

**KİLİS KEÇİLERİNDE GÖRÜNTÜ İŞLEME VE MAKİNE
ÖĞRENİMİ İLE CANLI AĞIRLIK TAHMİNİ**

ABBAS ÇELİK

**NİSAN 2025
DİYARBAKIR**

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**KİLİS KEÇİLERİNDE GÖRÜNTÜ İŞLEME VE MAKİNE
ÖĞRENİMİ İLE CANLI AĞIRLIK TAHMİNİ**

ABBAS ÇELİK

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV
YÖNETMELİĞİNİN BİR PARÇASI OLARAK
ZOOTEKNİ ANA BİLİM DALINDA
YÜKSEK LİSANS TEZİ
OLARAK HAZIRLANMIŞTIR

NİSAN 2025
DİYARBAKIR

KİLİS KEÇİLERİNDE GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENİMİ İLE CANLI AĞIRLIK TAHMİNİ

Abbas ÇELİK tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Zootekni Ana Bilim Dalı'nda Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Doç. Dr. Halit Deniz ŞİRELİ
Danışman, **Zootekni Bölümü,**
Dicle Üniversitesi

Doç. Dr. Cihan ÇAKMAKÇI
İkinci Danışman, **Tarımsal Biyoteknoloji Bölümü,**
Van Yüzüncü Yıl Üniversitesi

Sınav Jürisi:

Doç. Dr. Halit Deniz ŞİRELİ (*, **)
Zootekni Bölümü, Dicle Üniversitesi

Doç. Dr. Ali Murat TATAR
Zootekni Bölümü, Dicle Üniversitesi

Doç.Dr. Ferda KARAKUŞ
Zootekni Bölümü, Van Yüzüncü Yıl Üniversitesi

ONAY

Savunma Tarihi: 02 /04 /2025

(*) Jüri Başkanı.

(**)Tez Danışmanı.

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılıyıp kaynak gösterdiğimi beyan ederim. Beyanıyla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Ad, Soyad: Abbas ÇELİK

İmza:

TEŞEKKÜR

Çalışmam süresince benden yardımlarını esirgemeyen ve bu tezin oluşumunda büyük emek ve katkılarını gördüğüm danışmanım Doç. Dr. Halit Deniz ŞİRELİ ve ikinci danışmanım Doç. Dr. Cihan ÇAKMAKÇI hocama teşekkürlerimi bir borç bilirim. Ayrıca çalışmamın hem uygulama aşamasında hem de yazım aşamasında bana yardımcı olan hocam Araş. Gör. Murat TURAN'a da teşekkürlerimi sunarım.



İÇİNDEKİLER

TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ.....	viii
SİMGELER VE KISALTMALAR LİSTESİ	ix
ÖZET.....	x
ABSTRACT.....	xi
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR.....	15
3. MATERYAL VE METOT	22
3.1 Materyal.....	22
3.2 Metot	22
3.3 Veri Hazırlama Ön İşleme ve Makine Öğrenmesi Modellerinin Eğitimi	27
4. BULGULAR VE TARTIŞMA	28
4.1 Biyometrik Özelliklerin Çıkartılması.....	28
5. SONUÇLAR VE ÖNERİLER	39
KAYNAKLAR	40
ÖZGEÇMİŞ	49

ŞEKİLLER LİSTESİ

Şekil 3.2.1 Oğlakların sırt görüntülerinden alınan örnek bir görüntü	23
Şekil 3.2.2 Oğlakların sırt görüntülerinin çıkarılması.....	24
Şekil 3.2.3 Sırt görüntülerinin etiketlenmesi işlemi ve referans ölçümler	24
Şekil 3.2.4 Elde edilen verilerden çıkarılan özellikler	26
Şekil 4.1.1 Ham veriler arasındaki korelasyon matrisleri	28
Şekil 4.1.2 Boruta algoritması ile belirlenen değişkenlerin z-skor önem dağılımları..	29
Şekil 4.1.3 Nihai veri setinde değişkenler arasındaki korelasyonlar	31
Şekil 4.1.4 Öğrenme eğrileri.....	34
Şekil 4.1.5 Değişkenlerin önem seviyeleri.....	35
Şekil 4.1.6 Gerçek canlı ağırlık değerleri ile modellerin tahmin ettiği değerler arasındaki istatistiksel farklar	37
Şekil 4.1.7 Gerçek canlı ağırlık değerleri ile modellerin tahmin ettiği değerler arasındaki korelasyon katsayıları	38

TABLÖLAR LİSTESİ

Tablo 1.1 Canlı Ağırlık Verilerinin Hayvancılıkta Kullanım Alanları.....	3
Tablo 3.2.1 Biyometrik ölçümler ile elde edilen değişkenler.....	25
Tablo 4.1.1 Boruta algoritması ile belirlenen değişkenlerin önem istatistikleri	30
Tablo 4.1.2 Değişkenlerin Merkezi Eğilim ve Dağılım Özellikleri.....	32
Tablo 4.1.3 Farklı makine öğrenmesi modellerinin farklı veri setlerinde eğitim ve test performanslarının karşılaştırması.....	32



SİMGELER VE KISALTMALAR LİSTESİ

Simge

Açıklama

kg

Kilogram

gr

Gram

Kısaltma

AR

En-boy Oranı

BX

X Başlangıç, Şeklin sınırlarının sol üst köşesindeki X koordinatı

BY

Y Başlangıç, Şeklin sınırlarının sol üst köşesindeki Y koordinatı

CA

Canlı Ağırlık

CV

Varyasyon Katsayısı

GÇ

Göğüs Çevresi

GG

Göğüs Genişliği

GD

Göğüs Derinliği

MAE

Ortalama Mutlak Hata

MAPE

Ortalama Mutlak Yüzde Hata

MARS

Çok Değişkenli Uyarlanabilir Regrasyon Eğrileri

R^2

Belirtme Katsayısı

RMSE

Kök Ortalama Kare Hata

SD

Standart Sapma

SVM

Destel Vektör Makineleri

VU

Vücut Uzunluğu

XM

X Merkezi, Şeklin X eksenindeki ağırlık merkezi

YM

Y Merkezi , Şeklin Y eksenindeki ağırlık merkezi

ÖZET

KİLİS KEÇİLERİNDE GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENİMİ İLE CANLI AĞIRLIK TAHMİNİ

ÇELİK, Abbas

Yüksek Lisans, Zootečni Bölümü

Danışman: Doç. Dr. Halit Deniz ŞİRELİ

İkinci Danışman: Doç. Dr. Cihan ÇAKMAKÇI

Nisan 2025, 60 sayfa

Bu çalışma Kilis keçisi oğlaklarında görüntü işleme ve makine öğrenimi yöntemlerini kullanarak canlı ağırlığın tahmin edilmesi amaçlanmıştır. Çalışma, Dicle Üniversitesi Ziraat Fakültesi Araştırma ve Uygulama Çiftliği Küçükbaş Biriminde 2023 Temmuz ile 2024 Mart tarihleri arasında gerçekleştirilmiştir. Çalışmada, 9 baş Kilis keçisi oğlağından elde edilen morfolojik ölçümler ile sırt görüntüleri, 10 aylık bir süre boyunca düzenli olarak kaydedilmiştir. Oğlaklar, benzer yaş aralığında olan bireyler arasından seçilmiştir. Sırt görüntüleri, saniyede 30 kare (fps) çekim yapabilen 4K çözünürlükteki GoPro cihazı ile alınmıştır. Bu görüntüler, makine öğrenmesi için kullanılacak veri setinde özellik çıkarımı amacıyla işlenmiştir. Görüntüler, Python üzerinden Labelme programı ile etiketlenmiş, ardından sırt görüntülerinin arka planları çıkarılarak ImageJ programında analiz edilmiştir. Bu analizlerle elde edilen morfolojik ölçümler kullanılarak, farklı makine öğrenmesi modellerinin (Random Forest, SVR, MARS ve XGBoost) test performansları karşılaştırılmıştır. Modellerin tahmin performansları, test verilerinde R^2 , MAE ve RMSE gibi istatistiklerle değerlendirilmiştir. Sonuçlar, XGBoost modelinin eğitim veri setinde en yüksek performansı gösterdiğini ($R^2 = 0.98$, MAE = 0.50, RMSE = 0.64), ancak test veri setinde $R^2 = 0.01$, MAE = 0.01, RMSE = 5.36 ile düşük performans sergilediğini ortaya koymuştur. Diğer modellerin performansları sırasıyla; Random Forest için $R^2 = 0.85$, MAE = 1.55, RMSE = 1.89; SVR için $R^2 = 0.51$, MAE = 2.26, RMSE = 3.19; MARS için ise $R^2 = 0.19$, MAE = 3.10, RMSE = 3.91 olarak bulunmuştur. Sonuçta, görüntü işleme ve makine öğrenmesi tekniklerinin küçükbaş hayvanların canlı ağırlıklarının tahmin edilmesinde güvenilir ve pratik bir alternatif sunduğunu göstermektedir. Bunun yanı sıra, hayvancılık sektöründe teknolojik gelişmelerin entegrasyonu ve sürü yönetiminde dijital dönüşümün gerçekleştirilmesi adına önemli bir adım teşkil etmektedir.

Anahtar Kelimeler: Kilis Keçisi, Makine Öğrenimi, Görüntü İşleme, Canlı Ağırlık tahmini

ABSTRACT

LIVE WEIGHT ESTIMATION IN KILIS GOATS USING IMAGE PROCESSING AND MACHINE LEARNING

ÇELİK, Abbas

Master of Science in Department of Animal Science

Supervisor: Assoc.Prof. Dr. Halit Deniz ŞİRELİ

Second Advisor: Assoc Prof. Dr. Cihan ÇAKMAKÇI

April 2025, 60 pages

The aim of this study is to predict the live weight of Kilis goat kids using image processing and machine learning techniques. The research was conducted at the Small Ruminant Unit of the Faculty of Agriculture, Dicle University, between July 2023 and March 2024. The study's material consisted of morphological measurements and back images obtained from 9 Kilis goat kids, which were collected regularly over a period of 10 months. The goats were selected based on similar age ranges within the Kilis breed. The back images were captured using a GoPro device with 4K resolution (3840x2160 pixels) and 30 frames per second (fps). These images were used to extract features for the dataset intended for machine learning. The images were initially labeled using the Labelme program in Python, with the labels being generated based on the references in the images. After the background removal of the back images, the resulting images were analyzed using ImageJ to obtain morphological measurements. Various machine learning models (Random Forest, SVR, MARS, and XGBoost) were employed to compare different datasets and test performance. The predicted performance of these models was evaluated based on statistics such as R^2 (Coefficient of Determination), MAE (Mean Absolute Error), and RMSE (Root Mean Squared Error) for the test data. The results indicated that the XGBoost model exhibited the best performance on the training dataset with $R^2 = 0.98$, $MAE = 0.50$, and $RMSE = 0.64$, but showed lower performance on the test dataset with $R^2 = 0.01$, $MAE = 0.01$, and $RMSE = 5.36$. The performance of the other models was as follows: Random Forest ($R^2 = 0.85$, $MAE = 1.55$, $RMSE = 1.89$), SVR ($R^2 = 0.51$, $MAE = 2.26$, $RMSE = 3.19$), and MARS ($R^2 = 0.19$, $MAE = 3.10$, $RMSE = 3.91$). This research demonstrates that image processing and machine learning techniques offer a reliable and practical alternative for predicting the live weight of small ruminants. Moreover, it represents a significant step towards the application of technological advancements in the livestock industry and the digital transformation of flock management.

Keywords: Kilis Goat, Machine Learning, Image Processing, Live Weight prediction

1. GİRİŞ

Hayvancılık sektöründe, hayvanlara ait vücut ölçülerinin belirlenmesi, tür ve ırk düzeyinde morfolojik özelliklerin tanımlanmasında, fizyolojik yapıların değerlendirilmesinde ve gelişim süreçlerinin izlenmesinde kritik bir öneme sahiptir. Bu ölçümler, hayvanların dış morfolojisi hakkında bilgi sunmanın ötesinde; bireylerin üretim performansları, hastalıklara karşı dirençleri ve çevresel koşullara adaptasyon kapasiteleri gibi biyolojik ve ekonomik parametrelerin dolaylı göstergeleri olarak da değerlendirilmektedir. Özellikle, vücut ölçüleri ile süt verimi, et kalitesi ve doğurganlık gibi özellikler arasında anlamlı ilişkiler bulunmuştur (Öztürk vd., 2018; Yılmaz ve Kaya, 2020).

Geleneksel yöntemlerle gerçekleştirilen vücut ölçümleri, zaman alıcı, iş gücü gerektiren ve hayvan üzerinde stres oluşturabilen işlemler olup, daha az invazif ve daha verimli alternatiflere duyulan ihtiyacı artırmaktadır. Bu bağlamda, görüntü işleme teknikleri ve makine öğrenimi yöntemlerinin entegrasyonu, vücut ölçülerinin hızlı, hassas ve temassız bir şekilde elde edilmesini mümkün kılmakta; bu veriler üzerinden canlı ağırlık gibi önemli parametrelerin tahmin edilmesine olanak sağlamaktadır (Günay ve Demirtaş, 2019; Arslan ve Çelik, 2021). Özellikle, derin öğrenme algoritmaları kullanılarak elde edilen görüntüler üzerinden yapılan analizler, yüksek doğruluk oranlarıyla canlı ağırlık tahmini yapabilmektedir (Kaya vd., 2022).

Farklı araştırmacılar tarafından yürütülen çalışmalarda, makine öğrenmesi algoritmaları ile görüntü işleme tekniklerinin birlikte kullanımı sayesinde hayvanlarda canlı ağırlığın, gerçeğe oldukça yakın doğrulukta tahmin edilebildiği ortaya konmuştur. Ayrıca, bu teknolojilerin sürü yönetim sistemlerine entegre edilmesi ve bilgisayar destekli yazılımlarla desteklenmesi sonucunda, zooteknik uygulamalarda verimliliğin artırıldığı; işletmelerde ise daha isabetli ve veri temelli kararlar alınabildiği bildirilmektedir. Tüm bu gelişmeler, geleneksel canlı ağırlık ölçüm yöntemlerine kıyasla daha hızlı, pratik ve temassız (non-invazif) bir alternatif sunarak hayvancılıkta teknolojik dönüşümün önemli bir parçası hâline gelmektedir (Santana vd., 2021; Çakmakçı, 2022; Canaza-Cayo vd., 2024).

Hayvancılık sektöründe kullanılan canlı ağırlık verileri, hayvanların büyüme takibinden barınma koşullarının standardizasyonuna, alan gereksinimlerinin belirlenmesinden besleme uygulamalarının optimize edilmesine kadar birçok yönetsel süreçte önemli bir rol oynadığı görülmektedir. Ayrıca, sürülerin sağlık olup olmadığının izlenmesi, pazarlama stratejilerinin planlanması ve hedef ağırlıklara ulaşımın kontrol edilmesi gibi performansa dayalı parametrelerin yönetiminde de temel bir gösterge olarak kullanılmaktadır (Kashiha vd., 2014; Çakmakçı, 2022; Canaza-Cayo vd., 2024).

Canlı ağırlık verilerinin yönetimi, hayvancılıkla ilgili çok çeşitli parametrelerin optimize edilmesinde önemli bir rol oynamaktadır. Bu veriler, hayvanların büyüme süreçlerini izlemek için kullanılarak, verimli büyüme hızlarının belirlenmesine yardımcı olabilir. Aynı zamanda barınma koşullarının standardizasyonu için temel alınabilir, çünkü her hayvanın ihtiyacı olan alan, verimli büyüme için hayati öneme sahiptir. Besleme uygulamaları da bu verilerle optimize edilebilir; örneğin, hayvanların yaşına, ırkına ve mevcut ağırlığına göre doğru yem miktarı ayarlanabilir, böylece yemden elde edilen verimlilik artırılabilir. Sürü sağlığının izlenmesi bağlamında, canlı ağırlık değişiklikleri, hastalıkların erken teşhisinde önemli bir göstergedir. Özellikle ani kilo kayıpları veya artışlar, metabolik hastalıklar ya da enfeksiyonlar gibi sorunlara işaret edebilir. Bununla birlikte, pazarlama ağırlıkları ve kesim zamanlaması da bu verilere dayalı olarak tahmin edilebilir, böylece daha isabetli pazarlama stratejileri oluşturulabilir ve işletme karlılığı artırılabilir. Sonuç olarak, canlı ağırlık bilgileri, hayvancılık işletmelerinin verimliliğini artırma ve sürdürülebilir üretim için kritik bir araç olarak tanımlana bilinir (Kashiha vd., 2014; Çakmakçı, 2022; Canaza-Cayo vd., 2024). Tablo 1.1’ de canlı ağırlık verilerinin hayvancılıkta kullanım alanları nasıl takip edildiği bildirilmiştir.

