



ATATURK
UNIVERSITY
PUBLICATIONS

Journal of Animal Science and Economics

Official journal of Atatürk University Faculty of Agriculture, Department of Animal Science

Formerly: Palandöken Journal of Animal Science, Technology and Economics

Volume 4 • Issue 2 • July 2025

EISSN 2980-1486

dergipark.org.tr/tr/pub/jase

Journal of Animal Science and Economics

Owner

Önder ÇALMAŞUR
Dean of Faculty of Agriculture, Atatürk University, Erzurum, Türkiye

Editor in Chief

Bahri BAYRAM
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: bbayram@atauni.edu.tr

Associate Editors

Adem AKSOY
Atatürk University, Faculty of Agriculture,
Department of Agricultural Economics,
Erzurum, Türkiye
E-mail: aaksoy@atauni.edu.tr

Adem KAYA
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: akaya@atauni.edu.tr

Statistical Editor

Memiş ÖZDEMİR
Animal Science, Atatürk University,
Faculty of Agriculture, Department of
Animal Science, Erzurum, Türkiye
E-mail: ozdemirm@atauni.edu.tr

Foreign Language Editors

Veysel Fatih ÖZDEMİR
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: veysel.ozdemir@atauni.edu.tr

Layout Editor

Doğan TÜRKYILMAZ
Atatürk University, Faculty of Agriculture,
Department of Animal Science,
Erzurum, Türkiye
E-mail: dogan.turkyilmaz@atauni.edu.tr

Advisory Board

Ayhan CEYHAN
Niğde Ömer Halisdemir University,
Faculty of Agricultural Sciences and
Technologies, Niğde, Türkiye
E-mail: aceyhan@ohu.edu.tr

Erkan PEHLİVAN
Ankara University, Faculty of Agriculture,
Department of Animal Science, Ankara,
Türkiye
E-mail: pehlivan@agri.ankara.edu.tr

Feyzi UĞUR
Çanakkale Onsekiz Mart University,
Faculty of Agriculture, Department of
Animal Science, Çanakkale, Türkiye
E-mail: fugur@comu.edu.tr

Mete YANAR
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: mtyanar@gmail.com

Mehmet Sait EKİNCİ
Kahramanmaraş Sütçü İmam University,
Department of Animal Science,
Kahramanmaraş, Türkiye
E-mail: sekinci@ksu.edu.tr

Muazzez Cömert ACAR
Ege University, Faculty of Agriculture,
Department of Animal Science, İzmir,
Türkiye
E-mail: muazzez.comert@ege.edu.tr

Muhlis MACİT
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: mmacit@atauni.edu.tr

Nurinisa ESENBÜĞA
Atatürk University, Faculty of Agriculture,
Department of Animal Science, Erzurum,
Türkiye
E-mail: esenbuga@atauni.edu.tr

Tugay AYAŞAN
Osmaniye Korkut Ata University, Osmaniye,
Türkiye
E-mail: tugayayasan@osmaniye.edu.tr

Uğur ZÜLKADİR
Selçuk University, Faculty of Agriculture,
Department of Animal Science, Konya,
Türkiye
E-mail: uzulkad@selcuk.edu.tr

Vincenzo Tufarelli
University of Bari Aldo Moro, Section of
Veterinary Science and Animal Production,
Department of Precision and Regenerative
Medicine and Jonian Area, Valenzano, Italy
E-mail: vincenzo.tufarelli@uniba.it

Severino Pinto
Leipzig University, Faculty of Veterinary
Medicine, Leipzig, Germany.
E-mail: spinto@atb-potsdam.de

Contact

Publisher: Atatürk University
Address: Atatürk University
Yakutiye, Erzurum, Türkiye

AIMS AND SCOPE

Journal of Animal Science and Economics is a scientific, open access, online-only periodical published in accordance with independent, unbiased, and double-blinded peer-review principles. The journal is an official publication of the Atatürk University Faculty of Agriculture, Department of Animal Science and published biannually in February and July. The publication languages of the journal are Turkish and English.

Journal of Animal Science and Economics aims to contribute to the literature by publishing manuscripts at the highest scientific level in animal science and technology, as well as livestock economics. The journal publishes original articles and reviews that are prepared in accordance with ethical guidelines. The scope of the journal includes but not limited to relevant to the topics of animal breeding and improvement, feeds and animal nutrition, biometrics and genetics, beekeeping, feed technology, feed additives, fishery, animal behaviors, animal welfare, animal and meadow-pasture relationship, organization in animal husbandry, smart agricultural practices in livestock, farm tourism, reproductive biology and control, organic livestock production, animal biotechnology, livestock economy, animal health.

The target audience of the journal includes researchers and specialists who are interested or working in all fields in the journal's scope.

Journal of Animal Science and Economics currently indexed in EBSCO, CAB Abstract, ERIH Plus, and Gale Cengage.

The editorial and publication processes of the journal are shaped in accordance with the guidelines of the Council of Science Editors (CSE), Committee on Publication Ethics (COPE), European Association of Science Editors (EASE), and National Information Standards Organization (NISO). The journal is in conformity with the Principles of Transparency and Best Practice in Scholarly Publishing (doaj.org/bestpractice).

All expenses of the journal are covered by the Atatürk University. Processing and publication are free of charge with the journal. No fees are requested from the authors at any point throughout the evaluation and publication process. All manuscripts must be submitted via the online submission system, which is available at <https://dergipark.org.tr/tr/pub/jase>. The journal guidelines, technical information, and the required forms are available on the journal's web page.

Disclaimer

Statements or opinions expressed in the manuscripts published in the journal reflect the views of the author(s) and not the opinions of the editors, editorial board, and/or publisher; the editors, editorial board, and publisher disclaim any responsibility or liability for such materials.

Open Access Statement

Journal of Animal Science and Economics is an open access publication, and the journal's publication model is based on Budapest Access Initiative (BOAI) declaration. All published content is available online, free of charge at <https://dergipark.org.tr/tr/pub/jase>. Authors retain the copyright of their published work in the Journal of Animal Science and Economics. The journal's content is licensed under a Creative Commons Attribution-NonCommercial (CC BY-NC) 4.0 International License which permits third parties to share and adapt the content for non-commercial purposes by giving the appropriate credit to the original work.

From January 2023 onwards, content is licensed under a Creative Commons CC BY-NC 4.0 license. The journal's back content was published under a traditional copyright license however the archive is available for free access.

You can find the current version of the Instructions to Author at <https://dergipark.org.tr/en/pub/jase/writing-rules>

Editor in Chief: Bahri BAYRAM

Address: Atatürk University, Erzurum

E-mail: bbayram@atauni.edu.tr

Phone: +90 442 231 2577

Publisher: Atatürk University

Address: Atatürk University, Yakutiye, Erzurum, Türkiye

E-mail: ataunijournals@atauni.edu.tr

CONTENTS

RESEARCH ARTICLES

- 54 **Application of New Dietary Bentonite Clay as an Aquaculture Feed Additive**
Yeni Diyet Bentonit Kilinin Su Ürünleri Yetiştiriciliği Yem Katkı Maddesi Olarak Uygulanması
Tornike LASHKARASHVILI, Amros CHKUASELI
- 64 **Application of Artificial Intelligence Technologies in Livestock Management**
Hayvancılıkta Yapay Zekâ Teknolojilerinin Uygulanması
Hatice DİLAVER, Kamil Fatih DİLAVER
- 75 **Türkiye Koyun Eti Üretiminin 2023-2027 Dönemi Öngörülleri**
Forecasts for Sheep Meat Production in Türkiye for the 2023–2027 Period
Ahmet Semih UZUNDUMLU, Gülsüm DEMİR
- 81 **Aspir Küspesine (*Carthamus tinctorius*) yem katkı maddesi olarak Çınar Yaprağının (*Platanus orientalis* L.) ilavesinin; In Vitro Gaz Üretimi ve Sindirilebilirlik Parametreleri Üzerine Etkisi**
*The Effect of Supplementing Safflower Meal (*Carthamus tinctorius*) with Plane Tree Leaf (*Platanus orientalis* L.) as a Feed Additive on In Vitro Gas Production and Digestibility Parameters*
Atilla BAŞER, Ali KAYA, Tuğba BAKIR, Bilal SELÇUK

REVIEW ARTICLE

- 88 **Erzurum İli Yakutiye İlçesi Mahallelerinde Küçükbaş Hayvancılığın Son Dört Yıldaki Değişimi**
Changes in Small Ruminant Farming in the Neighborhoods of Yakutiye District of Erzurum Province in the Last Four Years
Hasan ÖZSAYGIN

Application of New Dietary Bentonite Clay as an Aquaculture Feed Additive

Yeni Diyet Bentonit Kilinin Su Ürünleri Yetiştiriciliği Yem Katkı Maddesi Olarak Uygulanması

ABSTRACT

This study evaluated the effectiveness of Georgian bentonite clay as a natural mycotoxin adsorbent in rainbow trout (*Oncorhynchus mykiss*) diets. The experiment involved 100 fish per group, fed diets without adsorbent (Control 1; C1), with 0.1% synthetic adsorbent (Control 2; C2), and with bentonite at 0.1% (Test 1; T1), 0.15% (Test 2; T2), and 0.2% (Test 3; T3) for 24 weeks. Weight gain was highest in T3 (254 ± 15.8 g) and T2 (244.92 ± 14.47 g), significantly exceeding C1 (143.39 ± 9.51 g) and C2 (187.67 ± 12.1 g) ($p < .05$). Survival rates were 97% in T2 and T3, but differences among groups were not statistically significant ($p > .05$). Feed conversion ratios (FCR) were lowest in T2 and T3 (0.9–0.92), indicating superior feed efficiency compared to C1 (1.3) and C2 (1.1). High-performance liquid chromatography (HPLC) analysis revealed that bentonite effectively adsorbed mycotoxins, with T2 and T3 removing 83-90% of aflatoxin B1 and 12.5-14% of T2/HT2. Chemical composition analysis showed significantly higher protein (18.3-18.5%) and fat content (7.8%) in T2 and T3 compared to C1 (16.5% protein, 6% fat) and C2 (17.2% protein, 6.8% fat) ($p < .05$). These findings suggest that Georgian bentonite clay enhances fish growth, feed efficiency, and nutritional quality while effectively mitigating mycotoxin contamination. This natural adsorbent offers a promising alternative for improving aquaculture sustainability and fish health.

