*, 20, 71-79.
- [6] Akman, N. (1998). *Pratik Sığır Yetiştiriciliği*. Ankara: Türkiye Ziraat Mühendisleri Birliği Vakfı Yayını.
- [7] Heinrichs, A. J., Rogers, G., & Cooper, J. (1992). Predicting Body Weight And Wither Height In Holstein Heifers Using Body Measurements. *J. Dairy Sci.*, 75, 3576–3581.
- [8] Pena, H. C., Machado, F. S., Campos, M. M., Tomich, T. R., Pereira, L. G. R., & Jayme, C. G. (2015). Predição Do Peso Vivo A Partir De Medidas Corporais Em Animais Girolando. In *Embrapa Gado De Leite-Resumo Em Anais De Congresso (Alice)*, 15.
- [9] Reis, G. L., Albuquerque, F. H. M. A. R., Valente, B. D., Martins, G. A., Teodoro, R. L., Ferreira, M. B. D., ... Madalena, F. E. (2008). Predição Do Peso Vivo A Partir De Medidas Corporais Em Animais Mestiços Holandês/Gir.
- [10] Weber, V. A. M., Weber, F. De L., Oliveira, A. Da S., Astolfi, G., Menezes, G. V., Porto, J. V. De A., Pistori, H. (2020). Cattle Weight Estimation Using Active Contour Models And Regression Trees Bagging.
- [11] Nasirahmadi, A., Edwards, S. A., & Sturm, B. (2017). Implementation Of Machine Vision For Detecting Behaviour Of Cattle And Pigs. *Livestock Sci.*
- [12] Wurtz, K., Camerlink, I., D'eath, R. B., Fernandez, A. P., Norton, T., Steibel, J., & Siegford, J. (2019). Recording Behaviour Of Indoor-Housed Farm Animals Automatically Using Machine Vision Technology: A Systematic Review.
- [13] Qiao, Y., Truman, M., & Sukkarieh, S. (2019). Cattle Segmentation And Contour Extraction Based On Mask R-Cnn For Precision Livestock Farming. *Comput. Electron. Agric.*

- [14] Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., & Schneider, D. (2020). Automated Cattle Counting Using Mask R-Cnn In Quadcopter Vision System. *Comput. Electron.*
- [15] Jun, K., Kim, S. J., & Ji, H. W. (2018). Estimating Pig Weights From Images Without Constraint On Posture And Illumination. *Comput. Electron.*
- [16] Bercovich, A., Edan, Y., Alchanatis, V., Moallem, U., Parmet, Y., Honig, H., ... Halachmi, I. (2013). Development Of An Automatic Cow Body Condition Scoring Using Body Shape Signature And Fourier Descriptors.
- [17] Spoliansky, R., Edan, Y., Parmet, Y., & Halachmi, I. (2016). Development Of Automatic Body Condition Scoring Using A Low-Cost 3-Dimensional Kinect Camera.
- [18] Song, X., Bokkers, E., Van Der Tol, P., Koerkamp, P. G., Van Mourik, S. (2018). Automated Body Weight Prediction Of Dairy Cows Using 3-Dimensional Vision.
- [19] Cozler, Y. L., Allain, C., Xavier, C., Depuille, L., Caillot, A., Delouard, J., ... Faverdin, P. (2019). Volume And Surface Area Of Holstein Dairy Cows Calculated From Complete 3d Shapes Acquired Using A High-Precision Scanning System: Interest For Body Weight Estimation. *Comput. Electron.*
- [20] Nir, O., Parmet, Y., Werner, D., Adin, G., & Halachmi, I. (2018). 3d Computer-Vision System For Automatically Estimating Heifer Height And Body Mass. *Biosyst.*
- [21] Cominotte, A., Fernandes, A., Dorea, J., Rosa, G., Ladeira, M., Vancleef, E., ... Neto, O. M. (2020). Automated Computer Vision System To Predict Body Weight And Average Daily Gain In Beef Cattle During Growing And Finishing Phases. <https://doi.org/10.1016/J.Livsci.2019.1039feature04>.
- [22] Gürkan, H., & Hanilçi, A. (2020). Evrişimsel Sinir Ağı Ve Qrs İmgeleri Kullanarak Ekg Tabanlı Biyometrik Tanıma Yöntemi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 26(2), 318-327.