Tablo 1.1 Canlı Ağırlık Verilerinin Hayvancılıkta Kullanım Alanları

Kullanım Alanı	Açıklama	Önerilen Yöntemler
Büyüme Takibi	Hayvanların büyüme hızlarını izleyerek, optimal büyüme koşullarını sağlamak.	Haftalık/aylık ağırlık ölçümleri, gelişim grafiklerinin analizi.
Barınma Koşulları	Hayvanların ideal yaşam alanlarını belirleyerek stresin ve hastalıkların önlenmesi.	Ağırlığa göre alan hesaplamaları, barınma sıcaklık ve nem takibi.
Besleme Uygulamaları	Canlı ağırlığa göre yem tüketimi ve yem miktarının optimize edilmesi.	Makine öğrenmesi ile yem verimliliği tahmini, bireysel besleme programları.
Sürü Sağlığı Takibi	Kilo değişimlerini izleyerek, hastalıklar hakkında erken uyarı sağlanması.	Ağırlık dalgalanma analizi, biyometrik verilerle desteklenen sağlık izleme sistemleri.
Pazarlama ve Kesim Ağırlığı Tahminleri	Canlı ağırlığa göre uygun pazarlama ve kesim zamanı belirlenmesi.	Yapay zeka destekli tahmin modelleri, ağırlık hedefleri belirleme.

Canlı ağırlık verileri, hayvancılık sektöründe birçok yönetimsel parametrenin optimize edilmesinde önemli bir rol oynamaktadır. Son yıllarda yapılan çalışmalarda, bu verilerin özellikle hayvanların büyüme süreçlerini izlemek için kullanıldığı ve verimli büyüme hızlarının doğru tahmin edilebildiği ortaya konmuştur. Örneğin, Zhang vd. (2023), derin öğrenme algoritmalarını kullanmak suretiyle, büyükbaş hayvanlardaki büyüme hızını oldukça yüksek doğrulukla tahmin edebilecek bir model geliştirirken aynı şekilde, Torres vd. (2022), küçükbaş hayvanların büyüme hızlarının, görsel veriler ve makine öğrenmesi tekniklerini kullanarak başarılı bir şekilde tahmin edilebileceğini bildirmişlerdir. Bu tür teknolojilerin kullanımı, hayvanların sağlıklı ve refah içerisinde büyümelerini sağlamak için gerekli şartların tespitine yardımcı olacaktır.

Canlı ağırlık verilerinin bir diğer kullanımı da, barınma koşullarının standartlaştırılması ve alan gereksinimlerinin belirlenmesidir. Örneğin, Liu vd. (2023), farklı görüntü işleme tekniklerini kullanarak, herhangi bir türe ait tesis edilen barınaklarda, hayvanların ihtiyaçları olan yaşam alanı gereksinimlerini daha doğru bir şekilde belirleyerek barınma şartlarının iyileştirilmesinde başarılı sonuçları elde ettikleri görülmüştür. Bu teknolojilerin kullanımı ile hayvan başına alan hesaplamalarının optimize edilmesini sağlanarak, sürülerdeki yoğunluklar azaltılabilir ve hayvanların refah ve sağlıklarının izlenmesi daha kolay olması sağlana bilinir.

Bunların yanı sıra, besleme uygulamalarının optimize edilmesi ile canlı ağırlık verileri doğrudan ilişkilidir. Son yıllarda yapılan çalışmalarda, canlı ağırlık ile besleme stratejilerinin optimize edilmesi önemli bir gösterge olduğunu ortaya koyulmuştur. Örneğin, Wang vd. (2022), yapay zeka destekli besleme yönetim sistemlerinin kullanarak, canlı ağırlık ve yem tüketimini verimli bir şekilde optimize ederek yem tüketimleri ve maliyetlerini azalttığını bildirmişlerdir. Bu tür sistemler, yem tüketiminin izlenmesi ve düzenlenmesi konusunda büyük fayda sağlamaktadır.

Hayvancılık sektöründe sürü sağlığının izlenmesinde canlı ağırlık verilerinin kullanıldığı önemli alanlardan birisi olup, özellikle hayvanlardaki canlı ağırlık değişikliklerinin, potansiyel sağlık sorunlarını tespit etmek için bir gösterge olduğunu ortaya koymaktadır. Li vd. (2019), hayvanların canlı ağırlık değişimlerinin takip edilmesi ile hastalıkların daha erken dönemlerde teşhis edilmesine olanak sağladığı ve böylece sağlık yönetimini iyileştirdiğini belirtmişlerdir. Bu bağlamda, makine öğrenmesi tabanlı sağlık izleme sistemlerinin, hastalıkların önceden tespit edilmesine yardımcı olduğunu vurgulanmaktadır.

Son olarak, kesim ağırlıkları ve kesim sürelerinin belirlenmesinde de canlı ağırlık verileri çok önemli bir rol oynadığı görülmektedir. Elde edilen bu veriler, hayvanların kesim zamanı ve pazarlama stratejilerinin en uygun hale getirmek için kullanılabilir. Zhang vd. (2023) çalışmalarında, canlı ağırlıkların tahmin edilmesinde kullanılan sistemlerin, piyasa tahmin araçlarıyla entegrasyonu sonucunda karar verme mekanizmasını ve karlılığı önemli ölçüde artıracığını bildirmişlerdir. Aynı şekilde, Torres vd. (2022), ise çalışmalarında hayvanların besi sonundaki kesim zamanlarını tahmin edilmesinde, canlı ağırlık verilerini kullanarak daha doğru bir şekilde yapılabileceklerini bildirmişlerdir. Brown vd., (2015), Akçapınar ve Özbeyaz, (2020), Yıldız vd. (2021), Çakmakçı, (2022), Canaza-Cayo vd. (2024) Küçükbaş hayvan yetiştiriciliğinde, özellikle koyun ve keçi gibi türlerde düzenli olarak canlı ağırlık ölçümlerinin yapılması ve bu verilerin sistematik şekilde değerlendirilmesi, hayvanların genel verim özellikleriyle doğrudan ilişkilidir. Canlı ağırlık verileri; döl verimi, et üretimi, süt verimi, yapağı, tiftik ve kıl üretimi gibi ekonomik olarak önemli üretim parametrelerinin izlenmesinde temel bir biyometrik gösterge niteliği

taşımaktadır. Bu üretim parametrelerinin her biri, işletmelerin genel verimliliği ve ekonomik kârlılığı üzerinde belirleyici rol oynamaktadır.

Canlılarda büyüme performansının bir göstergesi olan canlı ağırlık artışı, aynı zamanda, seleksiyon programlarında da kullanılan temel kriterlerden biridir. Canlı ağırlık takibinin düzenli olarak yapılması sayesinde, erken yaşta üstün verim potansiyeline sahip bireylerin belirlenmesi ve damızlık seçiminde erken seleksiyon kriteri olarak da kullanılmasını mümkün hale gelmektedir (Notter, 2012). Ayrıca, hayvanların canlı ağırlıkları ile üreme performansları arasında önemli ilişkiler olduğunu ve yüksek canlı ağırlığa sahip olan dişilerin, çoğunlukla daha yüksek doğurganlık oranlarına sahip olduğu çeşitli çalışmalarla ortaya konmuştur (Safari vd., 2005; Mandal vd., 2015).

Bu bağlamda, küçükbaş işletmelerinde canlı ağırlık verilerinin toplanması sadece hayvan sağlığını izlemekle sınırlı kalmamakta, aynı zamanda üretim planlaması, yem rasyonlarının optimizasyonu ve ekonomik karar alma süreçlerine de önemli katkılar sunmaktadır. Dolayısıyla, bu verilerin düzenli ve doğru biçimde izlenmesi, hem hayvan refahı hem de işletme verimliliği açısından kritik bir yönetim aracı olarak değerlendirilmektedir. Canlı ağırlığın izlenmesi ve tahmin edilmesine yönelik çalışmalarda, morfolojik ölçümlerin kullanımı giderek daha fazla önem kazanmakta ve bu ölçümlerin canlı ağırlıkla yüksek düzeyde korelasyon gösterdiği birçok araştırma tarafından ortaya konulmuştur. Özellikle koyunlarda (Ferra et al., 2010; Mavule et al., 2013) ve keçilerde (Dakhlan et al., 2020) gerçekleştirilen çalışmalar, bazı morfolojik ölçülerin canlı ağırlığın güvenilir tahmininde kullanılabileceğini göstermiştir. Bu ölçümler, canlı ağırlığın doğrudan tartım yoluyla belirlenemediği durumlarda özellikle kırsal alanlarda ve düşük teknolojiye sahip işletmelerde pratik ve etkili bir alternatif sunmaktadır (Menesatti vd., 2014; Gomes vd., 2016; Fernandes vd., 2019; Meghelli vd., 2020).

Dahası, bu morfometrik parametrelerin sadece küçükbaş hayvan türleriyle sınırlı kalmayıp, farklı hayvan türlerinde de benzer doğrulukla kullanılabildiği çeşitli bilimsel çalışmalarla kanıtlanmıştır. Örneğin Menesatti vd. (2014), 3 boyutlu

görüntüleme teknikniğini kullanarak morfolojik ölçümlerle sığır ve domuzlarda canlı ağırlığın yüksek doğrulukla tahmin edilebildiğini göstermiştir. Benzer şekilde Gomes vd. (2016), Fernandes vd. (2019) ve Meghelli vd. (2020) tarafından yapılan çalışmalarda, biyometrik verilerin hem canlı ağırlık tahmini hem de büyüme ve gelişme performansının izlenmesi açısından son derece güvenilir göstergeler olduğu vurgulanmıştır.

Bu bulgular, özellikle seleksiyon çalışmaları, beslemenin planlanması ve sağlık koruma yönetimi gibi konularda kullanılabilecek düşük maliyetli ve etkili yöntemler geliştirilmesi açısından büyük önem taşımaktadır. Dolayısıyla, morfolojik ölçümlere dayalı canlı ağırlık tahmini yöntemleri, modern hayvan yetiştiriciliği uygulamalarında karar destek mekanizmalarının önemli bir bileşeni haline gelmektedir.

Çiftlik hayvanlarında, morfolojik ölçümler ile vücut kondisyon puanları ve canlı ağırlıkların ilişkilendirilmesi (Chacón vd., 2011; Mekparıup vd., 2013; Olaniyi vd., 2018), sadece üreme performansı, büyüme ve gelişme ile ilişkisi yanında genetik özellikler hakkında da bilgi sunmaktadır. Bu nedenle, bu parametrelerdeki değişimlerin izlenmesi büyük önem taşımaktadır (Zhang vd., 2018; Çakmakçı, 2022).

Bununla birlikte, tahmin edici modellerin sayılarının artması, modeller arasındaki etkileşimlerin etkisinin göz önüne alınması ile tahmin etme süreci daha karmaşık hale gelmektedir. Bu noktada, makine öğrenimi yöntemleri, karmaşık veri setlerinden anlamlı içgörüler çıkarımlarda bulunulmasında konusunda ideal bir yaklaşım sunmaktadır (Valletta vd., 2017; Çakmakçı, 2022).

Makine öğrenmesi (ML), istatistiksel öğrenme kuramlarına dayanan ve elde edilen veriler üzerinden tahmin ve çıkarımlar yapılmasını sağlayan ve algoritmaların geliştirilmesine odaklanan bir yapay zekâ alt dalıdır (Morota vd., 2018). Son zamanlarda revaçta olan bu konu, hem akademik hem de uygulamalı araştırmalarda giderek artan bir ilgiyle karşılanmakta olup; özellikle büyük ve çok boyutlu veri kümelerinin analiz edilmesinde güçlü bir araç olarak değerlendirilmektedir. Makine öğrenmesi algoritmaları, sadece tahmine yönelik olmayıp, aynı zamanda sınıflandırma, kümeleme ve regresyon gibi çeşitli analitik görevlerde

kullanılabilmektedir. Özellikle regresyon analizleri yoluyla, bir bağımlı değişkenin çok sayıda bağımsız değişkene bağlı olarak modellenmesi sağlayarak, bu süreçte etkileyici faktörlerin açıklanması da analitik süreçlerin temel bileşeni haline gelmektedir (Valletta vd., 2017).

Son yıllarda yapılan kapsamlı çalışmalarda, makine öğrenimi algoritmalarını dört farklı şekilde sınıflandırmaktadır bunlar sırasıyla; denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme (Benos vd., 2021). Denetimli öğrenme (supervised learning), çoğunlukla öngörücü modelleme yapmak için kullanılır ve etiketli veriler aracılığıyla belirli bir çıktının tahmin edilmesini sağlayan algoritmalar içermektedir. Bu yaklaşım, özellikle sınıflandırma (örneğin, bir hayvanın verim grubunun belirlenmesi) ve regresyon (örneğin, canlı ağırlığının çeşitli morfometrik ölçümlere göre tahmini) gibi görevlerde yaygın olarak kullanılmaktadır (Boehmke ve Greenwell, 2019). Denetimsiz öğrenme (unsupervised learning) ise, veri kümesindeki gizli desenlerin keşfedilmesini için kullanılmaktadır ve genellikle kümeleme (clustering) tekniklerini içermektedir. Yarı denetimli öğrenme, sınırlı etiketli veriyle eğitilmiş modellerin doğruluğunu artırabilmek için denetimli ve denetimsiz yaklaşımları birlikte kullanan bir metottur. Pekiştirmeli öğrenme (reinforcement learning) ise bir ajan aracılığıyla çevresiyle etkileşime girerek optimum karar alma sürecini öğrenmeye odaklanan bir sistemdir. Bu yöntemler, biyoinformatik, tarımda hassas yetiştiricilik, genetik seleksiyon, hayvan refahının izlenmesi ve üretim verimliliğinin artırılması gibi alanlarda büyük potansiyel sunmaktadır.

Son yıllarda hayvancılık sektöründe, özellikle de küçükbaş hayvanlarda (koyun ve keçiler) canlı ağırlığı tahmin etmek için makine öğrenmesi algoritmalarının kullanımı oldukça fazla yaygınlaşmıştır. Bu algoritmalar ile elde edilen tahminleme, geleneksel regresyon yöntemlerine göre daha yüksek derecede doğruluk sağlamakta olup morfometrik ölçümler gibi kolayca elde edilebilen verilerle entegrasyonu sağlanarak maliyet etkin çözümler üretmektedir. Özellikle Random Forest (RF), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (ANN) ve Extreme Gradient Boosting (XGBoost) gibi algoritmalar, farklı çalışmalarda yüksek performans sergilemişlerdir (Tebug vd., 2019; Khan vd., 2020; Ershad vd., 2022).

Örneğin, Dakhlan vd. (2020) tarafından yerel keçi ırkları üzerinde yapılan bir çalışmada, göğüs çevresi, cidago yüksekliği ve vücut uzunluğu gibi morfometrik ölçümler kullanılarak canlı ağırlık tahmini yapılmış ve RF algoritması, geleneksel doğrusal regresyona göre daha düşük hata oranları (RMSE) ve daha yüksek belirtme katsayısı (R^2) değerleri elde etmişlerdir. Benzer şekilde, Ershad vd. (2022), XGBoost algoritmasının, küçükbaş hayvanlarda canlı ağırlık tahmini için üstün öğrenme yeteneği sergilediğini, özellikle veri seti büyüdükçe modelin genelleme kapasitesinin de arttığını bildirmişlerdir.