Keywords: Adsorbent, Fish, Mycotoxin binders, Nutrition

Tornike LASHKARASHVILI¹ 

Amros CHKUASELI¹ 

¹ Agricultural University of Georgia,
Animal Husbandry and Feed
Production Institute, Tbilisi, Georgia



Geliş Tarihi/Received 21.03.2025
Kabul Tarihi/Accepted 06.05.2025
Yayın Tarihi/Publication Date 24.07.2025

Sorumlu Yazar/Corresponding author:
Tornike LASHKARASHVILI

E-mail: t.lashkarashvili@agruni.edu.ge

Cite this article: Lashkarashvili, T. & Chkuaseli, A. (2025). Application of New Dietary Bentonite Clay as an Aquaculture Feed Additive. *Journal of Animal Science and Economics*, 4(2), 54-63.



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Introduction

The global consumption of fish and seafood is increasing yearly, as they are rich sources of protein. Statistically, 65-70% of the total protein consumed by humans comes from farm animals and poultry (including milk, eggs, and meat), while the remaining 30-35% is derived from fish and other seafood (Guillen et al., 2019). Over the past 50 years, global fish production has more than tripled. Fifty years ago, total fish production was around 60 million tons, with almost all of it coming from capture fisheries. Today, capture fisheries contribute 91 million tons, while aquaculture has grown to 94 million tons. In total, global fish production now reaches 186 million tons, rising from 9 kilograms per capita to 21 kilograms, and is projected to reach 30 kilograms per capita in the next decade (FAO, 2020). However, approximately 60-65% of fish farming costs stem from feeding, with Georgian fish farmers relying on expensive imported fish feed (FAO, 2024).

Today, fish feed enterprises face the challenge of producing complete, high-quality feed at reduced prices by utilizing cheaper raw materials (such as cereals or byproducts from various industries). The quality of these low-cost raw materials is a concern, as about 50-55% are often contaminated with mycotoxins—metabolic products of microscopic fungi (Saini et al., 2021).

Mycotoxins pose significant risks to farm animals, poultry, and fish due to their pronounced toxicity (Gruber-Dorninger et al., 2020). Even in small quantities, they can diffuse into feed raw materials and aquaculture feed. To date, around 300 types of mycotoxins have been isolated from 450 different fungal species, with up to 20 considered particularly dangerous due to their cancer-promoting properties in humans (Mahato et al., 2022).

Consequently, fish feed companies must find affordable methods to combat mycotoxins, ensuring the safety and quality of their products while remaining competitive with imported alternatives. Recent research has focused on the effectiveness of mycotoxin adsorbents, with numerous options available on the global market. In Georgia, many of these are synthetic, imported, and costly. One natural solution is aluminosilicate clays—specifically bentonites—which are widely used globally in the diets of agricultural animals and poultry (Kihal et al., 2022). These clays can adsorb mycotoxins, preventing their adsorption into the bloodstream and facilitating their excretion (Oliveira et al., 2023). Georgia's geological history, marked by numerous volcanic eruptions, has endowed the country with various clay deposits, including the essential bentonite clay deposit known as Georgian clay, in the Ozurgeti District (Western Georgia). Although the use of this bentonite in poultry feed for mycotoxin adsorption has been studied (Chkuaseli et al., 2016), the results indicated that incorporating Georgian bentonite clay into poultry diets led to several beneficial outcomes: improved poultry physiological condition and livability with 2-4% enhanced feed adsorption and FCR with 0.08%-0.12% reduced negative effects of mycotoxins toxicity, and increased daily weight gain with 7-9% improved meat safety. These findings suggest that Georgian bentonite clay serves as an effective mycotoxin adsorbent, positively influencing the growth, health, and safety of poultry meat. However, its application in aquaculture remains unexplored. This recent research has focused on evaluating the efficacy of locally produced bentonite clay for detoxifying mycotoxins at a comparatively low price.

The purpose of this study is to evaluate alternative feed additives using low-quality raw materials to reduce dependency on expensive traditional ingredients, while maintaining the growth performance and health of farmed trout. The significance of this research lies in its potential to reduce feed costs in trout farming, thus improving the economic efficiency of fish production and enhancing the safety of the final product (trout meat). Increased access to affordable aquaculture products can elevate community well-being. We believe the results will contribute to the sustainable development of the aquaculture industry, optimize resource (low-quality raw materials in feed) use, promote environmental awareness, and address One Health issues.

Method

Collection and Analysis of Bentonite Clay

Bentonite clay from the Guria region (Georgia) was collected and analyzed at the Alexander Tvalchrelidze Institute of Mineral Resources of the Caucasus using chemical research methods.

An X-ray phase, silicate and physical-chemical studies were conducted at the Agricultural University of Georgia, Tbilisi

State University, and the Institute of Mineral Materials of the Caucasus. The montmorillonite structure and formula were established using an X-ray phase test performed with the dual-polarization optical hybrids (DPOH-1.5) Kyla (part of the iXblue brand) device, model COH28-X (Chkuaseli et al., 2016).

Mycotoxin Safety and Toxicity Analysis

Chemical composition analysis

To determine the safety and potential toxic effects of Georgian bentonite clay in fish feed, the following analyses were conducted: chemical composition analysis: X-ray phase analysis, silicate tests, and physical-chemical studies confirmed by Chkuaseli et al., 2016, that Georgian bentonite clay is primarily composed of montmorillonite, making it suitable for mycotoxin binding.

Toxicity studies and mycotoxin levels in feed ingredients

In this context, fish biochemical blood tests and fish growth (daily weight gain), feed conversion, and daily survival data were monitored (Miller, 2020; Pereira, 2021). Raw materials and complete feed were tested for mycotoxins (aflatoxin B1 and trichothecenes T2/HT2 toxins). The analysis was conducted in the accredited veterinary laboratory of Chirina Ltd., using express methods on the Aokin fluorescence polarimeter (Sullivan, 2021). The mycotoxin content in feed ingredients was measured, ensuring that contamination levels did not exceed maximum allowable limits. The control and test group fish were provided with complete feed contaminated with mycotoxins (aflatoxin and T2 toxins). The contamination in this experiment was induced by the intentional addition of these mycotoxins (aflatoxin and T2 toxins) (Bøhn, 2020). Due to the fact that the raw materials of the feed are practically always contaminated with mycotoxins (sometimes more, sometimes less) in our region, we did not consider it necessary to provide any control group with feed free of mycotoxins. The concentration of these mycotoxins in the feed would have been carefully controlled and calibrated to ensure that the levels were appropriate for testing the effects on the fish. The content of mycotoxins (aflatoxin B1 and trichothecenes T2/HT2) in the fish feed ingredients from the research groups was assessed.

The results indicated the following levels of aflatoxin B1: soybean meal contained 118 ppb (micrograms), wheat had 16.75 ppb, and sunflower meal showed 9.9 ppb. For trichothecenes T2/HT2: sunflower meal had 450 ppb, soybean meal had 12.75 ppb, and wheat contained 68.02 ppb. Corn was used in minimal amounts in the diet; therefore, there was no need to test it at this stage. The results showed that the levels of T2/HT2 trichothecenes in sunflower and soybean meals were close to the maximum limit, whereas the content of aflatoxin and trichothecenes in the raw materials did not exceed the maximum allowable limits (Gruber-Dorninger et al., 2020).

However, it is important to note that these mycotoxins can accumulate in the fish's body over time (Pestka et al., 2019).

Experimental Design

Experimental diets

The control and test group fish were provided with complete feed contaminated with mycotoxins (aflatoxin and T2 toxins). The contamination in this experiment was induced by the intentional addition of these mycotoxins (aflatoxin and T2 toxins). For this trial, we used 4 mm size floating feed.

adversely affecting feed quality or fish health, leading to improved growth performance (Gruber-Dorninger et al., 2020). Furthermore, research by Pestka (2019) and Jian (2020) suggests that bentonite clay at similar concentrations not only mitigates mycotoxin toxicity but also enhances feed conversion efficiency in fish. In poultry, studies have confirmed that bentonite clay effectively binds aflatoxins and reduces their harmful effects (Van Der Merwe et al., 2018), with similar outcomes observed in aquatic species (Mohd Zain et al., 2021).

The percentage composition of experimental diets supplemented with different levels of mycotoxin adsorbents is shown in Table 1.

Table 1.

Percentage and Proximate Composition of the Experimental Diets Supplemented with Different Levels of Adsorbents (% in 100 Kilograms of Extruded Feed)

Ingredient Composition in Feed (%)	Experimental Groups				
	Control 1	Control 2	Test 1	Test 2	Test 3
Wheat	20	19.9	19.9	19.85	19.8
Meat Meal	20	20	20	20	20
Fish Meal	15	15	15	15	15
Soybean Meal	12	12	12	12	12
Sunflower Meal	13	13	13	13	13
Poultry Blood Meal	7	7	7	7	7
Fish Oil	5	5	5	5	5
Fish Premix (vitamins, minerals, amino acids)	8	8	8	8	8
Georgian Bentonite Clay	-	-	0.1	0.15	0.2
Synthetic Mycotoxin Adsorbent	-	0.1	-	-	-
Total (%)	100	100	100	100	100

Table 2.

Percentage Nutritional Composition of Experimental Diets Supplemented with Different Levels of Adsorbents (% in 100 Kilograms of Extruded Feed)

Parameters	%
Dry Matter (%)	93.8
Crude Protein (% D.M.)	42
Crude Fat (% DM.)	20
Crude Fiber (% D.M.)	1.3
Ashes (%)	8.5
Starch (%)	14.5
Lysine	3.2
Methionine + Cystine	1.3
Threonine	1.5
Methionine	0.78
Gross Energy (kJ/g)	22.5

The selection of additive levels (0.1%, 0.15%, and 0.2%) for bentonite clay in the experimental diets was based on prior studies and literature where similar mycotoxin adsorbents have been tested in poultry and fish feed (Bøhn et al., 2020). These concentrations were chosen because research has shown that they are effective in reducing mycotoxin concentrations without

Nutritional composition of experimental diets

The daily average weight gain is calculated by dividing the monthly weight by the number of days in each month; feed consumption per kg of fish weight gain (FCR) is calculated by dividing the amount of feed consumed by the amount of weight gained by the animals. Steps to calculate FCR: determine total feed consumed; measure the total amount of feed provided to the fish during the study period.

Fish and experimental setup

Rainbow trout (*Salmonidae* subspecies *Oncorhynchus mykiss*) fry (n=2,500) were obtained, with initial weights ranging from 16-21g. Test ponds were allocated at an aquaculture farm in Shida Kartli. Five experimental groups

were established: The study included five replicate sections per group, with 100 fish per section, for a total of 500 fish per group (Table 3).

The preparation and condition of the fish farm for conducting the experiment were assessed, including

Table 3.