- [23] Goodfellow, I., Bengio, Y., & Courville, A. (2015). *Deep Learning*. The Mit Press, Cambridge, Massachusetts, United States.
- [24] Indolia, S., Goswami, A. K., Mishra, S. P., & Asopa, P. (2018). Conceptual Understanding Of Convolutional Neural Network-A Deep Learning Approach. *Procedia Computer Science*, 132, 679-688.
- [25] Nebauer, C. (1998). Evaluation Of Convolutional Neural Networks For Visual Recognition. *Ieee Transactions On Neural Networks*, 9(4), 685-696. Doi: 10.1109/72.701181.
- [26] İnik, Ö., & Ülker, E. (2017). Derin Öğrenme Ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [27] Elmas, B. (2021). Türkiye'deki Kelebek Türlerinin Basamaklı Evrişimli Sinir Ağları İle Sınıflandırılması. *Konya Mühendislik Bilimleri Dergisi*, 9(3), 568-587. Doi: 10.36306/Konjes.844847
- [28] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-Cnn. In *Proceedings Of The Ieee International Conference On Computer Vision* (Pp. 2961-2969).
- [29] Drucker, H., Burges, C.J. C., Kaufman, L., Smola, A., Vapnik, V. 1997. Support vector regression machines, *Advances in Neural Information Processing Systems*, Cilt. 9, s. 155-161.
- [30] Breiman, L. (2001), Random forests. *Machine learning*, 45(1), 5-32.
- [31] Cosgun, C. (2023). İçi Beton Dolu Dairesel Kesitli Çelik Boruların Eksenel Yük Kapasitelerinin Yapay Sinir Ağları ve Rassal Orman Yöntemleri İle Tahmini. *Mühendislik Bilimleri Ve Tasarım Dergisi*, 11(2), 564-574. <https://doi.org/10.21923/jesd.1032191>
- [32] Alonso, J., Castañón, Á. R., & Bahamonde, A. (2013). Support Vector Regression to predict carcass weight in beef cattle in advance of the slaughter. *Computers and electronics in agriculture*, 91, 116-120.
- [33] Tırınk, C., Piwczyński, D., Kolenda, M., & Önder, H. (2023). Estimation of body weight based on biometric measurements by using random forest regression, support vector regression and CART algorithms. *Animals*, 13(5), 798.
- [34] Sarini, N. P., & Dharmawan, K. (2023). Estimation of bali cattle body weight based on morphological measurements by machine learning algorithms: random forest, support vector, K-Neighbors, and extra tree regression. *J Adv Zool*, 44(3), 1-9.
- [35] Grzesiak, W., Rzewucka-Wójcik, E., Zaborski, D., Szatkowska, I., Kotarska, K., & Dybus, A. (2014). Classification of daily body weight gains in beef cattle via neural

- Networks and decision trees. *Applied Engineering in Agriculture*, 30(2), 307-313.
- [36] Bakshi, A., & Prasad, A. (2021, June). Robust linear regression: Optimal rates in polynomial time. In *Proceedings of the 53rd Annual ACM SIGACT Symposium on Theory of Computing* (pp. 102-115).
- [37] Kikechi, C. B. (2020). On local polynomial regression estimators in finite populations. *Int. J. Stats. Appl. Math*, 5, 58-63.
- [38] Wei, J., Chen, T., Liu, G., & Yang, J. (2016). Higher-order multivariable polynomial regression to estimate human affective states. *Scientific reports*, 6(1), 23384.
- [39] Gök, M. (2017). Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi. *Gazi University Journal of Science Part C: Design and Technology*, 5(3), 139-148.
- [40] Toğaçar, M. (2021). Measuring the Security Effectiveness of Machine Learning Methods Used Against Cyber Attacks in Web Applications. *Gazi University Journal of Science Part C: Design and Technology*, 9(4), 608-620. <https://doi.org/10.29109/gujsc.950639>.
- [41] Taşkın, G. G. E. V. Ç. (2005). Veri madenciliğinde karar ağaçları ve bir satış analizi uygulaması. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(2), 221-239.
- [42] Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science*, 7, e623.