Makine öğrenmesi algoritmalarının en önemli avantajlarından birisi de, değişken önemi analizi yardımı ile canlı ağırlığı etkileyen en önemli morfolojik faktörün hangisi olduğunu belirlenmesini sağlamaktır. Bu durum, sadece tahmin doğruluk derecesini artırmakla kalmayıp, aynı zamanda damızlık seçimi ve besleme stratejilerinin belirlenmesinde de karar destek aracı olarak kullanılmasını da sağlamaktadır (Benos vd., 2021). Ayrıca, bazı araştırmalarda hibrit model yaklaşımları da (örneğin ANN + GA) kullanılmaktadır. Bu model parametre optimizasyonunun daha etkili hale getirildiği ve canlı ağırlık tahmininde doğruluk derecesinin daha da artırdığını bildirmişlerdir (Wang vd., 2021).

Tüm bu gelişmeler, makine öğrenmesi tekniklerinin hayvancılık alanında hem akademik araştırmalarda hem de pratik uygulamalarda çok yönlü olarak kullanılabileceğini ortaya koymakta, özellikle küçük ölçekli yetiştiricilerin de bu teknolojilere erişimini kolaylaştıracak yazılım ve mobil uygulamaların geliştirilmesine zemin hazırlamaktadır. Çalışmalarda gözetimli öğrenme yöntemini kullanmanın temel amacı, belirli sayıda giriş verisi kullanmak suretiyle sayısal bir çıktının tahmin edilmesi olarak tanımlanmaktadır. Bu tür problemlerin çözümünde, çoğunlukla regresyon analiz yöntemleri kullanılmaktadır (Boehmke ve Greenwell, 2019). Regresyon analiz yöntemi, özellikle hayvancılık sektöründe hayvanların canlı ağırlığını morfolojik özellikler temelinde tahmin etmek için yaygın olarak kullanılmaktadır. Bu bağlamda; sığırlarda (Aytekin vd., 2018), keçilerde (Dakhlan vd., 2020) ve diğer farklı türlerden elde edilen karkas kesitleri ile morfometrik ölçümler aracılığıyla (Pabiou vd., 2011; Shahinfar vd., 2019; Lee vd., 2020) canlı ağırlık tahminlerini gerçekleştirilmişlerdir. Bu çalışmalardan elde edilen sonuçlar, geleneksel

yöntemlerle kıyaslandığı zaman, gözetimli makine öğrenmesi algoritma yöntemleri daha yüksek doğruluk derecesinde bir orana ulaştığını bildirmişlerdir.

Görüntü analizi, bir nesnenin dijital ortama aktarılması ile başlayan ve belirli yazılımlar aracılığıyla bu görüntünün işlenerek ölçülebilir veri haline getirilmesini sağlayan bir süreçtir. Bu süreç, hem veri toplamada standardizasyon sağlar hem de manuel ölçümlerde ortaya çıkabilecek insan hatalarını minimize eder (Dipova, 2018). Görüntü tabanlı ölçümler, özellikle hayvanın fiziksel temas olmaksızın değerlendirilmesini mümkün kıldığı için hayvan refahı açısından da avantaj sunmaktadır.

Bununla birlikte, regresyon analizleri ve görüntü işleme tekniklerinin entegrasyonu ile canlı ağırlığın tahmin edilmesinde oldukça yüksek hassasiyet ve objektif sonuçlar elde edilmektedir. Pabiou vd. (2011) tarafından yapılan bir çalışmada, karkas görüntüsü kullanılmak suretiyle elde edilen dijital verilerin, çok değişkenli regresyon modelleri geliştirilmiş ve tahmin doğruluk derecelerinin önemli ölçüde arttığı bildirilmiştir. Benzer şekilde Shahinfar vd. (2019), üç boyutlu görüntü teknolojileri ile desteklenen makine öğrenmesi tabanlı modellerin, özellikle genç hayvanlarda canlı ağırlık tahmininde güvenilir alternatifler sunduğunu belirtmiştir. Bu bulgular, hayvancılık alanında dijitalleşmenin ve yapay zekâ destekli sistemlerin giderek daha fazla benimsenmeye başladığını göstermektedir. Özellikle düşük maliyetli ve temassız ölçüm olanakları sunan bu sistemler, hem araştırma hem de saha uygulamaları açısından oldukça büyük potansiyele sahiptir.

Hayvanlara ait canlı ağırlıklar, özellikle et üretimi açısından, hayvancılık sektöründeki üretim verimliliğini değerlendirmek için en önemli kriterlerden biridir. Canlı ağırlık, bir hayvanın genel durumunu değerlendirmek, üreme programlarında seçim kriteri olarak kullanmak, rasyonların formülasyonuna yardımcı olmak, hayvan sağlığı ve bakım kararlarını almak, besi döneminin tamamlanıp tamamlanmadığını belirlemek gibi birçok farklı amaç için kullanılmaktadır (Kunene vd., 2009; Çakmakçı, 2022).

Canlı ağırlığı tahmin edebilmek için morfolojik ölçümlerden biri olan bu parametrenin, makine öğrenimi yöntemlerinin potansiyelini doğrulamak amacıyla kullanılması, dijital görüntü işleme tekniklerinin entegrasyonu yoluyla gelecekte

otomatik canlı ağırlık tahmini için prototip yazılımların geliştirilmesine olanak tanıyabilir. Çiftlik yönetimi uygulamalarının üretim unsurları üzerindeki etkisi göz önüne alındığında, hayvancılık işletmelerinin genişlemesiyle birlikte, stres yaratan geleneksel değerlendirme yöntemleriyle her bir hayvanı sürekli ve düzenli bir şekilde yeterli şekilde değerlendirmek oldukça zordur. Dijital görüntü işleme gibi hassas hayvancılık teknolojilerinin uygulanması ve gelişmiş makine öğrenimi algoritmalarının entegrasyonu, çiftçilere destek sağlamak suretiyle hem hayvancılık üretim verimliliğini artırabilir hem de çiftçilere daha fazla boş zaman kazandırabilir (Çakmakçı, 2022).

Hayvanların görünüşü ve performansının değerlendirilmesi, büyük ölçüde vücut boyutlarının ölçülmesine dayanmaktadır. Hayvanın boyutunu yansıtan çeşitli ölçümler, hayvan seçimi ve yetiştiriciliğinde kritik faktörler olarak önemli bir rol oynamaktadır. Ayrıca, hayvanların ağırlıklarını tahmin etmek amacıyla vücut ölçüleri de kullanılabilmektedir (Sarini ve Dharmawan, 2023). Son yıllarda, bazı bilim insanları morfolojik ölçümleri kullanarak sığırların gerçek canlı ağırlıklarını belirlemek için farklı makine öğrenimi tekniklerini başarılı bir şekilde uygulamıştır (Borges Oliveira vd., 2021; Lee vd., 2020; Huma ve Iqbal, 2019; Çakmakçı, 2022).

Bu çalışmalar, makine öğrenimi algoritmalarının hayvanların canlı ağırlığı ile morfolojik özellikleri arasındaki doğrusal olmayan ilişkiyi etkili bir şekilde tahmin edebileceğini göstermiştir.

Son yıllarda, hayvancılıkta kullanılan görüntü işleme teknikleri, tüm araçlar ve yöntemler arasında, özellikle hassas hayvancılık teknolojileri (Berckmans, 2014) alanında en önemli araçlar olarak öne çıkmaktadır. Bu nedenle, uygulanan bu teknikler, morfolojik analizler için 3D teknolojisi kullanılarak (Le Cozler vd., 2019), kas kütesinin tahmini (Alsahaf vd., 2019), hayvan gruplarının tespiti için izleme sistemleri (Li vd., 2019) ve büyüme takibi amacıyla termal kameralarla canlı ağırlık kontrolü (Stajenko vd., 2008) gibi farklı hedeflere ulaşmak için kullanılmaktadır. Bu uygulamalar, görüntü işlemenin, hayvancılık sektöründeki yönetim ve kontrol süreçlerini iyileştirmeye yardımcı olan önemli bir teknik olduğunu göstermektedir.

Bu teknolojik ilerlemelerin giderek yaygınlaşmasına rağmen, tüm hayvancılık türleri için eşit bir şekilde uygulanmamıştır ve küçükbaş yetiştiriciliği, teknolojik ilerlemenin en az olduğu alanlardan biridir. Koyun ve keçi yetiştiriciliği, diğer türlere kıyasla daha sınırlı kaynaklara sahip olup, ürünlerin üretimi ve satışı açısından karlılık, sığır eti ve domuz eti gibi diğer sektörlerle karşılaştırıldığında önemli ölçüde daha düşük seviyelerdedir. Ayrıca, bu sektördeki ürün fiyatları son yıllarda diğer hayvancılık sektörlerine benzer şekilde artış göstermemiştir. Bu durum, küçükbaş işletmelerinde teknolojik uygulamaların daha geç benimsenmesine ve yeterli ilerleme kaydedilmemesine yol açmıştır. Bu sebeplerle, sektörde günlük işleri kolaylaştırmak için düşük maliyetli teknolojik çözümler gereklidir. Yeni sistemlere uyumun çiftçiler için sorun yaratmaması adına, kullanım kolaylığına sahip uygulamaların geliştirilmesi önemlidir. Bu süreçte, özellikle dikkat çeken değişkenlerden biri, canlı ağırlıkların tespitinde kullanılan tartılardır. Koyun ve keçi yetiştiriciliği de dâhil olmak üzere tüm türlerde, canlı ağırlıkların belirlenmesi, yetiştiricilerin hayvanlarının büyümesini, beslenmesini, üreme kapasitesini ve hatta kaslanma oranlarını takip etmelerine olanak tanıyan önemli bir göstergedir (Samperio vd., 2021).

Küçükbaş yetiştiriciliğinde, koyun ve keçilerin büyümesinin tüm aşamalarında canlı ağırlığın izlenmesinin, hayvanın gelişimi açısından faydalı olduğu kanıtlanmıştır (Brown vd., 2015). Et üretimi amacıyla yetiştirilen kuzularda, ağırlığın doğru bir şekilde tahmin edilmesi, yetiştiricinin ekonomik kararları üzerinde önemli bir etki yapabilir. Yetiştirici tarafından belirlenen canlı ağırlık eşiklerinin üzerinde veya altında kalan kuzular, bu eşik aralığındaki kuzulardan daha düşük ödeme değerine sahip olacaktır. Ayrıca, gebelik dönemi sırasında meydana gelen ağırlık farkları, kuzunun sonraki büyümesini etkileyebilir. Örneğin, yüksek doğum ağırlığına sahip bir kuzu, 20 kg'a kadar daha düşük doğum ağırlığına sahip bir kuzudan daha hızlı büyüme eğilimindedir (Greenwood vd., 1998). Benzer şekilde, düşük ağırlıklı bir kuzunun, laktasyon döneminde daha yüksek ağırlığa sahip bir kuzuya kıyasla yaşama şansının iki katı daha fazla olduğu bulunmuştur (Hatcher vd., 2008).

Son dönemde, görüntü analiz yöntemlerinde ve bu alandaki çalışmalarda önemli gelişmeler yaşanmıştır. Bu görsel uygulamalardan elde edilen fırsatlardan biri, tespit edilen görüntülerden ölçüm yapılabilmesidir. Nesnelerin herhangi bir temas

olmaksızın yapılan analizler, kullanılan diğer yöntemlere kıyasla daha yaygın bir şekilde tercih edilmektedir, çünkü en küçük bir temas bile ölçülecek nesnede bozulma ve değişikliklere yol açabilir. Bilgisayar destekli dijital görüntü işleme ve analiz yöntemleri, zaman kazandırıcı, doğru ve ekonomik olmasının yanı sıra, çok sayıda uygulama alanına da sahiptir (Taşdemir ve Özkan, 2018).

Bilgisayarla görüntü analizi ve çeşitli tahmin uygulamaları, farklı disiplinlerde yaygın bir şekilde kullanılmaktadır. Bunlardan biri de hayvancılık sektörüdür. Süt sığırcılığı işletmelerinin sayısı ve kapasiteleri arttıkça, bilgisayar destekli yapılan çalışmaların önemi de giderek artmakta ve bu çalışmaların kullanımı yaygınlaşmaktadır. Süt sığırcılığı işletmelerinde, hayvanların canlı ağırlıkları (CA), süt verimleri ve yem tüketimleri arasındaki ilişkiler, aynı zamanda bakım-beslenme düzeyleri ve işletmelerin mevcut şartları, bu durumun öncü faktörleri olarak kabul edilmektedir. Bu dönemlerin izlenmesi hayati bir öneme sahiptir; çünkü bu sınırların dışına çıkıldığında, ineklerin bağışıklık sistemleri ve ekonomik verimlilikleri üzerinde önemli etkiler meydana gelmektedir. Özellikle ineklerin canlı ağırlıklarındaki olumsuz değişiklikler, sağlık sorunlarına, uygun olmayan çevresel koşullara ve beslenme hatalarına yol açabilmektedir. Bu nedenle, süt ineklerinde canlı ağırlıkların (CA) izlenmesi büyük bir önem taşımaktadır (Taşdemir, 2010).

Hayvanlardan fenotipik veri elde etmek, üreme sürecinde kritik ancak zahmetli bir aşamasını oluşturur. Geleneksel olarak, hayvanın fenotipik veri değerlerini elde etmek öncelikle manuel, vücut üstü ölçüm yöntemlerini içermektedir. Bu yaklaşım yalnızca yoğun emek gerektirmez, aynı zamanda hayvanlarda strese neden olur ve bu da potansiyel ekonomik kayıplara yol açar. Günümüzde, yeni nesil Yapay Zekâ, görüntü işleme, akıllı algılama, çok modlu füzyon işleme ve robotik teknolojinin entegrasyonu hayvancılıkta giderek daha yaygın hale gelmektedir (Ma vd., 2024). Bugün kullanılan ıslah program uygulamalarının büyük çoğunluğunda dış görünüş yani hayvanların morfolojik özellikleri, çok önemli bir ölçüt olarak kullanıldığı görülmektedir (Diekmann 1991). Zehender vd. (1996) ise hayvanların dış görünüş özelliklerinin değerlendirilmesi, hayvan ıslahında kullanılan en temel kriterlerden biri, olduğunu bildirmektedirler. Dijital görüntü analiz yöntemleri gibi görüntü işleme yöntemlerinin

de kullanılması ile farklı tür ve ırklar üzerinde en az hataya sahip canlı ağırlık tahminleri yapılması gerçekleşmektedir (Tunaz, 2021).

Koyunların vücut büyüklüğü parametreleri, büyüme gelişimini, üretim performansını ve genetik özelliklerini yansıtabilir. Bu nedenle, vücut büyüklüğü ölçümü koyun yetiştiriciliğinde büyük öneme sahiptir (Zhang vd., 2018).

Makine öğrenimi modeli (MÖM) teorisi, istatistik, bilgisayar bilimi ve veri madenciliği prensiplerini birleştiren, veriler arasındaki ilişkileri öğrenmeyi ve bunlara bağlı sınıflandırma veya tahmin yapmayı amaçlayan bir yapay zekâ dalını temsil etmektedir (Palmer, vd., 2011). MÖM' leri birçok alanda sınıflandırma için kullanılmıştır. Bunların çoğu, değişkenler arasındaki doğrusal olmayan ilişkileri barındırmak, doğrusallık ve yüksek boyutlu verilerle başa çıkmak için onları daha esnek hale getirmek amacıyla doğrusal modellerin genellemeleri veya uzantılarıdır (Goldstein vd., 2017; Mullainathan ve Spiess, 2017). Bu sınıflandırma algoritmaları, süt ineklerinde östrus oluşumunun belirlenmesi (Andrade vd., 2021), hayvan otopsi raporlarında farklı patolojilerin tespiti (Bollig ve ark., 2020) ve süt sığırları ırklarının sınıflandırılması (Moawed ve Osman, 2017) gibi hayvancılık endüstrisindeki farklı görevlerde giderek daha fazla kullanılmaktadır.

Hayvanların canlı vücut boyutları ekonomik çıktının önemli bir göstergesidir. Manuel ölçüm emek yoğun ve zaman alıcıdır ve sıklıkla hayvanlarda stres tepkileri ortaya çıkarır. Bilgisayar teknolojisinin ilerlemesiyle birlikte, canlı hayvanlarda vücut ölçümlerinin elde edilme tekniklerinde önemli gelişmeler elde edilmiştir. Hayvancılık sektörü geliştikçe, canlı vücut boyut ölçüm teknolojisi giderek endüstriyellemeye ve ticarileşmeye doğru ilerlemektedir. Mevcut aşamada, bu alanda ekipman seçimi için tercih edilen özellikler istikrar, yüksek doğruluk ve düşük maliyete öncelik verme eğilimindedir. (Ma vd., 2024). Son yıllarda, bilimsel ve teknolojik ilerlemenin hızla ilerlemesiyle birlikte, bilgi teknolojisinin çeşitli endüstrilerle entegrasyonu giderek daha da derinleştirmektedir.