Experimental Design with Replicates and Mycotoxin Adsorbent Treatments

Group Number	Group Description	Mycotoxin Treatment	Number of Fish per Section	Number of Replicates (Sections)	Total Number of Fish per Group
1	Control 1 (C1)	No adsorbent	100	5	500
2	Control 2 (C2)	Synthetic adsorbent (0.1%)	100	5	500
3	Test 1 (T1)	Georgian bentonite clay 0.1%	100	5	500
4	Test 2 (T2)	Georgian bentonite clay 0.15%	100	5	500
5	Test 3 (T3)	Georgian bentonite clay 0.2%	100	5	500

Experimental conditions and fish management

The trial duration was 24 weeks (180 days). During the first 70 days, trout were hand-fed to satiation three times daily, with the feeding frequency reduced to twice daily for the remaining period. Monthly weight monitoring was conducted following a 24-hour fasting period. Mortality and clinical responses were recorded daily. Water quality was assessed weekly to ensure optimal fish health, with the following parameters maintained: temperature, dissolved oxygen (mg/L), pH, and ammonia (NH₃) mg/L (Smith et al., 2019).

All procedures were reviewed and approved by the Animal Care and Use Committee of the Agricultural University of Georgia (Institutional Animal Care and Use Committee [IACUC]).

Data Collection and Analysis

Growth and feed efficiency

The research involved individual weighing of fish at regular intervals (3, 4, 5, and 6 months) and calculating the Feed Conversion Ratio (FCR) as the ratio of total feed consumed to total weight gain. The survival rate was calculated using the formula: (Surviving fish / Initial fish) × 100 (Seppälä et al., 2022).

Feces collection and mycotoxin analysis

Feces were collected monthly from tanks using fine mesh nets, one from each group at the same time, and stored. At the end of the experiment, samples were analyzed for mycotoxin content (aflatoxin B1 and trichothecene T2/HT2) using high-performance liquid chromatography (HPLC) with fluorescence detection (FLD) (Sulyok et al., 2020).

Blood sample analysis

Blood samples were collected from 15 fish per group at the end of the experiment. Hematological parameters, including hemoglobin, erythrocytes, leukocytes, and thrombocytes, were determined using the following methods and

biosecurity norms and the operation of portable equipment (scale, oximeter, pH meter, and mineralization meter). Water parameters, trout health, and productivity were evaluated using zootechnical methods (Costas, 2021; Pulcini, 2020).

equipment: HemoCue Hb-201+ hemoglobinometer (for hemoglobin concentration), Neubauer Chamber (for erythrocyte and leukocyte counts), and automated hematology analyzers (e.g., Sysmex, Coulter Counter) for erythrocyte, leukocyte, and thrombocyte counts (Hossain et al., 2020; Nash, 2021).

Biochemical parameters such as AST, ALT, GGT, bilirubin, total protein, and creatinine levels were determined using the Humalyzer Primus biochemical analyzer (Zhou, 2020).

Fish meat quality analysis

Proximate Composition: Moisture content was determined through oven drying, protein by the Kjeldahl method, fat via Soxhlet extraction, and ash by incineration at 550°C. (Central Inland Fisheries Research Institute [CIFRI] Guidelines, 2022; FAO's Laboratory Manual, 2021).

Organoleptic Properties: Aroma, flavor, and tenderness were assessed using cooked samples (three fish from each group were boiled and three were fried). A trained panel of sensory experts, experienced in food quality evaluation, conducted the tasting. The tasting procedure was carried out in a controlled environment to ensure unbiased evaluations. A double-blind method was employed to eliminate bias, with panelists unaware of whether the samples came from control or experimental groups. Samples were presented in random order with coded labels to prevent preconceived notions from influencing the evaluation. Each sample of trout meat (boiled and fried) was rated on a 1-point or 5-point hedonic scale for aroma, flavor, tenderness, and overall impression (Civille et al., 2024).

All panelists were selected based on their expertise and previous experience in sensory analysis and food quality assessments. Prior to conducting the sensory evaluation, the panelists underwent training sessions to ensure consistency and reliability in their evaluations.

Mycotoxin Analysis: To ensure food safety, meat samples from each group were analyzed for potential mycotoxin residues. The levels of aflatoxin B1 and trichothecene (T2/HT2) were determined using enzyme-linked immunosorbent assay (ELISA) kits specifically designed for detecting these mycotoxins in animal products (Abcam, 2023; ProGnosis Biotech, 2023). In parallel with the organoleptic tasting, additional analyses were performed to ensure that meat from groups fed high mycotoxin content did not pose a health risk to consumers (Mago et al., 2020).

Statistical Analysis

All data collected were subjected to one-way analysis of variance (ANOVA). Significant differences between mean values were determined by Duncan's multiple range tests ($p < .05$) using a statistical package for social sciences (SPSS). Values were expressed as means ($\pm$ S.E).

Results

Field Study Findings, Results of Production Indicators

Table 4.

Growth Performance of Fish Under Different Experimental Conditions, Including Effects of Aflatoxin B1 (AFB1), Trichothecene T2/HT2, and Toxin Binders.

Indicators (Body mass)	Unit	Groups				
		Control 1	Control 2	Test 1	Test 2	Test 3
1 st Month	g	18.97 $\pm$ 1.01	16.5 $\pm$ 0.45	19.12 $\pm$ 0.88 *	19.23 $\pm$ 0.85*	18.55 $\pm$ 0.98
3 rd Month	g	78.96 $\pm$ 6.27	97.35 $\pm$ 5.32	113.14 $\pm$ 6.31	116.59 $\pm$ 7.08	122.82 $\pm$ 7.40*
4 th Month	g	95.22 $\pm$ 10.05	121.61 $\pm$ 8.91	142.56 $\pm$ 5.85	151.91 $\pm$ 10.30	155.72 $\pm$ 12.14
5 th Month	g	125 $\pm$ 10.06*	158.34 $\pm$ 13.99	200.95 $\pm$ 15.1	206.9 $\pm$ 15.14	212.34 $\pm$ 15.93
6 th Month	g	162.36 $\pm$ 14.15	204.17 $\pm$ 16.48	256.15 $\pm$ 18.14	264.15 $\pm$ 18.35	272.59 $\pm$ 17.49
Absolute Weight Gain (0-6 months)	g	143.39 $\pm$ 9.51	187.67 $\pm$ 12.1	237 $\pm$ 14.7*	244.92 $\pm$ 14.47	254 $\pm$ 15.8
Daily Weight Gain (0-6 months)	g	0.8 $\pm$ 0.06	1.04 $\pm$ 0.07	1.32 $\pm$ 0.08	1.36 $\pm$ 0.08	1.41 $\pm$ 0.09

*Mean values without superscript are significantly different ($p < .05$).

The test groups (T2 and T3) showed superior growth, with T3 having the highest growth and absolute weight gain. Significant improvements were noted in T2 and T3, likely due to the inclusion of Georgian bentonite clay (0.15% and 0.2%), which mitigated the negative effects of toxins (aflatoxins and Trichothecene) (Table 4).

Survival and Feed Conversion Rate Efficiency Findings

The feed conversion rate (FCR) and survival percentage were analyzed across all experimental groups: C1 had the highest FCR (1.3 $\pm$ 12.88), indicating lower efficiency in feed utilization. C2 showed improvement (1.1 $\pm$ 13.34). Among the test groups, T3 (0.9 $\pm$ 14.25) had the lowest FCR ($p < .01$), followed by T2 (0.92 $\pm$ 13.31) and T1 (1 $\pm$ 14.7), suggesting improved feed efficiency (Table 5). Survival rates were

According to Table 4, the live weight of fish at the beginning of the experiment is the same in all five groups and ranges from 16.5 to 19.2 g. This figure is an indicator of the high uniformity of the fish fry placed in the experiment. The fish groups demonstrated significant growth over the 24-week period (180 days), with the highest weight observed in the T3 group (272.59 $\pm$ 17.49) ($p < .01$) and the lowest in C1 (162.36 $\pm$ 14.15). Fish in the test groups (T1, T2, T3) showed better growth rates compared to the control groups (C1 and C2) ($p < .01$). At 24 weeks, T3 showed the highest absolute weight gain (254 $\pm$ 15.8), 77% higher than C1 (Table 4). The highest daily weight gain was also recorded in T3 (1.41g $\pm$ 0.09) ($p \geq .05$), followed by T2 and T1 (Table 4), indicating improved growth efficiency due to the addition of Georgian bentonite clay.

The coefficient of variation (CV) values ranged between 4.4% and 10%, indicating moderate variability in growth trends (Sadek et al., 2004). Statistical comparisons suggest significant improvements in the T2 and T3 groups, likely due to the inclusion of Georgian bentonite clay (0.15% and 0.2% respectively), which may have mitigated the negative effects of aflatoxins and trichothecene toxins on fish growth (Table 4).

highest in T2 and T3 (both 97%), followed by T1 (95%). Control groups had lower survival rates, with C1 at 87% and C2 at 92% (Table 5).

Table 5.

Effects of Aflatoxin B1 (AFB1), Trichothecene T2/HT2, and Toxin Binders on Survival and Feed Conversion Rate (FCR) Efficiency Indicators

Indicators	Groups				
	Control 1	Control 2	Test 1	Test 2	Test 3
Feed Conversion Rate (FCR)	1.3 $\pm$ 0.23	1.1 $\pm$ 0.20	1 $\pm$ 0.17*	0.92 $\pm$ 0.15	0.9 $\pm$ 0.18 *
Survival %	87 $\pm$ 1.23	92 $\pm$ 1.20	95 $\pm$ 1.19*	97 $\pm$ 1.16	97 $\pm$ 1.18

*Mean values without superscript are significantly different ($p < .05$).

These findings indicate that the test groups with Georgian bentonite clay (0.15 and 0.2%) demonstrated better feed utilization efficiency and higher survival rates compared to the control groups, reinforcing the positive impact of toxin binders in aquaculture.

Mycotoxin adsorption efficiency, fish health status, organoleptic and physical indicators, and comparison of the results and efficiency of trout production.

An analysis of the fish feces from both the test and control groups was conducted. The fish feces from the research groups were analyzed for the content of mycotoxins (trichothecene T2/HT2 and aflatoxin B1). The study revealed significant binding of these mycotoxins in the T2 and T3 test groups, as confirmed by the amounts of aflatoxin B1 and trichothecene T2/HT2 detected in the feces. The highest values were observed in the group T2 (B1 = 120.5 ppb / T2/HT2 = 66.3 ppb) (Table 6) and the group T3 (B1 = 130 ppb / T2/HT2 = 74.3 ppb) ($p < .05$), followed by the group T1 (B1 = 110.6 ppb / T2/HT2 = 53.3 ppb), and the control group C2 (B1 = 98.5 ppb / T2/HT2 = 37.8 ppb) (Table 6).

Table 6.
The Amount of Aflatoxin B1 and Trichothecene T2/HT2 Adsorbed Levels (binding) Detected in Fish Feces (ppb)

Groups	Aflatoxin B1 (ppb)	Trichothecenes T2/HT2 (ppb)
Control 1 (Without Adsorbent)	0	0
Control 2	98.5±1.58*	37.8±0.88
Test 1 (0.1% Bentonite)	110.6±0.93	53.3±1.99
Test 2 (0.15% Bentonite)	120.5±1.22	66.3±2.00
Test 3 (0.2% Bentonite)	130±1.75	74.3±1.88

*Mean values without superscript are significant different ($p < .05$).

In the test groups T2 with 0.15% and T3 group 0.2% Georgian bentonite clay, the adsorption rate of aflatoxin B1

reached 83-90%, while the adsorption efficiency for T2/HT2 mycotoxins was lower, at only 12.5-14%. In the T1 group, the adsorption rate for B1 was 76.4%, with T2/HT2 adsorption remaining low at 10%. The group C2 exhibited significantly lower adsorption rates ($p < .05$), with B1 at 68.1% and T2/HT2 at 7.1% (Table 7).

Table 7.
Adsorption Rate (%) Efficiency of Aflatoxin B1 and Trichothecene T2/HT2 in Feces

Groups	Aflatoxin B1 Adsorption Rate (%)	Trichothecene T2/HT2 Adsorption Rate (%)
Control 1 (Without Adsorbent)	No adsorption	No adsorption
Control 2	68.1±1.22	7.1±2.18*
Test 1 (0.1% Bentonite)	76.4±2.10	10±2.00
Test 2 (0.15% Bentonite)	83±1.08	12.5±0.99
Test 3 (0.2% Bentonite)	90±2.03	14±1.11

*Mean values without superscript are significantly different ($p < .05$).

General and biochemical analyses of blood showed that the levels of hemoglobin and erythrocytes in all test groups were higher compared to the control group ($p < .05$), with hemoglobin levels increasing by 10-26% and erythrocyte counts by 6-12%. In the T3 test group (with a 0.2% additive), the increases were particularly notable (Table 8). The total protein content in the blood serum was below the physiological norm in the control group at 34 g/l. In contrast, the experimental groups showed a 38-47% higher protein content ($p < .05$), ranging from 47 to 50 g/l (Table 9). Thus, the use of Georgian bentonite clay as a mycotoxin adsorbent in trout feed positively affected both general and biochemical blood indicators.

Table 8.
Effects of Aflatoxin B1 (AFB1), Trichothecenes T2/HT2, and Toxin Binders on Hematological Values (%) in Fish.

Groups	Hemoglobin g/l	Erythrocytes (10^{12})	Hematocrit (%)	Platelets 1000 mcg/L	Lymphocytes (%)	Eosinophils (%)
Control 1	60±5.86	1.0±0.1	18±2.29	147±9.70	62±0.01	1.0±0.03
Control 2	77±6.67	1.6±0.18*	26±3.02	170±10.30	78±0.05	5.0±0.05
Test 1 (0.1% Bentonite)	80±5.50	1.7±0.30	28±2.03	180±15.09	77±0.05	2.0±0.11
Test 2 (0.15% Bentonite)	85±6.01	1.7±0.17	27±1.99	190±17.08	76±0.15*	5.0±0.13
Test 3 (0.2% Bentonite)	97±7.10	2.0±0.49	30±3.32	200±16.99	75±0.20	4.0±0.10

*Mean values without superscript are significantly different ($p < .05$).

Table 9.*Effects of Aflatoxin B1 (AFB1), Trichothecenes T2/HT2, and Toxin Binders on Blood Metabolites of Fish.*

Groups	Alanine Aminotransferase U/l	Aspartate Aminotransferase U/l	Total protein g/l	Albumin g/l	Creatinine mg/dl	Glucose mmol/l
Control 1	20±3.35	155±11.2	23±0.25	7±0.03	0.32±0.01	2.2±0.11
Control 2	29±3.90	180±14.00	34±0.13	12±0.04	0.50±0.02	3±0.17
Test 1 (0.1% Bentonite)	32±4.10*	189±12.14	40±0.10	13±0.07	0.52±0.01	3.2±0.20
Test 2 (0.15% Bentonite)	34±5.12	193±15.09	47±0.16	14±0.04 *	0.53±0.04	3.3±0.12
Test 3 (0.2% Bentonite)	34±4.33	198±17.90	50±0.19	16±0.06	0.57±0.03	3.5±0.18

*Mean values without superscript are significantly different ($p<.05$).

As for the results of water quality parameters obtained during the experimental period, no significant difference ($p>.05$) was observed in dissolved oxygen, temperature, pH, and ammonia-nitrogen. Dissolved oxygen ranged from 6.2 ± 1 mg/l – 6.46 ± 0.71 mg/l, pH ranged from 6.6 ± 0.99 – 7 ± 0.68 , temperature ranged from $13\pm 0.79^\circ\text{C}$ – $16\pm 0.71^\circ\text{C}$ and ammonia-nitrogen ranged 0.09 ± 0.03 mg/l – 0.01 ± 0.18 mg/l.

Regarding the chemical composition of the fish meat, protein content was highest in the T2 and T3 groups ($p<.05$) at 18.3-18.5%, which was 1.1-1.3% higher ($p<.05$) than the C2 group. The fat content was highest in T2 ($p<.05$) compared to the lower in the C2 (protein (16.5%) and fat content (6%)) was lowest in C1 (Table 10). These differences were statistically significant ($p<.05$), indicating that the inclusion of Georgian bentonite clay improved both protein and fat content in trout meat (Table 10).

There is no direct indication in the study of toxicological reactions or harmful effects caused by the addition of bentonite. In fact, the results suggest that bentonite has beneficial effects on the growth and health of the trout. No signs of toxicity or adverse reactions were reported in terms of fish blood composition or meat quality. On the contrary, the biochemical analyses revealed improved protein content in the fish blood, which was higher in the test groups than in the control group (Table 9). Furthermore, meat quality, including texture, flavor, and fat content, was also enhanced in the test groups. Thus, based on the results, the addition of bentonite in the diet of trout appears to be safe and effective, with no observed toxicological reactions, and it provides a positive impact on fish health and growth. Organoleptic and physical indicators of the meat were assessed through tasting. All

tasting parameters (aroma, flavor, tenderness, and overall impression) were notably superior in trout from the T2 and T3 test groups, both in boiled and fried conditions (Table 11).

Table 10.*Proximate Carcass Composition of Experimental Fish*

Groups	Protein Content (%)	Fat Content (%)	Moisture (%)	Ash (%)
Control 1	16±0.32	6±0.18	72.0±0.16	1.0±0.80
Control 2	17.2±0.18*	6.8±0.07	71.1±0.12	1.2±0.18
Test 1 (0.1% Bentonite)	17.8±0.06	7.1±0.13*	71.6±0.03	1.1±0.12
Test 2 (0.15% Bentonite)	18.3±0.18	7.8±0.06	71.0±0.05*	1.3±0.10
Test 3 (0.2% Bentonite)	18.5±0.19	7.5±0.20	71.5±0.17	1.5±0.22

*Mean values without superscript are significantly different ($p<.05$).**Table 11.***Results of Organoleptic, Physical Indicators, and Taste Properties (boiled and fried conditions) Rating with 1 Being the Least Favorable and 5 Being the Most Favorable.*

Sample Group	Appearance	Flavor	Texture	Taste	Evaluation Average Score
Control 1	3.4	3.3	3.5	3.4	3.4
Control 2	3.7	3.6	3.8	3.9	3.8
Test 1 (0.1% Bentonite)	4	3.8	3.9	4.1	4
Test 2 (0.15% Bentonite)	4.7	4.5	4.8	4.7	4.7
Test 3 (0.2% Bentonite)	5	4.9	5	5	5

5-point hedonic scale, equivalent score: excellent - 5, good - 4, fair - 3, poor - 2, very poor - 1.

Discussion

The aim of this research was to evaluate the effectiveness of Georgian bentonite clay as a natural mycotoxin adsorbent in aquaculture. Previous studies have demonstrated the positive impact of Georgian bentonite clay on mycotoxin adsorption, primarily in poultry feed (Biomin, 2020; Chkuaseli & Khutsishvili-Maisuradze, 2016). The study demonstrates that the inclusion of Georgian bentonite clay at 0.15% to 0.2% in trout feed significantly improves fish growth parameters: The average weight gain and feed conversion ratio (FCR) show a positive correlation with the bentonite clay concentration, indicating that it helps optimize feed utilization. Enhancements in the growth rates of the fish were also observed Abdellaoui et al. (2019) and Enyidi et al. (2020).

The increased growth rates observed in the test groups can be attributed to better nutrient adsorption and improved feed efficiency facilitated by the mycotoxin-binding properties of the bentonite clay (Gruber-Dorninger et al., 2020). The reduced FCR in the test groups further supports the conclusion that the fish are utilizing the feed more effectively, likely due to the reduced toxic impact of mycotoxins on metabolism and digestion. Mycotoxins are known to cause immune system suppression, reduced disease resistance, and poor growth in aquaculture species (Gruber-Dorninger et al., 2020).

Therefore, the ability of Georgian bentonite clay to mitigate the harmful effects of these toxins may explain the improved health outcomes and survival rates seen in the test groups. In addition, the clay's ability to detoxify mycotoxins could result in lower mortality rates and fewer incidences of disease, further enhancing fish welfare. A key highlight of the study is the mycotoxin-binding efficiency of Georgian bentonite clay.

The results show that it was especially effective at adsorbing aflatoxin B1, with a binding rate ranging from 83% to 90% in the test groups. This result is in agreement with that from Oliveira et al. (2023) and Kihal et al. (2022). Aflatoxins are some of the most harmful mycotoxins, and their presence in fish feed can lead to liver damage, immunosuppression, and growth impairment (Oliveira et al., 2023). By reducing the exposure to aflatoxins, bentonite clay can have a significant protective effect on fish health and feed safety. However, the adsorption efficiency for T2/HT2 mycotoxins was lower, which could suggest that different mycotoxin structures or properties influence the efficiency of bentonite clay in binding them. Despite this, the clay still offered a modest improvement in mycotoxin adsorption, with 12.5%–14% binding efficiency. Bentonite's positive impact on African catfish feed was similarly observed (Enyidi et al., 2020).

The study also evaluated the impact of Georgian bentonite clay on the meat quality and sensory properties of the fish. The

test groups fed with bentonite showed significant improvements in chemical composition and taste properties, which were particularly beneficial for the consumer experience and market value of the fish. Meat quality factors like protein content, fat composition, and overall palatability were positively influenced by the addition of bentonite, potentially due to better overall fish health and improved metabolic processes. The enhancement of taste properties suggests that reducing the negative effects of mycotoxins on fish could lead to better quality products for the aquaculture market, where flavor, texture, and nutrient content are noted key factors in consumer choice (Oliveira et al., 2020).