Hayvancılığa uygulanan bilgi teknolojisi alanında, hayvanların canlı vücut ölçüleri ölçme teknolojisi, genellikle tarama ve görüntüleme gibi yöntemler kullanarak

hayvancılık verilerini elde etmek için sensörleri kullanır. Daha sonra, hayvanların canlı vücut ölçümlerini elde etmek için bilgisayarlı işleme uygulanır (Luo vd., 2023). Bu yaklaşım genellikle invaziv değildir, hayvanlardaki stres tepkilerini azaltır ve böylece tahribatsız bir test yöntemi oluşturur (Wang vd., 2017).

Bugüne kadar araştırmacılar, domuz, sığır ve koyun gibi çeşitli evcil hayvanlarda bilgisayarlı görme algılama teknolojisini kullanarak canlı vücut ölçülerinin tespit edilmesi ile önemli ilerlemeler kaydettiler. Bu bağlamda övgüye değer sonuçlar elde edildi (Xiaodong vd., 2023). Özellikle görüntü analizi ve yorumlama alanındaki hesaplama, fotoğraflar veya videolar aracılığıyla hem süt hem de besi sığırlarının, balıkların, koyunların ve domuzların ağırlığını tahmin eden özellikleri çıkarmak için bir araç olarak kullanılmıştır (Taşdemir vd., 2011; Özkaya, 2013; Menesatti vd., 2014). Bu çalışma, Kilis keçilerinin dijital görüntülerinden elde edilen morfolojik ölçümlere dayalı olarak, farklı makine öğrenimi algoritmaları kullanılarak canlı ağırlıklarının tahmin edilmesini amaçlamaktadır.

2. ÖNCEKİ ÇALIŞMALAR

Görüntü işleme yöntemi, kullanılacak olan cisim ya da cisimlere ait renk ve yansımalarla ait ışık özellikleriyle cisim ya da cisimlerin uzunluk, genişlik ve yükseklikleri gibi geometrik karakteristiklerinin incelenerek buna bağlı bir şekilde değerlendirilebilmesini sağlayan tüm donanım ve yazılımlar kombinasyonu olarak tanımlana bilinir. Sığır, manda gibi büyükbaş hayvanların vücut ölçülerinin alınması küçükbaş hayvanlara göre oldukça zordur. Bu zorluğu oluşturan temel sebepler arasında ise ölçüm yapılırken hayvanların istenildiği gibi sabit durmaması, ürkmeleri ayrıca ölçümü yapacak kişilerden kaynaklanan hatalar ölçümlerin doğru olarak alınamamasına neden olmaktadır. Bu zorluklar nedeniyle verilerin değerlendirmesinde hata ve yanlışlar olabilmekte ve yapılan araştırmaların güvenilirliği azaltmaktadır. Bu konuda daha önce yapılan çalışmalar bu bölümde özetlenecektir

Bektaş (2016) Kırşehir ilini temsil edecek şekilde yapmış olduğu çalışmada, esmer ve esmer ırkı melez sığırlarda görüntü işleme yöntemlerini kullanarak morfolojik özelliklere göre sınıflandırmıştır. Böylece araştırmasında daha doğru bilgilere ve verilere ulaşacağını amaçlanmıştır. Bu bilgileri kullanarak da sığır ırkları arasında farklı sınıflamaları (et ve süt verim yönlü vb.) yapılabileceğini bildirmiştir.

Cebeci ve Bek (1994), almış oldukları yapağı örneklerindeki kalite kontrolü için yapmış oldukları çalışmalarında, görüntü işleme yöntemini kullanmışlar ve bu yöntemde elde ettikleri sonuçların, klasik yöntemler le elde etmiş oldukları sonuçlara göre daha avantaj sağladığı bildirmişlerdir.

Sarini ve Dharmawan, (2023) yapmış oldukları çalışmalarında, Bali sığırlarının canlı ağırlığı tahmini için modeller oluşturmak amacıyla makine öğrenimi regresyonunun kullanımını incelemişlerdir. Tepki değişkenleri, bağımlı değişken olarak canlı ağırlığı ve benzer yaşlardaki (285 gün) 228 erkek ve 211 dişi sığırlara ait vücut uzunluğu (VU), Göğüs çevresi (GÇ), but çevresi (BÇ) ve cidago yüksekliğinden (CY) oluşmaktadır. Çalışmadaki dişi Bali sığırlarının tanımlayıcı istatistikleri, morfolojik ölçümlerin diğer araştırmacılar tarafından belgelenenlere benzer olduğunu ortaya koymuştur. Sığırların canlı ağırlıklarını farklı özelliklere göre tahmin etmek için Rastgele Orman, Destek Vektörü, K-Komşular ve Ekstra Ağaç regresyonları gibi makine öğrenimi modelleri

kullanılmıştır. Bunlara ek olarak da, geleneksel yaklaşımla karşılaştırma için sığırlara ait canlı ağırlıkları tahmin etmek için doğrusal regresyon modelini kullanmışlardır. Kullanılan değerlendirme standartları, değerlendirme verimliliğinin ölçütleri olarak belirleme katsayısı (R^2), ortalama karekök hatası (MAE), ortalama mutlak hata (REMS) ve ortalama mutlak yüzde hatalarını (MAPE) içerdiğini bildirmişlerdir. Ayrıca Doğrusal Regresyonun dışı sığırlar için tüm regresyonlar arasında en iyi performansı gösterdiğini tespit etmişlerdir. Benzer şekilde erkekler için ise ekstra ağaç regresyonu ile hemen hemen aynı olup, makine öğrenim algoritmasının geleneksel algoritmayı geride bırakarak sığırların canlı ağırlıklarının daha kesin bir tahminini sağladığı bildirilmektedir.

Huma ve Iqbal (2019) Pakistan'ın Beluci koyun ırklarına ait koçlarda canlı ağırlığı modelleyerek tahmin etmek için çeşitli makine öğrenme algoritmaları kullanılmışlardır. Geleneksel genelleştirilmiş doğrusal model, regresyon ağaçları, destek vektör makinesi ve rastgele ormanlar yöntemleri, hayvanların canlı ağırlık tahminleri için modeller geliştirmek amacıyla kullanılmışlardır. Bağımsız değişken olarak 2-36 aylık 131 baş koça ait vücut (vücut uzunluğu, kalp çevresi, cidago yüksekliği) ve testis (skrotum çapı, skrotum çevresi, skrotum uzunluğu ve testis uzunluğu) ölçümlerini kullanmışlardır. Modellerin performansı için, ortalama mutlak hata, ortalama mutlak yüzde hatası, gözlenen ve benzer değerler arasındaki korelasyon, belirleme katsayısı ve kök ortalama kare hatası değerlendirme kriterlerine göre değerlendirmişlerdir. Modellerin kararlılığını kontrol etmek için bir eğitim veri kümesi üzerinde 10 katlı çapraz doğrulama yaparak geliştirilen modellerin tahmin performansını değerlendirmek için ise de ayrı bir eğitim veri kümesi kullanmışlardır. Rastgele ormanlar modelinin hem eğitim hem de test veri kümeleri için en iyi sonuçları sağladığını, makine öğrenme yöntemlerinin ise geleneksel modellere kıyasla daha iyi sonuçlar sağladığı, uygulayıcı ve araştırmacıların çiftlik hayvanlarının canlı ağırlığı için en iyi tahmin edici seçmelerine yardımcı olabileceği sonucuna varılmışlardır. Ayrıca bu çalışmada kullanılan rastgele ormanlar yönteminin eğitim ve test veri kümeleri için sırasıyla 0,988 ve 0,916 olan belirleme katsayısı değerleri, Balochi koyunlarının canlı ağırlığını modellemek için en uygun model olduğunu bildirmişlerdir.

Mohammad vd. (2012) Belucistan'a özgü bir koyun ırkının canlı ağırlığını RT (Regression trees) yöntemini kullanarak tahmin etmiş ve 0,72'lik bir belirleme katsayısı değeri bildirmiştir.

Aytekin vd. (2018) Afyon ili Bolvadin ilçesinde yetiştirilen 38 baş Holstein, 27 baş Simmental, 23 baş Brown Swiss ve 15 baş melez genç boğalar ile yapmış oldukları çalışmalarında boğaların besi sonu ağırlığını en iyi tahmin eden metodun MARS algoritmasından elde edilen 0,97' lik R² değeri olduğunu bildirmişlerdir.

Canaza-Cayo vd. (2024) makine öğrenimi algoritmaları kullanarak 100 baş Corriedale koyunlarına ait canlı ağırlıklarını tahmin ettikleri çalışmalarında 14 vücut ölçümü ve altı farklı makine öğrenimi modeli (Destek Vektör Makineleri Regresyon, Sınıflandırma ve Regresyon Ağaçları, Rastgele Orman, Model Ortalama Sinir Ağları, Çok Değişkenli Uyarlamalı Regresyon Eğrileri ve Aşırı Gradyan Artırma) kullanmışlardır. Koyunlara ait canlı ağırlık ve ölçümü yapılan vücut ölçüleri sırasıyla; cidago yüksekliği, kuyruk sokumu yüksekliği, göğüs çevresi, sırt çevresi, ön bacak uzunluğu, ön bacak genişliği, ön bacak çevresi, kuyruk genişliği, kuyruk çevresi, kalça genişliği, bel genişliği, omuz genişliği, ön bacak uzunluğu ve vücut uzunluğu, tespit etmişlerdir. Modellerin performansı belirleme katsayısı (R^2), kök ortalama kare hatası (RMSE), ortalama mutlak hata (MAE) ve ortalama mutlak yüzde hatası (MAPE) ile değerlendirmişlerdir. Sonuç olarak, yüksek oranda ilişkili öngörücüler ($r \geq 0.75$) veri setinden çıkarılmış ve kalan öngörücüler daha sonra Boruta algoritması kullanılarak değişken seçim prosedürlerine tabi tutmuşlardır. Çalışmada kullanılan RF modeli en yüksek R² değerlerine ve en düşük MAE, RMSE ve MAPE değerlerine sahip olduğunu ve sonuç olarak, RF algoritmasının Corriedale koyunlarının vücut ölçülerinden yararlanılarak canlı ağırlığı en doğru şekilde tahmin ettiğini bildirmişlerdir.

Faraz vd., (2023) 152 baş Kajli koyununa ait vücut ölçümlerinden canlı ağırlığı tahmin etmek amacıyla yapmış oldukları çalışmalarında XGBoost ve MARS algoritmalarını kullanmışlardır. Çalışmada canlı ağırlığı vücut ölçümlerinden tahmin etmek için en iyi modelin XGBoost algoritması olduğunu bildirmişlerdir.

Delialioğlu vd. (2023) Polatlı koyunlarında (Ile de France × Akkaraman G₁) canlı ağırlığını , bazı vücut ölçülerini (cidago yüksekliği, but yüksekliği, vücut uzunluğu, göğüs derinliği, göğüs genişliği, göğüs çevresi, incik kemiği çevresi), bağımsız değişken olarak kullandıkları yaş ve cinsiyeti ele almışlardır. Çalışmada CART (Sınıflandırma ve Regresyon Ağacı), CHAID (Ki-kare Otomatik Etkileşim Dedektörü) ve MARS (Çok Değişkenli Uyarlamalı Regresyon Eğrileri) 3 farklı makine öğrenimi algoritmalarını kullanarak canlı ağırlıkları tahmin etmek ve canlı ağırlık tahmininde önemli bağımsız değişkenleri belirlemişlerdir. Bu amaçla, canlı ağırlık tahmini için farklı yaşlarda 180 dişi ve 30 erkek olmak üzere toplam 210 koyun kullanılmışlardır. Hesaplanan Pearson korelasyon katsayıları CA ile CY, BY, VU, GD, GG, GÇ ve İKÇ özellikleri arasında sırasıyla; 0,89, 0,89, 0,85, 0,94, 0,55, 0,91 ve 0,79' tespit etmişlerdir ($p < 0,05$). Veri madenciliği algoritmalarının tahmin modeli olarak uygulanmasında 10'luk çapraz doğrulama kullanılırken, ağaç tabanlı algoritmalar için ana düğüm 10 ve çocuk düğüm 5 olarak ayarlanmıştır. CHAID ve CART algoritmaları canlı ağırlıklarda gözlenen değişimi açıklamak için her biri 8 bağımsız değişken kullanırken, MARS algoritması 9 bağımsız değişken kullanmışlardır. Polatlı koyunlarında en yüksek canlı ağırlığa sahip koyunlar CHAID algoritmasında yaş > 3 ve GG > 36 cm kesim noktasına sahip düğümde bulunmuştur (93,571 kg). CART algoritmasında yaş > 0, GD > 36,5 cm ve İKÇ > 9,5 cm olduğunda (91,316 kg) öngörülmüştür. Yaygın olarak kullanılan kriterler dikkate alındığında CHAID, CART ve MARS algoritmalarının öngörü performansları şu şekilde hesaplanmıştır: RMSE değerleri “5,78, 5,10, 4,00”; SDR değerleri “0,25, 0,22, 0,17”; MAPE değerleri “7,55, 6,67, 5,68”; Adj-Rsq değerleri “0,93, 0,95, 0,96”; ve AIC değerleri sırasıyla; “741.43, 688.48, 582.79” dir. Tahmin performansı açısından ağaç algoritmaları (CHAID ve CART) arasında CART en iyisi bulunurken, tüm performans ölçütleri dikkate alındığında MARS algoritmasının en iyi performansı gösterdiği görülmüştür.

Özen vd. (2024) çalışmada, 6 aylık yaştaki Akkaraman koyunlarının canlı ağırlıklarını cinsiyet, doğum ağırlığı ve cidago yüksekliği, göğüs derinliği, vücut uzunluğu, göğüs genişliği, kuyruk sokumu yüksekliği ve göğüs çevresi gibi bazı morfolojik özellikler kullanılarak tahmin etmek için Ridge, En Az Mutlak Büzülme ve Seçim Operatörü (LASSO) ve Elastik Ağ (Etkileşim) yöntemleri ve ağaç tabanlı regresyon yöntemleri olarak Sınıflandırma ve Regresyon Ağaçları (CART) ve Rastgele Orman (RF)

metotlarını kullanılmışlardır. 44 erkek ve 56 dişi toplam 100 koyuna ait veri seti, sırasıyla %80 ve %20 oranında eğitim ve test setlerine rastgele ayrılmıştır. Optimum regresyon modellerini elde etmek ve aşırı uyumu önlemek için eğitim seti kullanmışlar ve 10 katlı çapraz doğrulama yöntemi uygulanmışlardır. Sonuç olarak, canlı ağırlıkların tüm morfolojik özellikler ve vücut ağırlığı ile 0,216 ila 0,757 arasında değişen katsayılarla anlamlı bir şekilde ilişkili olduğunu ortaya koymuşlardır. RF, 0,865'lik bir belirleme katsayısı değeri ile diğer regresyon modellerini geride bırakmış, bunu Ridge ($R^2 = 0,76$), LASSO ($R^2 = 0,75$), Elastic Net ($R^2 = 0,75$) ve CART ($R^2 = 0,65$) izlemiştir. Sonuç olarak, RF'nin Akkaraman koyunlarının canlı ağırlıklarını tahmin etmek için kullanılmasını önermişlerdir.

Tırınk vd. (2023a) çalışmalarında 393 Romane koyun (238 dişi ve 155 erkek hayvan) ırkı için doğum ağırlığı, doğum tipi, cinsiyet, emzirme ağırlığı, emzirme ağırlığındaki yaş, süttten kesme ağırlığı, süttten kesme ağırlığındaki yaş ve final vücut ağırlığı yaşını kullanarak final vücut ağırlıklarını tahmin etmeyi amaçlamışlar ve eğitim (%80) ve test (%20) setleri için sınıflandırma ve regresyon ağacı (CART), çok değişkenli adaptif regresyon eğrileri (MARS) ve destek vektör makinesi regresyonu (SVR) algoritmaları kullanılmışlardır. Sonuç olarak en iyi tahmin modelinin, hem eğitim hem de test setinde CART modeli olduğunu bildirmişlerdir.