This research points to several important implications for the aquaculture industry. Georgian bentonite clay could be a cost-effective solution to the growing problem of mycotoxin contamination in fish feed, which can affect both fish health and product quality. By incorporating bentonite as an additive in aquafeeds, farmers could:

1. Enhance fish growth and feed conversion while reducing the environmental and economic impacts of poor feed efficiency.
2. Improve fish health by reducing the toxic effects of mycotoxins, leading to higher survival rates and better resilience to diseases. (It has been shown that bentonite possesses detoxifying properties and can help improve immune responses and reduce disease susceptibility in aquaculture, as described by Kolawole et al. (2019).
3. Produce higher-quality fish products with improved taste and chemical composition, making them more appealing to consumers.

In terms of cost-benefit analysis, the use of Georgian bentonite clay could potentially offer long-term savings by reducing the need for expensive mycotoxin remediation technologies, improving feed utilization and lowering disease treatment costs, well-documented by Mendes dos Reis et al. (2024). The potential for cost-effective mycotoxin adsorbents to lower operational costs has also been discussed by Kolawole et al. (2019).

This finding suggests that while Georgian bentonite clay is highly effective against certain types of mycotoxins (like aflatoxins), further optimization may be required to enhance its binding capacity for other mycotoxins like T2/HT2. Additionally, it may be worthwhile to explore combinations of bentonite with other adsorbents to improve the overall mycotoxin-binding spectrum. Kihal et al. (2022) and Kolawole et al. (2019), mentioned similar challenges with the efficiency of bentonite in adsorbing certain types of mycotoxins, particularly T2/HT2.

Further studies could also evaluate the economic feasibility of using bentonite in large-scale aquaculture

operations, considering factors such as costs, availability, and supply chains.

Conclusion and Recommendations

The preliminary and primary experiments on trout indicate that the application of Georgian bentonite clay, a locally produced aluminosilicate bentonite clay, is highly effective for mycotoxin detoxification in trout feed. The addition of Georgian bentonite clay at 0.15-0.2% achieved an aflatoxin B1 adsorption rate of 83-90% and a T2/HT2 mycotoxin adsorption rate of 12.5-14%.

The results of our experiments confirm our hypothesis regarding the efficacy of Georgian bentonite clay for detoxifying certain mycotoxins in fish feed. This suggests that Georgian bentonite clay can be successfully utilized for mycotoxin detoxification in aquaculture.

Based on the results of our research involving Georgian bentonite clay in trout feed, we can conclude that:

1. Locally produced bentonite clay of aluminosilicate origin can effectively detoxify mycotoxins in trout extruded feed when used at proportions of 0.15-0.2%.
2. There will be an increase in the positive dynamics of trout body mass, including both absolute and daily growth +30-35%.
3. Trout feed utilization and conversion efficiency will improve +16-18%.
4. Survival rate will increase +4-5%.
5. There is a possibility of producing a safer final product (fish meat).

Ethics Committee Approval: Ethics committee approval is not required as existing data were used.

Peer-review: Externally peer-reviewed.

Author Contributions: Concept- TL, AC; Design- TL, AC; Supervision- TL; Resources- TL; Data Collection and/or Processing- TL, AC; Analysis and/or Interpretation- TL, AC; Literature Search- TL, AC; Writing Manuscript- TL, AC; Critical Review-TL.

Conflict of Interest: The authors have no conflicts of interest to declare.

Financial Disclosure: This research [YS-22-2184] has been supported by Shota Rustaveli National Science Foundation of Georgia (SRNSFG).

Etik Komite Onayı: Mevcut veriler kullanıldığından etik kurul onayına gerek yoktur.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Fikir- TL, AC; Tasarım- TL; Denetleme- TL; Kaynaklar- TL; Veri Toplanması ve/veya İşlemesi- TL, AC; Analiz ve/veya Yorum- TL, AC; Literatür Taraması- TL, AC; Yazıyı Yazan- TL, AC; Eleştirel İnceleme-TL

Çıkar Çatışması: Yazarlar, çıkar çatışması olmadığını beyan etmiştir.

Finansal Destek: Bu araştırma [YS-22-2184] Gürcistan Shota Rustaveli Ulusal Bilim Vakfı (SRNSFG) tarafından desteklenmiştir.

References

- Abdellaoui, Y., Bouchikhi, B., El Adraoui, B., & Draoui, K. (2019). A high capacity bentonite clay for the sorption of aflatoxins. *Journal of Agricultural and Food Chemistry*, 67(49), 13787–13794. <https://doi.org/10.1021/acs.jafc.9b06283>
- Biomin. (2020). *Biomin Mycotoxin Survey Q3 2020 Results*. <https://www.biomin.net/science-hub/biomin-mycotoxin-survey-q3-2020-results/>
- Bøhn, T., & Sørensen, M. (2020). Intentional contamination of animal feed with mycotoxins: Overview of regulatory limits and experimental protocols. *Journal of Food Protection*, 83(12), 2130–2141. <https://doi.org/10.4315/JFP-20-179>
- Central Inland Fisheries Research Institute. (2022). Standard methods for proximate composition analysis of fish meat (Vol. 4, pp. 65–70).
- Chkuaseli, A., & Khutsishvili-Maisuradze, M. (2016). Application of new mycotoxin adsorbent-bentonite clay “Askangel” in poultry feed. *Annals of Agrarian Science*, 14, 295–298.
- Civille, G. V., Carr, B. T., & Osdoba, K. E. (2024). *Sensory Evaluation Techniques* (6th ed.). CRC Press.
- Costas, A., Conceição, L., Aragão, S., & Enes, P. (2021). Effects of low stocking densities on zootechnical parameters and physiological responses of rainbow trout (*Oncorhynchus mykiss*) juveniles. *Biology*, 10(10), 1040. <https://doi.org/10.3390/biology10101040>
- Enyidi, D., & Emeaso, A. B. (2020). Effects of African bentonite on feed mycotoxigenic fungi and growth of African catfish *Clarias gariepinus*. *Aquaculture Studies*, 20(2), 121–131. <https://doi.org/10.4194/2618-6381-v20 2 06>
- Food and Agriculture Organization. (2020). *The State of World Fisheries and Aquaculture 2020: Sustainability in Action*. <https://doi.org/10.4060/ca9229en>
- Food and Agriculture Organization. (2021). *Nutrition of Fish and Crustaceans: A Laboratory Manual*. <https://www.fao.org/4/ab479e/ab479e00.htm>
- Food and Agriculture Organization. (2024). Georgia approves national aquaculture strategy through EU, Sweden, and FAO support. <https://www.fao.org/georgia/news/detail-events/en/c/1710888/>
- Gruber-Dorninger, C., Jenkins, T., & Schatzmayr, G. (2020). Multi-mycotoxin contamination of aquaculture feed: A global survey. *Toxins*, 12(2), 116. <https://doi.org/10.3390/toxins12020116>
- Guillen, J., Natale, F., Carvalho, N., Casey, J., Hofherr, J., Druon, J., Fiore, G., Gibin, M., & Martinsohn, A. (2019). Global seafood consumption footprint. *Ambio*, 48, 111–122. <https://doi.org/10.1007/s13280-018-1060-9>

- Hossain, M. A., & Islam, M. S. (2020). Hematological parameters as indicators of health status in fish. *Journal of Aquaculture Research & Development*, 11(7), 512.
- Kihal, M., Boudalia, S., Kihal, W., & Kihal, M. (2022). Mycotoxin binders in animal feed: A comprehensive review of their efficacy and safety. *Journal of Animal Science*, 100(6), skac123. <https://doi.org/10.1093/jas/skac123>
- Kolawole, O., Meneely, J., Greer, B., Chevallier, O., Jones, D., Connolly, L., & Elliott, C. (2019). Comparative in vitro assessment of a range of commercial feed additives with multiple mycotoxin binding claims. *Toxins*, 11, 659. <https://doi.org/10.3390/toxins11110659>
- Mago, R., & Kumar, P. (2020). Risk assessment of mycotoxins in food: A review of monitoring techniques and impact on human health. *Food Control*, 112, 107139.
- Mahato, D., Pandhi, S., Kamle, M., Gupta, A., Sharma, B., Panda, B., Srivastava, S., Kumar, M., Selvakumar, R., & Pandey, A. (2022). Trichothecenes in food and feed: Occurrence, impact on human health and their detection and management strategies. *Toxicon*, 208, 62–77. <https://doi.org/10.1016/j.toxicon.2021.10.008>
- Mendes dos Reis, J. (2024). Bentonite clays as adsorbent material for mycotoxins and the hematological parameters involved in tilapia species: A systematic review. *Aquaculture Research*. <https://doi.org/10.1111/are.16502>
- Miller, D., & Greer, D. (2020). Monitoring feed conversion and growth in aquaculture: A focus on statistical methods and feed efficiency. *Aquaculture Nutrition*, 26(9), 1956–1964. <https://doi.org/10.1111/anu.13139>
- Mohd Zain, S. N., Asmara, S. A., & Zakaria, Z. A. (2021). The application of bentonite clay as a feed additive to reduce the toxic effects of aflatoxins in aquaculture: A review. *Aquaculture Reports*, 20, 100746. <https://doi.org/10.1016/j.aqrep.2021.100746>
- Nash, C. E., & Brooking, R. S. (2021). Fish hematology and its application to fish health management. *Aquaculture Research*, 52(9), 4244–4258. <https://doi.org/10.1111/are.15347>
- National Statistics Office of Georgia. (2020). Soflis meurneoba. <https://www.geostat.ge/ka/modules/categories/196/s/oflis-meurneoba>
- Oliveira, C. A. F., Aoyanagi, M. M. C., Budiño, F. E. L., Raj, J., Vasiljević, M., Ramalho, L. N. Z., Ramalho, F. S., Corassin, C. H., & Ghantous, G. F. (2023). Efficacy of two commercially available adsorbents to reduce the combined toxic effects of dietary aflatoxins, fumonisins, and zearalenone. *Toxins*, 15(11), 629. <https://doi.org/10.3390/toxins15110629>
- Oliveira, M., & Vasconcelos, V. (2020). Occurrence of mycotoxins in fish feed and its effects: A review. *Toxins*, 12(3), 160. <https://doi.org/10.3390/toxins12030160>
- Pereira, J. M., & Silva, F. P. (2021). Biochemical blood parameters and their role in fish health monitoring. *Aquaculture Research*, 52(8), 3942–3952. <https://doi.org/10.1111/are.15285>
- Pestka, J. J., & Yuan, Y. (2019). Trichothecenes in food and feed: Human and animal health implications. *Food Additives & Contaminants: Part A*, 36(10), 1672–1694. <https://doi.org/10.1080/19440049.2019.1649474>
- ProGnosis Biotech. (2023). *Bio-Shield T-2/HT-2 ELISA Kit*. <https://www.prognosis-biotech.com/product/bio-shield-t-2-ht-2/>
- Saini, R., Vaid, P., Saini, N., Siwal, S., Gupta, V., Thakur, V., & Saini, K. (2021). Recent advancements in the technologies detecting food spoiling agents. *Journal of Functional Biomaterials*, 12, 67. <https://doi.org/10.3390/jfb12040067>
- Seppälä, O., Kause, A., Quinton, C., & Ødegård, J. (2022). Realised genetic gains on growth, survival, feed conversion ratio and quality traits after ten generations of multi-trait selection in rainbow trout. *Aquaculture Reports*, 22, 100911. <https://doi.org/10.1016/j.aqrep.2022.100911>
- Smith, J., Doe, A., & Brown, R. (2019). Long-term feeding trial on growth performance and health status of rainbow trout (*Oncorhynchus mykiss*). *Aquaculture Research*, 50(5), 1234–1245. <https://doi.org/10.1111/are.13952>
- Sulyok, M., Stadler, D., Steiner, D., & Krska, R. (2020). Validation of an LC-MS/MS-based dilute-and-shoot approach for the quantification of >500 mycotoxins. *Analytical and Bioanalytical Chemistry*, 412(11), 2607–2620. <https://doi.org/10.1007/s00216-020-02489-9>
- Sullivan, M., & Clark, J. (2021). Detection of mycotoxins in animal feed: A review of methods and their application. *Veterinary Sciences*, 8(5), 132. <https://doi.org/10.3390/vetsci8050132>
- Van Der Merwe, D., Howell, N., & Cumming, R. B. (2018). The role of bentonite clay in poultry diets contaminated with aflatoxins. *Poultry Science*, 97, 12–20. <https://doi.org/10.3382/ps/pex305>
- Vasadze, E. (2022). *Ascan Bentonite Clays*. <https://ka.wikipedia.org/wiki>
- Zhou, F., & Wang, Z. (2020). Evaluation of biochemical parameters in fish health: A review of assays and techniques. *Fish Physiology and Biochemistry*, 46(4), 1211–1226. <https://doi.org/10.1007/s10695-020-00810-9>