Tırınk vd. (2023b) çalışmalarında Polonya Merinosu ile yapmış oldukları çalışmalarında vücut ölçümlerine dayalı vücut ağırlığını tahmin etmek için çeşitli veri madenciliği ve makine öğrenimi algoritmalarını karşılaştırmışlardır. Çalışmada CART, destek vektör regresyonu ve rastgele orman regresyon algoritmalarının yetenekleri tahmin edilmiş ve değerlendirilen algoritmaların tahmin performanslarının karşılaştırılması ile vücut ağırlığının tahmin edilmesi için en iyi model olarak bildirmişlerdir.

Ali vd. (2015) çalışmalarında Harnai koyun ırkı için CART, CHAID, ANNs ve Exhaustive CHAID algoritmalarını karşılaştırmışlar ve sonuçlar şu şekilde tahmin edilmişlerdir: Exhaustive CHAID 0.84, CHAID 0.83, ANNs 0.81 ve CART 0.82. CART algoritmasının performansı R^2 kapsamındaki diğer algoritmalarla karşılaştırıldığında, kullanılan algoritmaların çeşitliliği ve ırk farklılıkları dikkate

alındığında CART algoritması üçüncü en iyi algoritma olduğunu, ancak performans açısından diğer algoritmalara yakın sonuçlar verdiğini bildirmişlerdir. Sonuçların hem SVR hem de RFR algoritmasının CART algoritmasından daha iyi olduğunu ve buna göre ise SVR ve RFR algoritmaları CHAID ve ANN' lerden daha iyi uyum özelliklerine sahip olduğunu bildirmişlerdir.

Faraz vd. (2021) Pakistan'da 155 baş Talli koyununun canlı ağırlıklarını tahmin edebilmek için iki farklı model (MARS ve CART) kullanmışlar ve MARS algoritmasını canlı ağırlık tahmininde CART'tan daha iyi performans gösterdiğini ve Thalli koyunlarının canlı ağırlıklarını $R^2 = \%90,3$ olduğunu bildirmişlerdir.

Taşdemir ve ark., (2011) çalışmalarında, Holstein ırkı ineklerin vücut ölçülerini dijital görüntü analiz yöntemini her ineğe ait canlı ağırlıkları belirleyebilmek için kullanmışlardır. Bu amaçla bir süt sığırcılığı işletmesinde görüntü yakalama düzeni oluşturarak Holstein inek ırkına ait vücut ölçüleri (Cidago yüksekliği, Sağrı yüksekliği, vücut uzunluğu, Sağrı genişliği ve ineklerin canlı ağırlıklarını ilk önce manuel yöntemlerle belirlemişlerdir. Daha sonra ineklere ait dijital fotoğrafları, farklı yön ve duruş pozisyonlarında eş zamanlı olarak çekmişlerdir. Daha sonra her ineğe ait CY, SG, VU ve SG' lerini tespit edebilmek için IA yazılımı kullanılarak analiz etmişlerdir. IA ile elde edilen vücut ölçüleri, manuel ölçümlerle karşılaştırmışlar ve doğruluk CY için $\%97,72$, SY için $\%98,00$, VU için $\%97,89$ ve SG için $\%95,25$ olarak belirlemişlerdir. Daha sonra vücut ölçüleri kullanılarak canlı ağırlık tahmini, regresyon denklemini kullanmışlar ve tartım sonucunda elde edilen tahmini ve gerçek canlı ağırlık değerleri arasında 0,97 korelasyon hesaplamışlardır. Bu da IA yönteminin Holstein ırkı inekler için elde edilen canlı ağırlık tahmini için uygun bir yöntem olduğunu bildirmişlerdir.

Taşdemir ve Özkan, (2019) Holstein ırkı ineklerle yapmış oldukları çalışmalarında, vücut ölçülerini fotogrametri yöntemi ile belirlemiş ve canlı ağırlıklarını ise yapay sinir ağı yöntemi kullanarak tahmin etmişlerdir. Çalışmada kullanılan vücut ölçüleri, senkronize olarak üç boyutlu kamera ortamında farklı açı ve duruşlarda görüntülenen ineklerin analizinden metrik olarak elde edilmişlerdir. İneklerden elde edilen vücut ölçülerinden cidago yüksekliği, sağrı yüksekliği, vücut uzunluğu, sağrı genişliği

fotogrametri yöntemi kullanılarak belirlenmiştir. Ayrıca bu vücut ölçümleri yapay sinir ağı yöntemi kullanılarak tahmin modelini geliştirmişlerdir. Araştırmacılar ilk önce elde edilen görüntüleri, veri seti ön işleme tabi tutmuşlardır, daha sonra eğitim ve test veri seti olarak ikiye ayırmışlardır. Bundan sonra da farklı yapılandırılmış yapay sinir ağı modellerini üretmişler ve sonunda en iyi performansa sahip olan yapay sinir ağı modelini belirlemişlerdir. Sonuç olarak da bu yapay sinir ağı modelini kullanarak hayvanlara ait canlı ağırlık, görüntülerden elde edilen ölçümleri kullanılarak tahmin etmişlerdir. Ayrıca tahmin edilen canlı ağırlıklar ile teraziden elde edilen gerçek ağırlıklar karşılaştırılarak, korelasyon katsayılarını bulmuşlardır ($R^2=0,995$). Yapılan istatistik sonuçlarına göre, her iki gruba ait değerlerin de anlamlı olduğu ve yapay sinir ağının canlı ağırlık tahmini için güvenilir olduğunu bildirmişlerdir.

Özkaya, (2012) dişi Holstein buzağılarında dijital görüntü analizi kullanılarak vücut ölçümlerinden canlı ağırlığın tahmininin doğruluğunu belirlemiştir. Buzağılardan vücut ölçülerini bir ölçü bastonu ve dijital görüntü analizi yöntemlerini kullanarak tespit etmiştir. Ölçümü yapılan vücut ölçüleri sırasıyla; vücut uzunluğu, cidago yüksekliği, göğüs derinliği, sağrı yüksekliği ve sağrı genişliği dir. Canlı ağırlık ve vücut ölçüleri doğumda, sütten kesimde ve 24 haftalık yaşta kaydetmiştir. Doğumdaki tüm vücut ölçüleri içeren regresyon katsayıları düşük bir R^2 değer verdiği (%66.7), ancak R^2 değerinin sütten kesimde ve 24 haftalık yaşta sırasıyla; %87.6 ve %86.0 olduğunu tespit etmiştir. Canlı ağırlık ve GD, SY ve SG arasında sütten kesimde sırasıyla; 0.90, 0.91 ve 0.90 ve 24 haftalık yaşta sırasıyla; 0.89, 0.90 ve 0.91 olarak yüksek bir korelasyon katsayısı tespit etmiştir. Sonuç olarak, dişi Holstein buzağıları için dijital görüntü analizinin vücut ölçülerinden canlı ağırlık tahmini için etkili bir ölçüm sistemi olduğunu bildirmiştir.

3. MATERİYAL VE METOT

3.1 Materyal

Çalışma Dicle Üniversitesi Ziraat Fakültesi Araştırma ve Uygulama Merkezi Küçükbaş hayvancılık işletmesinde gerçekleştirilmiştir. Hayvan materyalini 10 aylık yaştaki 9 baş Kilis keçisi oğlağı oluşturmuştur. Oğlaklara ait ilk görüntüler doğumdan itibaren alınmaya başlanmıştır. Oğlakların sırt görüntüleri ve canlı ağırlığa ait ölçümler 10 ay boyunca her ayın aynı gününde alınmıştır.

3.2 Metot

Bu çalışmanın veri seti alınan sırt görüntüleri ile birlikte Kilis keçisi oğlaklarından alınan morfolojik ölçümler ve canlı ağırlıkları içermektedir. Keçilerin canlı ağırlığını (CA) tahmin etmek için dört morfolojik ölçüm kullanılmıştır.

Canlı ağırlıklar, morfolojik ölçümler alındıktan sonra, tahmin modelleri için altın standart olarak kullanılmak üzere 10 grama hassas statik bir tartım platformunda ölçülmüştür. Oğlaklar tartımdan önce 12 saat süreyle aç bırakılmıştır.


Oğlakların sırt görüntüleri, 4K (3840x2160 piksel) çözünürlükte saniyede 30 kare (fps) görüntü yakalayan ve oğlakların tartım sonrası GoPro HERO 8 kamera (GoPro, San Mateo, CA) ile kaydedilmiştir (Şekil 3.2.1). MP4 formatında kaydedilen video görüntüleri Movavi Video Converter 22.2.0 yazılımı ile ImageJ uyumlu avi formatına dönüştürülmüştür. Video kayıtlarının ön işlenmesi ImageJ yazılımı ile gerçekleştirilmiştir (Schneider ve ark., 2012). Videolardan her bir hayvanın sırt bölgesinin tamamen görülebildiği net görüntü kareleri çıkarılmış ve bu kareler makine öğrenmesi için kullanılacak veri seti özellik çıkarmak amacıyla kullanılmıştır. Her oğlağın canlı ağırlığı ölçülmüş ve bu veriler ayrıca kaydedilmiştir. Canlı ağırlık ölçümleri, ilgili görüntü için "altın standart" veya referans değerler olarak kullanılmıştır.

Daha sonra elde edilen görüntüler Python ile arka plan çıkarma işlemi LabelMe yazılımı ile gerçekleştirilmiştir. Makine öğrenmesi yöntemleri kullanılarak oğlaklarda canlı ağırlık tahmin sürecini adım adım gösteren iş akışı diyagramı Şekil 3.2.1'de verilmiştir. Çalışmada referans olarak kullanılan cetvel ile oğlakların sırt görüntülerine ait ölçümler elde edilen görüntülerden elde edilmiştir. Çıkarılmış görüntüler ImageJ programı kullanılarak biyometrik ölçüm değerleri elde edilmiş ve makine öğrenmesi modellerinde kullanılmak üzere ham veri seri oluşturulmuştur (Şekil 3.2.1). Üç renkten oluşan maskede siyah renk arka planı, yeşil renk oğlakların sırt görüntüsünü ve kırmızı renk ise referans olarak kullanılan cetveli temsil etmektedir. Yapılan işlemler sırası ile aşağıda bildirilmiştir;

- Çalışma boyunca düzenli olarak oğlaklara ait sırt görüntülerinin alınması ve aynı anda canlı ağırlık ölçümlerinin gerçekleştirilmesi
- Elde edilen görüntülerin LabelMe yazılımında kullanılması
- Görüntülerin LabelMe ile etiketlenmesi
- Etiketlerin kaydedilmesi ve etiketlenmiş görüntülerden arka planların çıkarılması
- ImageJ programı ile arka planı çıkarılmış fotoğrafların biyometrik ölçümlerinin alınması




Şekil 3.2.1 Oğlakların Sırt Görüntülerinden Alınan Örnek Bir Görüntü



Şekil 3.2.2 Oğlakların Sırt Görüntülerinin Çıkarılması


Oğlaklardan alınan görüntülerin etiketleme işlemi LabelMe programı ile yapıldıktan sonra arka planlarının çıkartılması işlemi ImageJ programıyla gerçekleştirilmiş ve biyometrik ölçümler alınmıştır. Yeşil renk oğlaklara ait sırt görüntüleri, siyah renk arka plan ve kırmızı renk ise 10 cm'lik referans cetveli temsil etmektedir.



Şekil 3.2.3 Sırt Görüntülerinin Etiketlenmesi İşlemi ve Referans Ölçümler

Tablo 3.2.1 Biyometrik Ölçümler İle Elde Edilen Değişkenler (Olcay, 2025)

Değişken Adı	Açıklama	Hesaplama Yöntemi
Alan	Nesnenin kapladığı piksel alanı.	Nesne sınırları içindeki toplam piksel sayısı.
X Merkezi (XM)	Şeklin X eksenindeki ağırlık merkezi.	Şeklin piksel yoğunluklarının X koordinatındaki ağırlık merkezi hesaplanır.
Y Merkezi (YM)	Şeklin Y eksenindeki ağırlık merkezi.	Şeklin piksel yoğunluklarının Y koordinatındaki ağırlık merkezi hesaplanır.
Çevre (Perimeter)	Şeklin sınırlarının toplam uzunluğu.	Şeklin kenar uzunluklarının toplamı (piksel cinsinden).
X Başlangıcı (BX)	Şeklin sınırlarının sol üst köşesindeki X koordinatı.	Şeklin sınırlarının dikdörtgen çerçevesine göre hesaplanması.
Y Başlangıcı (BY)	Şeklin sınırlarının sol üst köşesindeki Y koordinatı.	Şeklin sınırlarının dikdörtgen çerçevesine göre hesaplanması.
Genişlik (Width)	Şeklin yatay eksenindeki toplam genişliği.	Şeklin yatay ekseninde kapladığı piksel sayısı.
Yükseklik (Height)	Şeklin dikey eksenindeki toplam yüksekliği.	Şeklin dikey ekseninde kapladığı piksel sayısı.
Uzun Eksen (Major)	Şeklin en uzun çapı (elips uydurma yöntemiyle).	Şekle en iyi uyan elipsin ana eksen uzunluğu.
Kısa Eksen (Minor)	Şeklin en kısa çapı (elips uydurma yöntemiyle).	Şekle en iyi uyan elipsin kısa eksen uzunluğu.
Açı (Angle)	Şeklin uzun ekseninin yatay eksene göre eğim açısı.	Uzun eksenin yatay eksene yaptığı açı (derece cinsinden).
Dairesellik (Circularity)	Şeklin daireye ne kadar benzediğini ifade eden bir oran.	$(4\pi \times \text{Alan}) / (\text{Çevre}^2)$.
Feret Çapı (Feret's Diameter)	Şeklin herhangi bir yöndeki maksimum çapı.	Şeklin her yöndeki çaplarının maksimum değeri.
Feret X (FeretX)	Feret çapının X eksenindeki başlangıç noktası.	Şeklin maksimum çapının X koordinatı.
Feret Y (FeretY)	Feret çapının Y eksenindeki başlangıç noktası.	Şeklin maksimum çapının Y koordinatı.
Feret Açısı (FeretAngle)	Feret çapının eğim açısı.	Maksimum çapın yatay eksene göre açısı.
Minimum Feret (MinFeret)	Şeklin minimum çapı.	Şeklin her yöndeki çaplarının minimum değeri.
En-boy Oranı (AR)	Şeklin uzun eksen ile kısa eksen oranı.	Uzun eksen / Kısa eksen.
Yuvarlaklık (Round)	Şeklin ne kadar yuvarlak olduğunu ifade eden bir oran.	$(4 \times \text{Alan}) / (\pi \times \text{Major}^2)$.
Katılık (Solidity)	Şeklin alanının dış çerçevesine (konveks alan) oranı.	Alan / Konveks Alan.



Şekil 3.2.4 Elde Edilen Verilerden Çıkarılan Özellikler

3.3 Veri Hazırlama, Ön İşleme ve Makine Öğrenmesi Modellerinin Eğitimi


Çalışmada veri keşfi ve korelasyon analizi gerçekleştirilmiş ve bu işlem değişkenler arasındaki ilişkinin incelenmesi ve optimal değişken setinin belirlenmesi amacıyla gerçekleştirilmiştir. Korelasyon matrisini oluşturmak ve Pearson korelasyon katsayılarını hesaplamak için ggstatsplot R paketi (Patil, 2021) kullanılmıştır. Yeo-Johnson dönüşümü ile veriler daha simetrik hale getirilmiş ve normal dağılıma yakınlştırılması amaçlanmıştır. Değişken seçimi makine öğrenmesi çalışmalarında önemli bir kavramdır. Çalışmada değişkenlerin belirlenmesi amacıyla Boruta algoritması kullanılmıştır (Kursa ve Rudnicki, 2010).