Application of Artificial Intelligence Technologies in Livestock Management

Hayvancılıkta Yapay Zekâ Teknolojilerinin Uygulanması

Hatice DİLAVER¹



Kamil Fatih DİLAVER²



¹ Niğde Ömer Halis Demir University,
Eurasia Research Institute, Niğde,
Türkiye,

² Niğde Ömer Halis Demir University,
Institute of Science, Department of
Engineering, Niğde, Türkiye

ABSTRACT

Artificial Intelligence (AI) has become a transformative technology in livestock management within the evolving framework of precision agriculture. The integration of AI methods—including supervised and unsupervised machine learning, deep learning, smart sensor networks, and real-time analytics—enables data-driven, timely, and efficient decisions that enhance animal health, welfare, and productivity. AI systems reduce human error, lower labor costs, and automate complex biological and environmental analyses. Key applications include behavior monitoring through accelerometers and vision-based systems, early disease detection via biometric patterns, estrus prediction using movement and vocal cues, and personalized feeding strategies through predictive algorithms. AI also enables biometric identification of animals through facial and vocal recognition, improving traceability and welfare without invasive tagging. This study presents a comprehensive analysis of major AI subfields—Machine Learning (ML), Deep Learning (DL), Artificial Neural Networks (ANN), Computer Vision (CV), Robotics, and Natural Language Processing (NLP)—and their applications in livestock farming through empirical research and quantitative models. Special emphasis is placed on convolutional neural networks for diagnostics, reinforcement learning in feeding systems, and sensor fusion for behavior recognition. A practical Python-based simulation is introduced, utilizing a Multilayer Perceptron (MLP) neural network to predict daily milk yield from synthetic biometric data (heart rate, respiration rate, body and eye temperature) of 100 dairy cows. Model performance was evaluated using Mean Squared Error (MSE), Mean Absolute Error (MAE), and R² metrics, demonstrating potential for real-time prediction in farm operations. AI technologies contribute to Agriculture 4.0 by promoting sustainability, automation, and data-centric decision-making, reshaping livestock farming into a more resilient, efficient, and welfare-oriented system.

Keywords: Artificial Intelligence, Computer Vision, Deep Learning, Estrus Detection, Livestock, Neural Networks, Smart Farming

Introduction

Artificial Intelligence (AI) is defined as the capability of a machine or computer system to imitate intelligent human behavior, such as reasoning, problem-solving, interpretation, generalization, and learning from experience (Nabiyev, 2012; Öztürk & Şahin, 2018). The field has evolved rapidly, supported by foundational work from George Boole's formal logic (1847), Alan Turing's computation theory (1936), and the development of artificial neurons (McCulloch & Pitts, 1943). John McCarthy first coined the term "Artificial Intelligence" in 1955, defining it as "the science and engineering of making intelligent machines" (Hamet & Tremblay, 2017).

Today, AI is employed in numerous industries—from finance to medicine, from logistics to agriculture—due to its ability to process massive datasets, recognize patterns, and derive meaningful decisions. Particularly in livestock management, AI offers a revolutionary path toward precision farming. Modern AI models simulate cognitive functions of the human brain to optimize systems that traditionally relied on intuition and manual oversight. By minimizing human intervention, AI allows for more efficient herd management, predictive disease control, and optimization of feeding strategies. In this paper, we present a comprehensive analysis of the key subfields of AI—Machine Learning, Deep Learning, Artificial Neural Networks, Computer Vision, Robotics, and Natural Language Processing—and their real-world applications in animal agriculture. In this paper, we present a comprehensive analysis of the key subfields of AI and their real-world applications in animal agriculture. Machine Learning (ML) techniques enable systems to learn from data without explicit programming, facilitating



Received/Geliş Tarihi 20.05.2025

Accepted/Kabul Tarihi 12.06.2025

Publication/Date Yayın Tarihi 24.07.2025

Corresponding author/Sorumlu Yazar:

Hatice DİLAVER

E-mail: haticedilaver509@gmail.com

Cite this article: Dilaver, H. & Dilaver, K.F. (2025). Application of Artificial Intelligence Technologies in Livestock Management. *Journal of Animal Science and Economics*, 4(2), 64-74.



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

tasks like disease diagnosis and yield prediction. Deep Learning (DL), a subset of ML utilizing multi-layered neural networks, excels in complex pattern recognition, particularly in image and sound analysis for animal monitoring. Artificial Neural Networks (ANNs) form the backbone of many AI applications, offering robust frameworks for modeling non-linear relationships in biological data. Computer Vision (CV) allows systems to "see" and interpret visual data, crucial for individual animal identification, behavior analysis, and lameness detection. Robotics integrates AI to automate physical tasks, from milking to precise feed delivery, enhancing labor efficiency. Finally, Natural Language Processing (NLP), though less common, holds potential for analyzing animal vocalizations or textual farm records to derive insights. By exploring these advanced technological domains, this paper aims to provide a holistic overview of how AI is fundamentally transforming livestock management, fostering more sustainable, productive, and welfare-oriented practices.

Method

This research adopts a multi-method qualitative approach to examine the adoption and efficacy of Artificial Intelligence (AI) applications in livestock management. The methodology combines a systematic literature review, a technical analysis of AI systems used in selected case studies, and an evaluation of performance metrics related to productivity, animal health, and resource efficiency.

Systematic Literature Review

The literature review was conducted using academic databases such as Scopus, IEEE Xplore, SpringerLink, and ScienceDirect. Search terms included "artificial intelligence in livestock," "machine learning in animal farming," "precision livestock farming," "sensor-based monitoring," and "automated decision-making in dairy production." Inclusion criteria focused on peer-reviewed articles, published between 2015 and 2025, addressing AI applications in dairy, beef, and poultry sectors.

Selected publications were coded and categorized according to the following thematic axes:

- Type of AI technology (e.g., supervised learning, unsupervised learning, reinforcement learning)
- Purpose of application (e.g., disease prediction, behavior monitoring, feed optimization)
- Type of sensor integration (e.g., RFID, thermal imaging, accelerometers, biosensors)

Case Study Framework

Three real-world AI-integrated livestock systems were analyzed using a comparative case study design:

Case A–Dairy Farm (Netherlands): A commercial dairy farm using deep learning algorithms (e.g., convolutional neural networks) for real-time cow activity recognition, estrus detection, and automated milking through robotic systems.

Case B–Beef Cattle Operation (USA): A ranch employing wireless biosensor networks and support vector machines (SVM) for early detection of respiratory infections and remote monitoring of grazing patterns.

Case C–Poultry Production Facility (Japan): A smart poultry house integrating Internet of Things (IoT) and reinforcement learning to optimize feed conversion ratios, detect abnormal vocal patterns, and manage climate control autonomously.

Each case was evaluated in terms of:

- System architecture (hardware and software components)
- AI model structure and learning algorithms
- Data acquisition and preprocessing workflows
- Decision-making automation and user interface design
- Impact on operational KPIs (milk yield, feed cost, mortality rate)

Simulated Data for Daily Milk Yield Prediction: For the practical simulation framework in Python, a synthetic dataset representing 100 dairy cows was generated. This dataset was designed to simulate realistic physiological and production parameters over a specific period. The simulated cow population comprised a mix of Holstein Friesian, Jersey, and Brown Swiss breeds, reflecting common dairy farm compositions. The parity (number of calvings) of these simulated animals ranged from 1 to 5, with an average parity of 2.5 ± 1.2 . The lactation order for each cow was also simulated accordingly. The dataset included daily records for heart rate, respiratory rate, body temperature, and eye temperature, alongside corresponding daily milk yield values. These synthetic data points were generated based on established physiological ranges and correlations observed in real dairy cattle, ensuring a realistic representation for the purpose of demonstrating the MLP model's predictive capabilities. The synthetic nature of this dataset allowed for controlled

experimentation and validation of the AI model without the logistical constraints of real-world data collection for 100 individual animals

AI Technologies and Sensor Integration

The AI tools analyzed include:

- Supervised learning: logistic regression, decision trees, and random forest for disease classification
- Unsupervised learning: k-means clustering for behavioral anomaly detection
- Reinforcement learning: policy optimization in automated feeding systems
- Computer vision: convolutional neural networks (CNN) for image-based animal tracking
- Natural language processing (NLP): used in vocalization pattern recognition in poultry

Sensors integrated with AI systems include GPS collars, RFID tags, thermographic cameras, acoustic microphones, heart rate monitors, and ammonia gas sensors.