Canlı ağırlığın tahmini için Random Forest (Rastsal ormanlar) (Breiman, 2001), MARS (çok değişkenli uyarlanabilir regresyon eğrileri) (Friedman, 1991), SVM (Destek vektör makineleri) (Cortes ve Vapnik, 1995), ve XGBoost (Aşırı gradyan artırma) (Chen ve Guestrin, 2016) makine öğrenmesi algoritmaları kullanılmıştır. Makine öğrenme modellerinin performansı, belirtme katsayısı (R^2), Ortalama Mutlak Hata (Mean Absolute Error, MAE), Kök Ortalama Kare Hata (Root Mean Square Error, RMSE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE) kriterleri kullanılarak test veri kümesinde değerlendirilmiştir. (Boehmke ve Greenwell, 2019). Bu kriterler, Metrics R paketi kullanılarak elde edilmiştir (Hamner ve Frasco, 2018). Modeller, caret R paketi kullanılarak uygulanmıştır (Kuhn, 2008). Analizler, R programlama dili, version 4.3.2 (RCoreTeam, 2023) kullanılarak gerçekleştirilmiştir.

4. BULGULAR VE TARTIŞMA


4.1 Biyometrik Özelliklerin Çıkartılması

Korelasyon matrislerinin analizinde, biyometrik ölçümler arasındaki ilişkiler tespit edilmiştir. Ham veri seti matrisindeki güçlü korelasyon gösteren bazı değişkenler çıkarılmış ve nihai veri seti oluşturulmuştur (Şekil 4.1.1)



Şekil 4.1.1 Ham Veriler Arasındaki Korelasyon Matrisleri

Değişkenlerin önem derecelerinin belirlenmesi amacıyla Boruta algoritması uygulanmıştır. Önem dereceleri medyan sıralamasına göre sıralanmış ve dağılımları Şekil 4.1.2’de gösterilmiştir. Yüksek z-skoru yüksek olan değişkenler; sınırlayıcı değer, ana eksen, çevre, feret x, x merkezi, feret çapı, alan, küçük eksen, min feret ve yükseklik değerleri önemli bulunmuştur.



Şekil 4.1.2 Boruta Algoritması İle Belirlenen Değişkenlerin Z-Skor Önem Dağılımları

Boruta algoritması, değişkenlerin önem dağılımlarını değerlendirmektedir. Z-skorları ile gösterilen önem dağılımlarında bazı değişkenler “Confirmed” (onaylanmış) ve bazıları “Rejected” (reddedilmiş) olarak sonuçlanmıştır. En önemli değişkenler; Sınırlayıcı_X (meanImp = 6.17), Ana Eksen (meanImp = 6.03), Çevre (meanImp = 5.51), Feret_X, Xmerkezi, feret çapı, alan, küçük eksen, min feret, yükseklik bulunurken, Yuvarlaklık, dairelilik, feret açısı, Katılık, feret y, Sınırlayıcı_Y, genişlik (meanImp = 0.87), Y_Merkezi, Açı (meanImp = -0.14) önemsiz bulunan değişkenlerdir (Tablo 4.1.1).


Tablo 4.1.1 Boruta Algoritması İle Belirlenen Değişkenlerin Önem İstatistikleri

Değişken	Ortalama önem skoru	Medyan önem skoru	Minimum önem skoru	Maksimum önem skoru	Normalize edilmiş hit sayısı	Değişkenin durumu
Alan	4.86	4.88	2.29	6.55	0.84	Onaylandı
X_Merkezi	5.50	5.51	3.09	7.85	0.93	Onaylandı
Y_Merkezi	0.71	0.84	-0.88	2.27	0.00	Reddedildi
Cevre	5.51	5.54	3.94	7.36	0.91	Onaylandı
Sınırlayıcı_X	6.17	6.15	3.17	8.28	0.96	Onaylandı
Sınırlayıcı_Y	0.95	1.08	-0.89	2.24	0.00	Reddedildi
Genislik	0.87	0.88	-0.88	2.71	0.01	Reddedildi
Yukseklık	3.66	3.70	0.89	5.58	0.65	Onaylandı
Ana_Eksen	6.03	6.01	4.11	8.80	0.94	Onaylandı
Kucuk_Eksen	4.69	4.76	2.09	6.89	0.83	Onaylandı
Aci	-0.14	0.22	-1.32	0.80	0.00	Reddedildi
Dairesellik	2.26	2.40	0.67	4.17	0.02	Reddedildi
Feret_Capı	5.22	5.22	3.22	7.10	0.89	Onaylandı
Feret_X	5.61	5.53	3.56	7.94	0.93	Onaylandı
Feret_Y	1.67	1.65	0.32	3.28	0.02	Reddedildi
Feret_Acisi	1.75	1.95	-0.75	4.31	0.05	Reddedildi
Min_Feret	4.12	4.19	1.32	5.92	0.76	Onaylandı
Boy_En_Oranı	2.43	2.54	-0.53	5.07	0.39	Reddedildi
Yuvarlaklık	2.52	2.42	-0.51	4.66	0.35	Reddedildi
Katılık	1.58	1.70	-1.31	3.49	0.04	Reddedildi

AR: Aspect Ratio (en-boy oranı); meanImp: Ortalama önem skoru; medianImp: Medyan önem skoru; minImp:

Minimum önem skoru; maxImp: Maksimum önem skoru; normHits: Normalize edilmiş hit sayısı (0 ile 1 arasında değişir, her iterasyonda değişkenlerin önemini test eder); decision: Değişkenin durumu (Confirmed: Onaylanmış değişken, Rejected: Önemsiz olduğu belirlenen değişken).

Şekil 4.1.3'te ham veri setinde elemine edilen değerler gerçekleştirildikten sonra geriye kalan verilerde güçlü korelasyon gösteren değişken çiftleri birleştirilerek model daha da optimize hale getirilmiştir. Korelasyon katsayılarının değerleri -0.52 ile 0.81 arasında değişmektedir. Pozitif korelasyonlar yeşil renk ile negatif korelasyonlar ise turuncu renk ile gösterilmiştir. Korelasyonlar arasında bazıları "X" ile işaretlenmiş olup, bunlar $p < 0.05$ (Holm düzeltmesi) seviyesinde anlamsız olarak kabul edilmiştir. Korelasyonlar için örneklem büyüklüğü $n = 60$ 'tır. Şekil 4.1.2'de değişkenlerin (Dairesellik, Yükseklik, Sınırlayıcı_X, Cevre, X_Merkezi) nihai veri setinde birbiriyle olan ilişkisi gösterilmektedir. Ham veri setindeki korelasyonda önemsiz değişkenler elemine edilmiştir. X_Merkezi ve Sınırlayıcı_X arasındaki korelasyon 0.81 değeri ile en güçlü pozitif ilişki değerini göstermiştir. Sınırlayıcı_X ve CA arasındaki korelasyon -0.52 değeri ile en güçlü negatif ilişki değerini göstermiştir.



Şekil 4.1.3 Nihai Veri Setinde Değişkenler Arasındaki Korelasyonlar

Her değişkenin ortalama, standart sapma ve dağılım bilgilerinin gösterildiği Tablo 4.1.2’de Merkezi Eğilim tablosunda en değişken parametre, Yükseklik değerleri (VK = %73.93) arasında büyük farklılık olduğunu göstermektedir (heterojen). En düşük varyasyona sahip parametre, Dairesellik (VK = %9.99) verilerdeki değerlerin birbirine yakın olduğunu göstermektedir (homojen). Yüksek varyasyon katsayısı; veriler arasında yüksek değerde farklılıklar olduğu yani nesnelerin boyut, şekil ve diğer özelliklerinin çok fazla çeşitlendiğini ifade eder. Düşük varyasyon katsayısı ise; verilerin daha tutarlı ve birbirlerine daha yakın özellik gösterdiğini, yani nesnelerin özellikler bakımından benzer olduğunu ifade eder. Bu da genellikle homojen yapı olarak ifade edilir.

Tablo 4.1.2 Değişkenlerin Merkezi Eğilim ve Dağılım Özellikleri

Değişken	Ortalama± StdSap	VK%	Mak	Min
CA	16.58±4.38	26.41	25.26	8.88
X_Merkezi	0.18±0.06	35.32	0.30	0.06
Cevre	0.63±0.19	29.95	1.10	0.39
Sınırlayıcı_X	0.08±0.05	63.53	0.20	0.02
Yükseklik	0.15±0.11	73.93	0.43	0.06
Dairesellik	0.52±0.05	09.99	0.62	0.40

Tablo 4.1.3'te de görüldüğü üzere XGBoost modeli *eğitim veri setinde* çok iyi performans gösterirken ($R^2=0.98$, MAE =0.50, RMSE=0.64), test veri setinde ise ($R^2=0.01$, MAE =0.01, RMSE=5.36) bu performansı göstermemiştir. Faraz vd. (2023)'nin Kajli koyunlarında gerçekleştirmiş oldukları çalışmada XGBoost algoritmasının ($R^2=0.98$ train, $R^2=0.92$ test) güncel ağırlığı vücut ölçümlerinden tahmin etmek için en güvenilir model olduğu ve bunun da çalışmamızdaki benzer model olduğu görülmektedir. Fakat bu sonuçlar sadece XGBoost eğitim veri setinde elde ettiğimiz sonuçlarla uyum göstermekle beraber XGBoost test veri setinde elde ettiğimiz sonuçlardan farklılık göstermektedir. Bu da çalışmamızda XGBoost modelinin eğitim veri setine aşırı uyum (overfitting) sağladığını ve yeni verilere genelleme yapmada zorlandığını göstermiştir.

Tablo 4.1.3 Farklı Makine Öğrenmesi Modellerinin Farklı Veri Setlerinde Eğitim Ve Test Performanslarının Karşılaştırması

Model	Eğitim Veri Seti				Test Veri Seti		
	RMSE	R^2	MAE	Eğitim Süresi	RMSE	R^2	MAE
Random Forest	1.89	0.85	1.55	4.82 sn	4.63	0.04	3.67
SVR	3.19	0.51	2.26	9.95 sn	4.48	0.07	3.51
MARS	3.92	0.19	3.10	5.95 sn	4.13	0.09	3.40
XGBoost	0.64	0.98	0.50	1.21 dk	5.36	0.01	4.14


Iqbal vd. (2022)'nin Pakistan'da Beetal keçilerinin canlı ağırlıklarının tahmininde makine öğrenme yöntemlerinin tahmin yeteneklerinin karşılaştırılmasını amaçladıkları çalışmada; gradyan artırma makinesi, regresyon ağacı, rastgele ormanlar ve SVM algoritmaları için model performanslarını karşılaştırmışlardır. Çalışmada cinsiyet, vücut uzunluğu, but çevresi, boyun uzunluğu, baş çevresi, kuyruk yüksekliği ve göbek çıkıntısı gibi açıklayıcı değişkenler değerlendirilmiştir. Bu çalışmada, Pearson korelasyonu, R^2 , MAE, MAPE ve RMSE gibi model karşılaştırma kriterleri

seçilmiştir. Sonuçlara göre, gradyan artırma makinesi (GBM), Beetal keçilerinin canlı ağırlığını tahmin etmek için en iyi model olarak belirlenmiştir.

Karahan (2020)'ın makine öğrenmesi ve görüntü işleme yöntemleri ile sığırlarda canlı ağırlık tahmini yapmak amacıyla gerçekleştirdiği çalışmada yapay sinir ağları, çok değişkenli uyarlanabilir regresyon eğrileri (MARS) ve Ki kare otomatik interaksyon belirleme yöntemleri ile yapılan canlı ağırlık tahminlerinde ortalama mutlak hata yüzdesi (MAPE) değerleri sırasıyla %4.15, %4.75 ve %5.36 olarak tespit edilmiştir. Çalışmada R^2 değerleri aynı sırayla 0.9467, 0.9334 ve 0.9211 olarak, hata kareler ortalamasının karekökü (RMSE) değerleri sırasıyla 31.63 kg, 32.95 kg ve 38.42 kg olarak belirlenmiş ve çoklu doğrusal regresyon (ÇDR) yöntemiyle ise MAPE, R^2 ve RMSE değerleri sırasıyla %5.02, 0.9266 ve 37.06kg olarak tespit edilmiştir.

Coşkun vd. (2023) Anadolu merinoslarında günlük canlı ağırlığını tahmini için veri madenciliği algoritmalarından 3 modelin performansını karşılaştırmışlardır. Çalışmada algoritmaların tasarımında bağımsız değişken olarak, tek doğum ve erkek olmak üzere toplam 54 baş Anadolu Merinosu kuzularından besiye alınmadan önce; cidago yüksekliği, kuyruk sokumu yüksekliği, vücut uzunluğu, göğüs çevresi, but çevresi ve göğüs derinliği ölçümleri alınmıştır. Çalışmada XGBoost algoritmasında $RMSE=1.492$, $R^2=0.946$ değerleri çalışmamızda elde ettiğimiz değerlerden farklılık göstermektedir. Çalışmamızda benzer şekilde MARS, Random Forest ve SVR modelleri de test setinde düşük performans değerleri göstermiştir. XGBoost model karmaşık işlemleri gerçekleştirirken eğitim süresinin daha yüksek olmasına neden olmuş, en uzun eğitim süresine sahip model olarak tespit edilmiştir. Çalışmalardan elde edilen sonuçlarda farklılıklar olduğu ve farklı modellerin canlı ağırlık tahminlerinde öne çıktığı görülmektedir. Çalışmalarda verileri değerlendirirken eğitim veri setinde elde edilen değerlerden daha çok test veri setindeki değerleri dikkate almanın daha doğru olacağı sonucu ortaya çıkmıştır. Çünkü Tablo 4.1.3'de de görüldüğü üzere test veri setindeki en küçük R^2 (0.01) değerine sahip XGBoost modeli canlı ağırlığı en iyi tanımlayan model olmuştur. Bu çalışma ile diğer çalışmalar arasındaki farklılıkları, çalışmalarda farklı tür, ırk, cinsiyet, doğum tipi, ölçümlerdeki hassasiyetlerin farklı olması gibi nedenlerle açıklayabiliriz.


Model öğrenme şekilleri, şekil 4.1.4'te verilmiştir. Eğitim metrikleri modelin eğitim verilerine ne derecede iyi uyum gösterdiğini gösterirken, doğrulama metrikleri modelin daha önce işlenmemiş verilerde ne derece iyi performans gösterdiğini değerlendirir. Eğitim ve doğrulama metriklerinin birbirlerine benzer şekilde veya yakın şekilde olması, modelin hem eğitim hem de doğrulama verilerinde tutarlı ve iyi performans gösterdiğini ifade eder. Eğitim seti ile yapılan değerlendirmeler, modelin öğrenme sürecinde ne kadar iyi uyum sağladığını gösterirken, doğrulama seti ile yapılan değerlendirmeler, modelin genelleme yeteneğini göstermektedir.



Şekil 4.1.4 Öğrenme Eğrileri


Şekil 4.1.5'te dört farklı makine öğrenimi modeli; MARS, SVM, Random Forest ve XGBoost için çeşitli özelliklerin önem seviyeleri karşılaştırılmıştır. Her grafik dört özelliğin (X_Merkezi, Yükseklik, Sınırlayıcı_X ve Çevre) önem seviyelerini göstermektedir. Önem değerleri 0 ila 100 arasında bir ölçekte temsil edilmektedir. Özelliklerin önem seviyesi modeller arasında önemli ölçüde değişiklik göstermektedir. X_Merkezi, MARS ve SVM modelleri için önemli bulunurken. Çevre, Random Forest

ve XGBoost modelleri için en önemli özellik olarak ortaya çıkmaktadır. Yükseklik ve Sınırlayıcı_X ise genellikle diğer özelliklere kıyasla daha düşük öneme sahip olmuştur. Cevre; Random Forest ve XGBoost modellerinde en önemli özellik olarak görülürken, MARS ve SVM modellerinde daha az önemli özellikte olduğu görülmektedir. X_Merkezi; Hem MARS hem de SVM modellerinde en önemli özellik olarak öne çıkarken, Random Forest ve XGBoost modellerinde ikinci sırada yer almaktadır (Şekil 4.1.5). Sınırlayıcı_X; SVM ve XGBoost modellerinde üçüncü sırada yer alırken, Random Forest ve MARS modellerinde daha az düzeyde önemli bulunmuştur. Yükseklik; MARS modelinde ikinci en önemli özellikken, diğer modellerde daha alt sıralarda yer almaktadır. Çakmakçı (2022)'nın çalışmasında göğüs derinliği ve göğüs genişliği tüm makine öğrenimi modellerinde en önemli öngörücüler iken, en az önemli öngörücüler vücut uzunluğu ve omuz yüksekliğidir. Huma ve Iqbal (2019)'un yalnızca rastgele orman modeli için önem puanı bildirdikleri çalışmada ise vücut uzunluğu en önemli öngörücü iken, cidago yüksekliği ve göğüs genişliği en az önemli öngörücülerdir. Sonuçlardaki farklılıkların çalışmamızdaki veri setlerinin oluşturulması sırasında çekilmiş görüntülerden kaynaklandığı düşünülmektedir.