Ethical and Sustainability Considerations

Since this study exclusively employs secondary data and non-invasive sources, and the practical simulation part uses synthetically generated data, no formal ethical approval was required. Nevertheless, ethical concerns related to AI bias, animal surveillance, and data transparency are addressed in the discussion section, in line with the guidelines of the European Food Safety Authority (EFSA) and the FAO's Ethics of Digitalization in Agriculture framework.

Data Sources and Analysis Tools

Secondary data were sourced from publicly available datasets, governmental agriculture reports, technical manuals of farm equipment manufacturers, and results from previous empirical studies. Analytical synthesis was supported by the use of NVivo for qualitative coding, and Python-based tools for reviewing AI model structures and performance metrics where available.

Key metrics assessed include:

- Animal productivity indices (e.g., daily milk yield, weight gain)
- Health and welfare indicators (e.g., disease detection rate, behavior regularity)
- Resource efficiency (e.g., feed utilization efficiency, energy consumption)

AI Technologies and Sensor Integration

The AI tools analyzed include:

- Supervised learning: logistic regression, decision trees, and random forest for disease classification
- Unsupervised learning: k-means clustering for behavioral anomaly detection
- Reinforcement learning: policy optimization in automated feeding systems
- Computer vision: convolutional neural networks (CNN) for image-based animal tracking
- Natural language processing (NLP): used in vocalization pattern recognition in poultry


Sensors integrated with AI systems include GPS collars, RFID tags, thermographic cameras, acoustic microphones, heart rate monitors, and ammonia gas sensors.

Ethical and Sustainability Considerations

Since this study exclusively employs secondary data and non-invasive sources, no formal ethical approval was required. Nevertheless, ethical concerns related to AI bias, animal surveillance, and data transparency are addressed in the discussion section, in line with the guidelines of the European Food Safety Authority (EFSA) and the FAO's Ethics of Digitalization in Agriculture framework.

Figure 1.

General AI systems architecture in livestock management



Subfields of Artificial Intelligence

Machine learning (ML)

Machine Learning is an AI subdiscipline that focuses on algorithms capable of learning from data without explicit programming. ML algorithms are trained using input-output pairs to detect underlying relationships, making them ideal for applications such as pattern recognition, anomaly detection, and time-series prediction.

There are two main types of machine learning:

- **Supervised Learning:** The algorithm learns from labeled training data. For instance, identifying estrus in dairy cows by correlating behavioral changes with confirmed estrus events.
- **Unsupervised Learning:** The algorithm explores unlabeled data to identify hidden patterns or groupings, such as clustering animals based on feeding behavior or stress response.

ML is widely used in livestock for tasks like disease classification, feed optimization, and yield estimation (El Naqa & Murphy, 2015; Zhang, 2020).

Deep learning (DL)

Deep Learning is a specialized ML method using layered neural networks to model high-level abstractions in data. DL algorithms learn from vast datasets and are particularly powerful in analyzing unstructured data such as images, video, and audio. They use backpropagation and iterative training to improve prediction accuracy over time.

Key applications in livestock management include:

- Facial recognition of animals
- Emotion and pain detection
- Thermal image analysis for health monitoring
- Estrus prediction based on video behavior cues
- Common architectures include:
 - Convolutional Neural Networks (CNN): Effective in image classification (e.g., identifying cows based on muzzle prints)
 - Recurrent Neural Networks (RNN): Suitable for sequential data like animal movement over time
 - Faster R-CNN & Mask R-CNN: Used for object detection in drones and surveillance videos (He et al., 2017)

Artificial neural networks (ANNs)

ANNs are computational systems inspired by the human brain's structure. They consist of interconnected nodes (neurons) that process and transmit data. ANNs learn from examples and generalize to make decisions about new inputs.

In livestock science, ANNs have shown superior performance compared to traditional statistical models in predicting:

- Milk yield
- Body weight
- Nutritional needs
- Estrus and mastitis detection

Example formula for milk prediction:

$$MY = w_1(HR) + w_2(RR) + w_3(BT) + w_4(ET) + b$$

Where:

- MY = Milk yield (liters/day)
- HR = Heart Rate
- RR = Respiration Rate
- BT = Body Temperature
- ET = Eye Temperature
- w_1 – w_4 = Weight coefficients
- b = Bias term

This model forms the basis for our simulation code presented in Section 6.

Computer vision (CV)

Computer Vision involves enabling machines to interpret and analyze visual data. It is used extensively in livestock applications, especially for:

- Facial recognition of animals
- Automated counting and tracking in open pastures
- Identifying gait and movement disorders
- Monitoring emotional states based on facial expressions

Technologies such as thermal imaging and 3D cameras have further enhanced the scope of CV in farm settings. For example, Mask R-CNN is used in drones to detect and count animals in large-scale grazing lands (Xu et al., 2020).

Robotics

Robotics in animal husbandry includes automated milking systems (AMS), robotic feeders, and mobile cleaning units. These devices often operate with embedded AI to:

- Recognize individual animals
- Adapt to behavioral changes
- Respond to stress or health alerts in real-time

Robot-assisted farms increase efficiency and reduce labor dependency, especially in large-scale dairy operations.

Natural language processing (NLP)

NLP in livestock science may seem less common but has emerging applications:

- Voice analysis of animal sounds for behavior and stress detection
- Interpretation of unstructured textual data from farm logs or veterinary reports
- Translation tools for multilingual agricultural datasets

For instance, researchers have used speech-to-text and convolutional neural networks to classify cattle vocalizations

and link them to emotional or reproductive states (Jung et al., 2021).

Applications of artificial intelligence in livestock management

The integration of artificial intelligence (AI) technologies into livestock production has revolutionized traditional animal husbandry methods. As part of the Agriculture 4.0 movement, AI enables precise, data-driven interventions that enhance productivity, improve animal welfare, and reduce operational costs. The following sections explore the most prominent applications of AI in livestock, based on cutting-edge research and practical implementations.

Behavioral monitoring and welfare assessment

AI technologies allow real-time monitoring of animal behavior, enabling early detection of abnormalities. Sensor-based systems integrated with machine learning algorithms can detect behavioral changes associated with:

- Heat stress
- Estrus (reproductive heat)
- Illness
- Aggression or depression
- Changes in feeding and rumination patterns

For example, Neethirajan (2021) proposed a facial recognition system to identify emotional states in cows and pigs by analyzing ear positions, eye white exposure, and facial tension. Similarly, behavior analysis using accelerometers and RFID tags allows farmers to remotely monitor standing, lying, walking, or chewing patterns. These insights help minimize stress and ensure optimal living conditions.

Disease detection and health prediction

Disease outbreaks in livestock can lead to significant economic losses and reduced food safety. AI systems can analyze body temperature, respiration rate, gait, and facial expressions to detect subclinical conditions early. Technologies such as:

- Electronic noses (eNoses) for odor-based diagnosis
- Thermal imaging for inflammation or infection
- Automated weighing systems for weight fluctuation tracking

are increasingly supported by deep learning models. For instance, Memmedova (2012) used artificial neural networks (ANN) to detect subclinical mastitis in dairy cattle with a sensitivity of 82% and specificity of 74%.

Moreover, CNN-based models like Faster R-CNN have been deployed to detect signs of lameness, injuries, and posture anomalies in sheep and cattle, with detection rates exceeding 90%.

Milk yield prediction and productivity optimization

AI-powered tools are used to predict milk yield based on multiple biometric and environmental variables. These systems learn from historical and sensor-collected data to model complex relationships among:

- Heart rate (HR)
- Respiratory rate (RR)
- Body temperature (BT)
- Eye temperature (ET)
- Ambient humidity and heat stress index (HSI)

A commonly used formulation is:

$$MY = f(HR, RR, BT, ET) = w_1 \cdot HR + w_2 \cdot RR + w_3 \cdot BT + w_4 \cdot ET + b$$

$$MY = f(HR, RR, BT, ET) = w_1 \cdot HR + w_2 \cdot RR + w_3 \cdot BT + w_4 \cdot ET + b$$

Where MY represents milk yield and w_1 – w_4 are the learned weights via machine learning.

Fuentes et al. (2020, 2021) applied such models in robotic milking systems using visible remote sensing, achieving a prediction accuracy of $R = 0.96$ in estimating daily milk yield.

Facial recognition and biometric identification

Traditionally, livestock identification relied on ear tags or physical branding. However, AI has introduced contactless biometric solutions using:

- Muzzle print recognition (Barry et al., 2007)
- Nose pattern analysis via CNNs (Kumar et al., 2018)
- Facial image classification with deep metric learning (Andrew et al., 2021)

These systems eliminate the need for invasive tagging, reduce labor, and improve animal welfare. Figure-based facial recognition systems can identify individual cows with 98–99% accuracy, even under field conditions.

Voice analysis and estrus detection

AI-driven voice recognition systems are now capable of interpreting animal sounds for stress, hunger, and reproductive cues. Jung et al. (2021) created a deep learning-based cattle vocalization model that achieved 81.96% accuracy in identifying emotional states and estrus status from audio recordings.

Such models rely on real-time audio collection using embedded microphones and apply:

- Mel Frequency Cepstral Coefficients (MFCC)
- Long Short-Term Memory (LSTM) networks
- Spectrogram analysis

These technologies enable early estrus detection, reducing insemination failures and improving breeding efficiency.

Emotion recognition through computer vision

The emotional state of farm animals is closely linked to productivity and health. Neethirajan (2021) developed a facial coding platform using YOLOv3 and Faster-YOLOv4 to analyze 13 facial expressions and classify nine emotional states in cows and pigs, such as calm, aggressive, or stressed.

Using CV-based systems, farmers can now:

- Assess pain intensity (Pain Facial Expression Score – PFES)
- Evaluate animal discomfort during procedures
- Monitor emotional shifts due to environmental changes

Such emotion-aware systems pave the way for ethical livestock practices aligned with global animal welfare standards.

Pain recognition and welfare evaluation

Pain recognition is essential for early veterinary intervention. Using AI models trained on facial landmarks, researchers can now detect pain indicators such as:

- Eye tightening
- Nose wrinkling
- Ear positioning
- Mouth tension

McLennan and Mahmoud (2019) developed a 25-point facial landmark detection model to estimate pain in sheep. Using deep learning, their system achieved reliable classification accuracy and allowed automated alerts in farm settings.

Object detection and counting via drones

In vast pasture lands, it is difficult to manually count or monitor free-grazing livestock. AI-based drone systems using Mask R-CNN or Faster R-CNN analyze aerial images and detect:

- Number of animals

- Spatial distribution
- Movement trajectories
- Body condition

Xu et al. (2020) used unmanned aerial vehicles (UAVs) equipped with machine learning models to detect and classify cattle in real-time with up to 94% accuracy.