Şekil 4.1.5 Değişkenlerin Önem Seviyeleri

Şekil 4.1.6’da ANOVA testi dört farklı makine öğrenimi modellerinin canlı ağırlık ortalamalarının istatistiksel olarak anlamlı bir fark bulunmadığını göstermektedir ($p = 0.70$). Burada, $p = 0.70$ olduğu için, modeller arasında fark olmaması olasılığı %70’ tir. Genel olarak, p değeri 0.05’ten küçükse, sonuçlar istatistiksel olarak anlamlı kabul edilmektedir. Ancak bu durumda, p değeri 0.70 olduğu için farkların istatistiksel olarak anlamlı olmadığı görülmektedir. Aynı şekilde Çakmakçı (2022) çalışmasında ANOVA testi sonuçlarının makine öğrenimi modelleri tarafından gerçek ve öngörülen canlı ağırlıkların ortalamaları arasında istatistiksel olarak anlamlı bir fark olmadığını bildirmiştir. Şekil 4.1.6’te ANOVA testi sonuçlarına göre **Ortalama Değerler** dört farklı makine öğrenimi modellerinin ortalama canlı ağırlık değerleri ile birbirine oldukça yakın değerde olduğu görülmektedir. Gerçek (16.73), MARS (16.23), RF (16.02), SVM (15.45) ve XGBoost (15.95) modelleri arasında büyük farklar gözlenmemiştir. Farklı modellerin canlı ağırlık ölçümleri arasında istatistiksel olarak anlamlı bir fark olmadığını ve dört farklı makine öğrenimi modellerinin performanslarının birbirine oldukça benzer olduğunu göstermiştir. Tırınk vd. (2023b) ise çalışmalarında Suffolk $\times$ Polonya Merinos koyunlarının vücut ağırlığını yedi vücut ölçümünden tahmin etmek için RF, SVMR ve CART modellerinin tahmin yeteneklerini karşılaştırmış ve RF’nin diğer modellerden daha iyi performans gösterdiğini, göğüs çevresinin ana tahmin edici değişken olduğunu bulmuştur.




Şekil 4.1.6 Gerçek Canlı Ağırlık Değerleri İle Modellerin Tahmin Ettiği Değerler Arasındaki İstatistiksel Farklar

Şekil 4.1.7’de dört farklı makine öğrenimi modelleri (SVM, XGBoost, RF ve MARS) ile gerçek değerler arasındaki Pearson korelasyon katsayılarını göstermektedir. SVM ve RF modelleri 0.89 ile yüksek bir korelasyon gösterirken, SVM ve MARS (0.68), XGBoost ve MARS (0.46), RF ve MARS (0.65), SVM ve XGBoost (0.66) orta düzeyde korelasyon ve SVM ve Gerçek (0.27), RF ve Gerçek (0.2), MARS ve Gerçek (0.3), XGBoost ve Gerçek (0.09) modelleri düşük bir korelasyon değerine sahip olmuştur.

RF ile XGBoost arasında (0.85) iken bu ifade bu iki modelin benzer tahminler ürettiği anlamına gelmektedir. En düşük korelasyon XGBoost ile gerçek veriler arasında (0.09) gerçekleşirken bu ifade XGBoost model tahminlerinin gerçek verilerle çok düşük ilişkiye sahip olduğunu ifade etmektedir. SVM ve RF modelleri birbirleri arasında güçlü bir korelasyon (0.89) gösterirken, tahminlerin modeller arasındaki benzerliğini ifade etmektedir. Çakmakçı (2022) çalışmasında korelasyon matrisi değerlerinde canlı ağırlık değerlerini SVMR ($r=+0.80, P<0.05$), RF, ($r=+0.79, P<0.05$)

ve ANN ($r = +0,77$, $P < 0,05$) en yüksek anlamlı pozitif korelasyona, CART ($r = +0,59$, $P < 0,05$) modelinin ise en düşük korelasyona sahip olduğunu bildirmiştir. Çalışmamızda sınırlı veri kümesinin ve aşırı uyumun korelasyon değerleri üzerinde olumsuz etkisinin olduğu düşünülmektedir.



Şekil 4.1.7 Gerçek Canlı Ağırlık Değerleri İle Modellerin Tahmin Ettiği Değerler Arasındaki Korelasyon Katsayıları

5. SONUÇ VE ÖNERİLER

Hayvanların canlı ağırlıklarının ve vücut gelişimlerinin düzenli takibi hayvan sağlığı, verimlilik, ekonomik kazanç, kesime uygun hayvanların ve damızlık hayvanların belirlenmesi açısından oldukça önemlidir. Aynı zamanda, sürü içerisinde canlı ağırlığın takibi ile yeterli beslenme ve ani kilo kaybı hakkında bilgiler elde edilir. İstenilen canlı ağırlığa ulaşmış hayvanların tespiti ise ekonomik kazanç sağlarken, üreticinin de kârlılığını arttırmış olur. Küçükbaş hayvanların vücut kompozisyonlarının doğru bir şekilde belirlenmesi, durumlarının değerlendirilmesinde kullanılabilir ve bu da yönetim kararları almak için önemli bilgiler sağlar.

Bu çalışmada, farklı makine öğrenimi algoritmalarının canlı ağırlık tahmini konusundaki performansları değerlendirilmiştir. Elde edilen bulgulara göre, test verisi üzerinde en düşük hata oranlarına sahip olan MARS modeli, bu çalışmada canlı ağırlık tahmini için en başarılı ve genellenebilir model olarak öne çıkmıştır. Bununla birlikte, XGBoost, Random Forest ve SVR gibi modeller eğitim verisi üzerinde başarılı sonuçlar elde etse de, test verisindeki performansları daha düşük kalmıştır. Bu durum, aşırı öğrenme ve sınırlı veri kümesinin etkisiyle açıklanabilir.

Bu çalışmanın sonuçları, araştırmacıların ve yetiştiricilerin hayvanlarda vücut ölçümlerini kullanarak vücut ağırlığını doğru bir şekilde tahmin etmek için optimizasyon uygulamalarını ve makine öğrenimi yaklaşımlarını uygulamada yardımcı olabilir. Canlı ağırlığın tahmininde görüntü işleme ve makine öğreniminin kullanımı pratik, güvenilir ve daha az iş gücü gerektirecek çözümler sunabilir. Ayrıca, gelecekteki çalışmalar, hayvan türlerinin vücut ağırlıklarını ve morfolojik ölçüm değerlerini doğru bir şekilde tahmin etmek için veri madenciliği ve makine öğrenimi algoritmalarının daha fazla araştırılmasını içerebilir.

KAYNAKLAR

- Ali, M.; Eydurán, E.; Tariq, M.M.; Tirink, C.; Abbas, F.; Bajwa, M.A.; Baloch, M.H.; Nizamani, A.H.; Waheed, A.; Awan, M.A. (2015). Comparison of artificial neural network and decision tree algorithms used for predicting live weight at post weaning period from some biometrical characteristics in Harnai sheep. *Pak. J. Zool.* 2015, 47, 1579–1585.
- Alsahaf, A., Azzopardi, G., Ducro, B., Hanenberg, E., Veerkamp, R. F., & Petkov, N. (2019). Estimation of muscle scores of live pigs using a kinect camera. *IEEE Access*, 7, 52238-52245.
- Akçapınar, H., & Özbeyaz, C. (2020). Küçükbaş Hayvan Yetiştiriciliği. Ankara: Akademisyen Kitabevi.
- Amandine, V., Cédric, M., Sergio, M., & Patricia, D. (2019). An ImageJ tool for simplified post-treatment of TEM phase contrast images (SPCI). *Micron*, 121, 90-98.
- Andrade, V. V., Bernardes, P. A., Vicentini, R. R., Oliveira, A. P., Veroneze, R., Ujita, A., & El Faro, L. (2021). Estrus prediction models for dairy gyr heifers. *Animals*, 11(11), 3103.
- Arslan, M., & Çelik, S. (2021). Görüntü işleme ve makine öğrenimi yöntemleriyle hayvan canlı ağırlık tahmini. *Tarım Bilimleri Dergisi*, 27(3), 345-360.
- Aytekin I, Eydurán E, Karadas K, Aksahan R, Keskin I. (2018). Prediction of fattening final live weight from some body measurements and fattening period in young bulls of crossbred and exotic breeds using MARS data mining algorithm. *Pak J Zool* 2018; 50: 189-195. doi: 10.17582/journal.pjz/2018.50.1.189.195
- Aytekin, İ., Özbeyaz, C., & Akçapınar, H. (2018). Prediction of body weight in cattle using body measurements. *Anadolu Tarım Bilimleri Dergisi*, 33(2), 210–215.
- Bektaş, S. (2016). Kırşehir ilinde yetiştirilen esmer ve esmer melezi sığırlarda bazı morfolojik özelliklerin görüntü işleme yöntemi ile belirlenmesi (Master's thesis, Ahi Evran Üniversitesi).
- Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine learning in agriculture: A comprehensive updated review. *Sensors*, 21(11), 3758. <https://doi.org/10.3390/s21113758>
- Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. *Rev. Sci. Tech*, 33(1), 189-196.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324

- Boehmke, B., & Greenwell, B. M. (2019). *Hands-on machine learning with R*. Chapman and Hall/CRC.
- Boehmke, B., & Greenwell, B. (2019). *Hands-On Machine Learning with R*. CRC Press.
- Bollig, N., Clarke, L., Elsmo, E., & Craven, M. (2020). Machine learning for syndromic surveillance using veterinary necropsy reports. *PloS one*, 15(2), e0228105.
- Borges Oliveira Vd., 2021; Lee Vd., 2020; Huma Ve Iqbal, 2019; Çakmakçı, 2022.
- Brown, D. J., Savage, D. B., Hinch, G. N., & Hatcher, S. (2014). Monitoring liveweight in sheep is a valuable management strategy: a review of available technologies. *Animal Production Science*, 55(4), 427-436.
- Brown, C. L., Carter, M., & Gibson, P. A. (2015). The Relationship Between Live Weight Changes and Reproductive and Growth Performance in Small Ruminants. *Animal Science Journal*.
- Burke, J. A., Nuthall, P. L., & McKinnon, A. E. (2004). An analysis of the feasibility of using image processing to estimate the live weight of sheep.
- Canaza-Cayo, A. W., Churata-Huacani, R., Çakmakçı, C., Rodríguez-Huanca, F. H., de Sousa Bueno Filho, J. S., Fernandes, T. J., & De La Cruz, Y. C. R. (2024). Use of machine learning approaches for body weight prediction in Peruvian Corriedale Sheep. *Smart Agricultural Technology*, 7, 100419.
- Canaza-Cayo, J., García, M., López, D., & Martínez, R. (2024). Development of an Automated System for Live Weight Prediction in Small Ruminants Using Machine Learning and Image Processing. *Journal of Agricultural Engineering*.
- Counce, S. L., Dadarwal, D., Adams, G. P., Brar, P., & Singh, J. (2019). An objective volumetric method for assessment of ovarian follicular and luteal vascular flow using colour Doppler ultrasonography. *Theriogenology*, 138, 66-76.
- Cebeci, Z., Bek, Y. (1994). Yapağı örneklerinin Kalite Kontrolünde Görüntü İşleme Sistemi Kullanımı Üzerine Bir Araştırma. Tarımda Bilgisayar Uygulamaları Sempozyumu 5-7 Ekim 1994. E.Ü.Ziraat Fakültesi – İzmir. S:1-7.
- Chacón, E., Macedo, F., Velázquez, F., Paiva, S. R., Pineda, E., & McManus, C. (2011). Morphological measurements and body indices for Cuban Creole goats and their crossbreds. *Revista Brasileira de Zootecnia*, 40, 1671-1679.
- Chen, T., Guestrin, C. (2016). XGBoost., 785-794. doi:10.1145/2939672.2939785

- Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. doi:10.1007/BF00994018
- Çakmakçı, C. (2022). Live weight prediction in norduz sheep using machine learning algorithms. *Turkish Journal of Agriculture-Food Science and Technology*, 10(4), 587-594.
- Dakhlan, A., Hamdani, M., & Sulastri, S. (2020). Regression models and correlation analysis for predicting body weight of female Ettawa Grade goat using its body measurements. *Advances in Animal and Veterinary Sciences*, 8(11), 1142-1146.
- Dipova, N. (2018). Görüntü analizi yöntemlerinin geoteknik mühendisliğinde kullanımı. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9(1), 33-44.
- Dipova, N. (2018). Görüntü işleme tekniklerinin zemin sınıflandırmalarındaki yeri ve kullanımı. *Mühendislik Bilimleri ve Tasarım Dergisi*, 6(2), 267-278.
- Ershad, S. M. E., Islam, M. T., & Paul, B. K. (2022). Comparison of machine learning algorithms for live body weight prediction of sheep using biometric data. *Computers and Electronics in Agriculture*, 194, 106770
- Faraz, A., Tırınk, C., Önder, H., Şen, U., Ishaq, H. M., Tauqir, N. A., ... & Nabeel, M. S. (2023). Usage of the XGBoost and MARS algorithms for predicting body weight in Kajli sheep breed. *Tropical Animal Health and Production*, 55(4), 276.
- Fernandes, A. F., Dórea, J. R., Fitzgerald, R., Herring, W., & Rosa, G. J. (2019). A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. *Journal of animal science*, 97(1), 496-508.
- Fernandes, T. S., et al. (2019). Development of prediction equations for live weight based on biometric measurements in sheep. *Revista Brasileira de Zootecnia*, 48, e20180246.
- Ferra, J. D. C., Cieslak, S., Sartori Filho, R., McManus, C., Martins, C. F., & Sereno, J. R. B. (2010). Weight and age at puberty and their correlations with morphometric measurements in crossbred breed Suffolk ewe lambs. *Revista Brasileira de Zootecnia*, 39, 134-141.
- Ferra, B. A., et al. (2010). Morphometric traits as predictors of live weight in sheep. *Animal Science Journal*, 81(2), 250-255.
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 19(1), 1-67. <http://www.jstor.org/stable/2241837>.

- Goldstein, B. A., Navar, A. M., & Carter, R. E. (2017). Moving beyond regression techniques in cardiovascular risk prediction: applying machine learning to address analytic challenges. *European heart journal*, 38(23), 1805-1814.
- Gomes, R. A., Monteiro, G. R., Assis, G. J. F., Busato, K. C., Ladeira, M. M., & Chizzotti, M. L. (2016). Estimating body weight and body composition of beef cattle trough digital image analysis. *Journal of Animal Science*, 94(12), 5414-5422.
- Gomes, F. B., et al. (2016). Morphometric measurements and their use in estimating body weight of goats. *Small Ruminant Research*, 134, 1–6.
- Greenwood, P. L., Hunt, A. S., Hermanson, J. W., & Bell, A. W. (1998). Effects of birth weight and postnatal nutrition on neonatal sheep: I. Body growth and composition, and some aspects of energetic efficiency. *Journal of animal science*, 76(9), 2354-2367.
- Günay, M., & Demirtaş, H. (2019). Hayvan vücut ölçüleri ve canlı ağırlık tahmini üzerine bir araştırma. *Hayvancılık Araştırmaları Dergisi*, 30(2), 123-130.
- Hatcher, S., Eppleston, J., Graham, R. P., McDonald, J., Schlunke, S., Watt, B., & Thornberry, K. J. (2008). Higher weaning weight improves postweaning growth and survival in young Merino sheep. *Australian Journal of Experimental Agriculture*, 48(7), 966-973.
- He, D.J., Liu, D., Zhao, K.X., 2016. Review of perceiving animal information and behavior in precision livestock farmin. *Trans. Chin. Soc. Agric. Mach.* 47 (5), 231–244 (in Chinese).
- Hamner, B., Frasco, M. (2018). Metrics: Evaluation Metrics for Machine Learning. R package version 0.1. 4. 2018.
- Huma, Z. E., & Iqbal, F. (2019). Predicting the body weight of Balochi sheep using a machine learning approach. *Turkish Journal of Veterinary & Animal Sciences*, 43(4), 500-506.
- Karahan, A.E. (2020). Makine öğrenmesi ve Görüntü işleme yöntemlerini kullanarak et sığırlarında canlı ağırlık tahmini. (Doktora Tezi). Ege Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Kashiha, M., Bahr, C., Ott, S., Moons, C. P., Niewold, T. A., Ödberg, F. O., & Berckmans, D. (2014). Automatic weight estimation of individual pigs using image analysis. *Computers and Electronics in Agriculture*, 107, 38-44.
- Kaya, A., Demirtaş, H., & Öztürk, M. (2022). Derin öğrenme algoritmaları ile hayvan canlı ağırlık tahmini. *Ziraat Fakültesi Dergisi*, 35(1), 45-55.

- Khan, M. A., et al. (2020). Predictive modeling of live weight in livestock using machine learning techniques. *Animals*, 10(9), 1566.
- Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5), 1-26. doi:<https://doi.org/10.18637/jss.v028.i05>
- Kunene, N. W., Nesamvuni, A. E., & Nsahlai, I. V. (2009). Determination of prediction equations for estimating body weight of Zulu (Nguni) sheep. *Small Ruminant Research*, 84(1-3), 41-46.
- Kursa, M. B., Rudnicki, W. R. (2010). Feature Selection with the Boruta Package. *Journal of Statistical Software*, 36(11). doi:10.18637/jss.v036.i11
- Le Cozler, Y., Allain, C., Caillot, A., Delouard, J. M., Delattre, L., Luginbuhl, T., & Faverdin, P. (2019). High-precision scanning system for complete 3D cow body shape imaging and analysis of morphological traits. *Computers and Electronics in Agriculture*, 157, 447-453.
- Lee, D. H., Lee, S. H., Cho, B. K., Wakholi, C., Seo, Y. W., Cho, S. H., ... & Lee, W. H. (2019). Estimation of carcass weight of Hanwoo (Korean native cattle) as a function of body measurements using statistical models and a neural network. *Asian-Australasian journal of animal sciences*, 33(10), 1633.
- Lee, S. H., Hwang, H., Kim, J. H., & Park, B. (2020). Predicting live weight in sheep using machine vision and deep learning. *Computers and Electronics in Agriculture*, 173, 105385.
- Li, B., Liu, L., Shen, M., Sun, Y., & Lu, M. (2019). Group-housed pig detection in video surveillance of overhead views using multi-feature template matching. *Biosystems Engineering*, 181, 28-39.
- Liu, W., Wang, X., & Zhang, Q. (2023). Use of Image Processing Techniques for Livestock Housing and Space Requirement Determination. *Journal of Agricultural Engineering*.
- Luo, X., Hu, Y., Gao, Z., Guo, H., & Su, Y. (2023). Automated measurement of livestock body based on pose normalisation using statistical shape model. *Biosystems Engineering*, 227, 36-51.
- Lüttgenau, J., Ulbrich, S. E., Beindorff, N., Honnens, A., Herzog, K., & Bollwein, H. (2011). Plasma progesterone concentrations in the mid-luteal phase are dependent on luteal size, but independent of luteal blood flow and gene expression in lactating dairy cows. *Animal Reproduction Science*, 125(1-4), 20-29.
- Ma, W., Qi, X., Sun, Y., Gao, R., Ding, L., Wang, R., ... & Li, Q. (2024). Computer Vision-Based Measurement Techniques for Livestock Body Dimension and Weight: A Review. *Agriculture*, 14(2), 306.

- Mandal, A., et al. (2015). Relationship between body weight and reproductive traits in sheep: A review. *Small Ruminant Research*, 123(1), 1–7.
- Mavule, B. S., Muchenje, V., Bezuidenhout, C. C., & Kunene, N. W. (2013). Morphological structure of Zulu sheep based on principal component analysis of body measurements. *Small Ruminant Research*, 111(1-3), 23-30.
- Mavule, B. S., et al. (2013). Predicting body weight of Zulu sheep using body measurements. *Tropical Animal Health and Production*, 45(2), 511–516.
- Meghelli, I., Kaouadji, Z., Yilmaz, O., Cemal, I., Karaca, O., & Gaouar, S. B. S. (2020). Morphometric characterization and estimating body weight of two Algerian camel breeds using morphometric measurements. *Tropical animal health and production*, 52, 2505-2512.
- Mekpariyup, J., Saithanu, K., & Arunkeeree, N. (2013). Estimation of body weight of holstein-friesian cattle with multiple regression analysis. *International Journal of Applied Mathematics and Statistics*, 44(14), 1-7.
- Menesatti, P., Costa, C., Antonucci, F., Steri, R., Pallottino, F., & Catillo, G. (2014). A low-cost stereovision system to estimate size and weight of live sheep. *Computers and Electronics in Agriculture*, 103, 33-38.
- Miller, G. A., Hyslop, J. J., Barclay, D., Edwards, A., Thomson, W., & Duthie, C. A. (2019). Using 3D imaging and machine learning to predict liveweight and carcass characteristics of live finishing beef cattle. *Frontiers in Sustainable Food Systems*, 3, 30.
- Moawed, S. A., & Osman, M. M. (2017). The robustness of binary logistic regression and linear discriminant analysis for the classification and differentiation between dairy cows and buffaloes. *Int. J. Stat. Appl*, 7(7).
- Mohammad MT, Rafeeq M, Bajwa MA, Awan A, Abbas F, Waheed A, Bukhari A, Akhtar P. (2012). Prediction of body weights from body measurements using Regression Tree (RT) method for indigenous sheep breed in Balochistan, Pakistan. *J Anim Plant Sci* 2012; 22: 20-24.
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M., & Fernando, S. C. (2018). Big data analytics and precision animal agriculture symposium: Machine learning and data mining advance predictive big data analysis in precision animal agriculture. *Journal of animal science*, 96(4), 1540-1550.
- Mullainathan, S., & Spiess, J. (2017). Machine learning: an applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87-106.
- Negretti, P., Bianconi, G., Bartocci, S., & Terramoccia, S. (2007). Lateral Trunk Surface as a new parameter to estimate live body weight by Visual Image Analysis. *Italian Journal of Animal Science*, 6(sup2), 1223-1225.

- Notter, D. R. (2012). Genetic improvement of reproductive efficiency of sheep and goats. *Animal Reproduction Science*, 130(3–4), 147–151.
- Olaniyi, T. A., Popoola, M. A., Olaniyi, O. A., Faniyi, T. O., & Iniobong, U. (2018). Relationship between morphological traits, body indices and body condition score as welfare indicators of Nigerian sheep. *Journal of Animal Science and Veterinary Medicine*, 3(1), 1-5.
- Olcar, B. (2025). Akkaraman Erkek Kuzularda Sırt Görüntülerinden Dijital Görüntü İşleme ve Makine Öğrenmesi Yöntemleriyle Canlı Ağırlık Tahmini. (Yüksek Lisans Tezi) Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü, Van.
- Öztürk, M., Yılmaz, R., & Kaya, A. (2018). Vücut ölçüleri ile süt verimi arasındaki ilişkinin incelenmesi. *Süt Teknolojisi Dergisi*, 16(4), 200-210.
- Pabiou, T., Fikse, W. F., Cromie, A. R., Keane, M. G., Näsholm, A., & Berry, D. P. (2011). Use of digital images to predict carcass cut yields in cattle. *Livestock Science*, 137(1-3), 130-140.
- Palmer, A., Jiménez, R., & Gervilla, E. (2011). Data Mining: Machine Learning and Statistical Techniques. In K. Funatsu (Ed.), *Knowledge-Oriented Applications in Data Mining*. IntechOpen. Retrieved from <https://www.intechopen.com/chapters/13179>
- Patil, I. (2021). Visualizations with statistical details: The “ggstatsplot” approach. *Journal of Open Source Software*, 6(61), 3167. doi:10.21105/joss.03167
- RCoreTeam. (2023). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>. R version 4.3.2.
- Safari, E., Fogarty, N. M., & Gilmour, A. R. (2005). A review of genetic parameter estimates for wool, growth, meat and reproduction traits in sheep. *Livestock Production Science*, 92(3), 271–289.
- Samperio, E., Lidón, I., Rebollar, R., Castejón-Limas, M., & Álvarez-Aparicio, C. (2021). Lambs’ live weight estimation using 3D images. *Animal*, 15(5), 100212.
- 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.
- Shahinfar, S., Kelman, K., & Kahn, L. (2019). Prediction of sheep carcass traits from early-life records using machine learning. *Computers and electronics in agriculture*, 156, 159-177.

- Stajanko, D., Brus, M., & Hočevan, M. (2008). Estimation of bull live weight through thermographically measured body dimensions. *Computers and Electronics in Agriculture*, 61(2), 233-240.
- Taşdemir, S., Urkmez, A., & Inal, S. (2011). Determination of body measurements on the Holstein cows using digital image analysis and estimation of live weight with regression analysis. *Computers and electronics in agriculture*, 76(2), 189-197.
- Tebug, S. F., et al. (2019). Predicting body weight of Ethiopian sheep breeds using linear body measurements. *Tropical Animal Health and Production*, 51(2), 381–388.
- Tırınk, C., Önder, H., Francois, D., Marcon, D., Şen, U., Shaikenova, K., ... & Tyasi, T. L. (2023a). Comparison of the data mining and machine learning algorithms for predicting the final body weight for Romane sheep breed. *Plos One*, 18(8), e0289348.
- Tırınk, C., Piwczyński, D., Kolenda, M., & Önder, H. (2023b). Estimation of body weight based on biometric measurements by using random forest regression, support vector regression and CART algorithms. *Animals*, 13(5), 798.
- Torres, R., Pereira, F., & Silva, P. (2022). Image Processing and Machine Learning for Weight Prediction in Small Ruminants. *Journal of Agricultural Technology*. Küçükbaş hayvanların ağırlık tahmininde görüntü işleme ve makine öğrenmesi yöntemlerinin entegrasyonunu tartışan bu çalışmada, büyüme hızları üzerinde başarılı sonuçlar elde edilmiştir.
- Tunaz, A. T. (2021). Görüntü İşleme ve Klasik Yöntem İle Şami ve Halep Keçilerinde Canlı Ağırlık Tahminlenmesi. *Türk Tarım ve Doğa Bilimleri Dergisi*, 8(4), 913-927.
- Valletta, J. J., Torney, C., Kings, M., Thornton, A., & Madden, J. (2017). Applications of machine learning in animal behaviour studies. *Animal Behaviour*, 124, 203-220.
- Valletta, J. J., Torney, C., Kings, M., Thornton, A., & Madden, J. (2017). Applications of machine learning in animal behaviour studies. *Animal Behaviour*, 124, 203–220. <https://doi.org/10.1016/j.anbehav.2016.12.005>
- Varughese, E. E., Brar, P. S., & Ghuman, S. S. (2017). Vascularization to preovulatory follicle and corpus luteum-a valuable predictor of fertility in dairy cows. *Theriogenology*, 103, 59-68.
- Vrisman, D. P., Bastos, N. M., Rossi, G. F., Rodrigues, N. N., Borges, L. P. B., Taira, A. R., ... & Oliveira, M. E. F. (2018). Corpus luteum dynamics after ovulation induction with or without previous exposure to progesterone in prepubertal Nellore heifers. *Theriogenology*, 106, 60-68.

- Wang, K., Zhao, X., & He, Y. (2017). Review on noninvasive monitoring technology of poultry behavior and physiological information. *Transactions of the Chinese Society of Agricultural Engineering*, 33(20), 197-209.
- Wang, C., Li, J., & Zhao, Y. (2021). A hybrid genetic algorithm and artificial neural network model for prediction of live body weight in goats. *Journal of Animal Science and Biotechnology*, 12(1), 14.
- Wang, L., Zhang, F., & Li, S. (2022). Artificial Intelligence in Livestock Feed Management: Optimizing Feed Intake Using Live Weight Data.
- Xiaodong, D., Xiaoxiao, L., Shiran, F., Zhichun, Y., Xiangdong, D., Jifan, Y., & Liping, Z. A. (2023). Review of the Methods of Pig Body Size Measurement and Body Weight Estimation. *Chin. J. Anim. Sci*, 59, 41-4656.
- Yıldız, N., Kaya, U., & Doğan, M. (2021). Canlı ağırlık ve verim özellikleri arasındaki ilişkiler: Küçükbaş hayvan örneği. *Türk Tarım ve Doğa Bilimleri Dergisi*, 8(2), 115–122.
- Yılmaz, R., & Kaya, A. (2020). Et kalitesi ve vücut ölçüleri arasındaki korelasyonların analizi. *Et ve Et Ürünleri Bilimi*, 35(2), 150-160.
- 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.
- Zhang, A. L. N., Wu, B. P., Jiang, C. X. H., Xuan, D. C. Z., Ma, E. Y. H., & Zhang, F. Y. A. (2018). Development and validation of a visual image analysis for monitoring the body size of sheep. *Journal of Applied Animal Research*, 46(1), 1004-1015.
- Zhang, Y., Li, Z., & Liu, X. (2023). Application of Deep Learning Algorithms for Live Weight Prediction in Beef Cattle. *Livestock Science*. Bu çalışma, derin öğrenme algoritmalarını kullanarak büyükbaş hayvanlarda büyüme hızının tahmin edilmesini ele almaktadır.
- Zhang, A. L., Wu, B. P., Wuyun, C. T., Jiang, D. X., Xuan, E. C., & Ma, F. Y. (2018). Algorithm of sheep body dimension measurement and its applications based on image analysis. *Computers and Electronics in Agriculture*, 153, 33-45.
- Zülkadir, U., Şahin, Ö., AYTEKİN, İ., & Boztepe, S. (2008). Malya kuzularda canlı ağırlık ve bazı vücut ölçülerinin tekrarlanma dereceleri. *Selcuk journal of agriculture and food sciences*, 22(45), 89-93.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyad, Ad

ÇELİK, Abbas

Web sayfası

(Research Gate, Academia, vs.)

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Lisans	Dicle Üniversitesi Ziraat Fakültesi	2016
Lise	Şehitlik Lisesi	2015

İş Denevimi

Dönem (Yıl)	Şirket, Kurum	Görev
2023-2024	PROYEM A.Ş.	Ziraat Mühendisi
2024-	Harran İlçe Tarım Müd	Ziraat Mühendisi

Yabancı Dil

İngilizce

Yayınlar

1. Turan, M., Bülbüller, F., Çelik, A., Akdamar, H. 2023. İnsansız Hava Araçlarının Hayvancılık Yönetiminde Kullanılması. Dicle Üniversitesi I. Uluslararası Fen Bilimleri Lisansüstü Araştırmalar Sempozyumu. 19-20 Ekim. 2023. Diyarbakır/Türkiye
- 2.
- 3.
- 4.

Özel İlgiler

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Abbas ÇELİK		
Öğrenci No	21802014		
Ana Bilim Dalı	Zootekni		
Program Türü	Proje ☐	Yüksek Lisans ☒	Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. H. Deniz ŞİRELİ		
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. Cihan ÇAKMAKÇI		
Tez Başlığı	Kilis Keçilerinde Görüntü İşleme ve Makine Öğrenimi ile Canlı Ağırlık Tahmini		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Sonrası		
Sayfa Sayısı	60		
Raporlama Tarihi	25.04.2025		
Benzerlik Oranı (%)	9		

Yukarıda bilgileri verilen tez çalışmamın toplam 60 sayfalık kısmına ilişkin, 25/04/2025 tarihinde şahsım/tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı % 9 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

- ☐ Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası Özet/Abstract) Dahil
☒ Kaynaklar hariç
☐ Alıntılar hariç/dâhil
☐ Diğer (Açıklayınız)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Tez benzerlik oranı üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir, gereğini arz ederim.

Öğrencinin Adı, Soyadı: Abbas ÇELİK

Tarih: 02/04/ .2025

İmza:

Danışman. Adı, Soyadı: Doç. Dr. H. Deniz ŞİRELİ

İmza:

Tarih:02/04/ .2025

Ana Bilim Dalı Başkanı Adı, Soyadı: Prof. Dr. Nihat TEKEL

İmza:

Tarih:02/04/ .2025