Breed classification and automated sorting

Dutta (2021) used deep learning to classify sheep breeds in mixed herds with an accuracy of 99.97%. AI-enabled gate systems can now sort animals automatically based on visual traits, RFID signals, or biometric inputs. This minimizes human labor and enables faster herd management during breeding or milking processes.

Integration with farm management systems

Modern livestock management is moving toward full integration of AI with digital farm platforms. Cloud-based dashboards gather data from:

- Sensor arrays
- Robotic devices
- Climate stations
- Health records

These are processed by AI models and visualized for farmers, enabling:

- Forecasting feed demands
- Alerting for medical attention
- Scheduling reproductive cycles
- Reducing carbon footprint

Such intelligent farm ecosystems contribute to sustainable practices in line with global climate goals and food security agendas

Results

The ANN model produced a mean squared error (MSE) of 7.85 and a mean absolute error (MAE) of 1.99 liters. While the R^2 score was -0.15 due to synthetic data limitations, the simulation confirmed that milk yield can be estimated using biometric features such as heart rate and eye temperature. These results align with prior studies that showed ANN models outperforming traditional linear regression in livestock productivity predictions.

Mathematical Modeling and Formulations

Artificial intelligence systems rely on mathematical models to make accurate predictions, recognize complex patterns, and optimize decision-making in real-time. In livestock management, several types of AI models are utilized, including linear regression, artificial neural networks (ANN), decision trees, and convolutional neural networks (CNN). This section presents three core formulations developed to address key problems in animal husbandry:

Milk yield prediction model using artificial neural network (ANN)

Milk production is influenced by a combination of physiological and environmental factors. An ANN-based model can be used to estimate daily milk yield based on biometric indicators collected via sensors.

Mathematical Formulation:

$$MY = f(HR, RR, BT, ET) = w_1 \cdot HR + w_2 \cdot RR + w_3 \cdot BT + w_4 \cdot ET + b$$

$$\text{MY} = f(\text{HR}, \text{RR}, \text{BT}, \text{ET}) = w_1 \cdot \text{HR} + w_2 \cdot \text{RR} + w_3 \cdot \text{BT} + w_4 \cdot \text{ET} + b$$

Where:

- MY = Milk Yield (liters/day)
- HR = Heart Rate (beats per minute)
- RR = Respiratory Rate (breaths per minute)
- BT = Body Temperature ($^{\circ}C$)
- ET = Eye Temperature ($^{\circ}C$)
- $w_1 - w_4$ = Learned weight coefficients
- b = Bias term

This model is trained using historical farm data and adjusted iteratively using backpropagation to minimize prediction error (e.g., Mean Squared Error, MSE).

Heat Stress Index (HSI) Model

Environmental stress can negatively impact both productivity and animal welfare. The Heat Stress Index (HSI)

is a simplified linear model that relates ambient temperature and humidity to heat load experienced by animals.

Formulation:

$$HSI = Ta + RH^2 \quad \text{HSI} = \frac{Ta}{RH^2} + \dots$$

Where:

- HSI = Heat Stress Index
- Ta = Ambient Temperature ($^{\circ}C$)
- RH = Relative Humidity (%)

When $HSI > 75$, automated cooling systems (e.g., fans, water sprinklers) are activated. AI models can dynamically adjust feed composition or hydration protocols based on the HSI value.

Estrus detection accuracy model

Accurate estrus detection is critical for successful breeding management. AI systems trained on movement, sound, and temperature data can provide real-time estrus alerts.

Formulation for Accuracy Evaluation:

$$\text{Accuracy}(\%) = \frac{TP + TN}{TP + TN + FP + FN} \times 100$$

$$\text{Accuracy}(\%) = \frac{TP + TN}{TP + TN + FP + FN} \times 100$$

Where:

- TP = True Positives (correct estrus predictions)
- TN = True Negatives (correct non-estrus predictions)
- FP = False Positives (non-estrus labeled as estrus)
- FN = False Negatives (estrus labeled as non-estrus)

This metric is essential for evaluating AI model performance in reproductive monitoring systems.

Neural network training optimization

The ANN used for milk yield prediction minimizes a loss function during training:

$$\text{Loss} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$


$$\text{Loss} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Where:

- $\hat{y}_i$ = Predicted output (e.g., milk yield)
- y_i = Actual output (measured milk yield)
- n = Number of training samples

The objective is to minimize this loss using gradient descent or more advanced optimizers such as Adam or RMSprop.

Figure 2.
Actual vs Predicted Milk Yield



Python-Based Simulation for Milk Yield Prediction

In order to demonstrate how artificial intelligence can be applied to livestock data, a simulated dataset was created containing physiological parameters for 100 dairy cows. These variables include:

- Heart Rate (HR)
- Respiratory Rate (RR)
- Body Temperature (BT)
- Eye Temperature (ET)

The milk yield (MY) is predicted based on a weighted combination of these features using a Multilayer Perceptron (MLP) Regressor, which is a form of artificial neural network (ANN).

Model architecture

- Input Layer: 4 features (HR, RR, BT, ET)
- Hidden Layers: Two layers with 10 and 5 neurons respectively
- Output Layer: Continuous value representing predicted milk yield
- Training Data: 80% of dataset
- Test Data: 20% of dataset
- Iterations: 1000 (maximum allowed)

Evaluation metrics

After training, the model was evaluated using standard regression performance metrics:

- Mean Squared Error (MSE): 7.85
- Mean Absolute Error (MAE): 1.99
- R^2 Score (Coefficient of Determination): -0.15

The negative R^2 value indicates that the model did not generalize well on this small simulated dataset. However, with real-world sensor data and proper feature scaling, performance would likely improve significantly.

Visualization: actual vs predicted milk yield

Below is a scatter plot comparing the predicted milk yield values against the actual values for the test set.

Interpretation:

- Each dot represents a cow from the test dataset.
- The closer the dots lie along the diagonal line, the better the model prediction.

Discussion

The application of artificial intelligence (AI) in livestock management has demonstrated significant promise, both in research and real-world implementation. The results from the Python simulation, along with literature evidence, affirm that AI systems can accurately model complex biological processes such as milk yield prediction, behavior analysis, and health monitoring.

Evaluation of the Neural Network Model

The simulated model used a four-variable input (heart rate, respiratory rate, body temperature, eye temperature) to predict daily milk yield. Although based on synthetic data, the system revealed a mean absolute error (MAE) of approximately 1.99 liters, which is relatively acceptable for early-stage prediction models.

However, the negative R^2 score (-0.15) indicates overfitting or insufficient generalization, which is expected due to:

- The small sample size ($n = 100$)
- Use of randomly generated data
- Absence of data normalization or cross-validation

Despite these constraints, the results demonstrate the technical feasibility of using ANN-based systems in dairy operations. In real-world scenarios, with access to continuous sensor data and larger datasets, such a model would yield significantly improved predictive power.

Interpretation of the Visual Results

The scatter plot comparing actual vs. predicted milk yields shows visible dispersion, suggesting that the model captures trends but lacks fine-grained precision. However, this is a common starting point for developing ANN-based livestock models. Over time, additional features such as ambient conditions, feed intake, or lactation phase can be added to improve performance.

Furthermore, the visualization clearly illustrates how individual biometric markers (e.g., eye temperature) can serve as proxies for physiological stress and productivity fluctuations. These findings are consistent with studies by Fuentes et al. (2021), who used similar biometric sensors in robotic milking systems to predict milk yield with $R = 0.96$ accuracy.

Comparison with Literature Findings

The structure and behavior of the ANN model presented align with previous work:

- Chen et al. (2008) applied ANN to estimate nutrient content in dairy manure and reported superior prediction performance compared to linear models.
- Memmedova (2012) used ANN to detect subclinical mastitis in dairy cows with over 80% sensitivity.
- Görgülü (2012) and Takma et al. (2012) demonstrated that ANN outperforms multiple linear regression in milk yield estimation.
- Gjergji et al. (2020) developed convolutional models to predict cattle body weight from images, eliminating the need for physical weighing.

These findings validate the direction and structure of our model, reinforcing the utility of AI in agricultural environments.

Ethical and Practical Implications

Beyond productivity, the integration of AI in livestock farming promotes:

- Animal welfare, by enabling non-invasive, stress-free monitoring
- Labor efficiency, reducing the need for manual observation
- Economic sustainability, by minimizing losses due to late detection of health or reproductive issues

However, practical deployment must consider challenges such as:

- Sensor calibration
- Data privacy and ownership
- Farmer training and digital literacy

Contribution to Agriculture 4.0

This study supports the broader paradigm shift toward Agriculture 4.0, where data-driven technologies transform traditional farming into smart, sustainable systems. With

machine learning, computer vision, and biometric sensing, farmers can move from reactive to proactive decision-making, thus enhancing food security, animal health, and environmental stewardship.

Conclusion and Recommendations

The integration of artificial intelligence (AI) technologies into livestock management marks a transformative shift in agricultural science. Through the use of machine learning, artificial neural networks, deep learning, and computer vision, farmers can now predict, monitor, and respond to animal needs with unprecedented precision. From milk yield estimation and estrus detection to disease identification and emotional state monitoring, AI has shown its ability to revolutionize both productivity and animal welfare.

The mathematical models and Python simulation developed in this study provide a simplified yet illustrative view of how AI can be applied to real-world livestock scenarios. Even with a limited dataset, the artificial neural network (ANN) demonstrated reasonable predictive capacity and served as a technical foundation for more advanced systems. As the availability of sensor data increases and AI algorithms become more refined, such systems will be capable of generating highly accurate, real-time predictions that support intelligent, data-driven farm management.

Moreover, the results reinforce findings in the current literature, validating AI's potential not only as a computational tool but also as a strategic partner in precision agriculture. By reducing manual labor, increasing diagnostic accuracy, and improving the overall efficiency of livestock operations, AI paves the way for a sustainable and ethically aware farming future.

The widespread adoption of AI in livestock management will also foster a transition toward Agriculture 4.0, which prioritizes smart, scalable, and environmentally responsible technologies. In this vision, AI does not replace the human element of farming but rather enhances it—empowering producers with the tools needed to meet global demands for food, animal welfare, and ecological balance.

Therefore, continued research, investment, and education in AI-based livestock technologies are essential. As AI matures, its applications in animal agriculture will no longer be a futuristic concept, but a present-day necessity for resilient, productive, and humane food systems.

Ethics Committee Approval: Ethics committee approval is not required as existing data were used.

Peer-review: Externally peer-reviewed.

Author Contributions: Concept -H.D.; Design -H.D.; Supervision -H.D.; Resources -; F.K.D.-; Writing Manuscript -F.K.D.; Critical Review -F.K.D.; Other - F.K.D.

Conflict of Interest: The authors have no conflicts of interest to declare.

Financial Disclosure: The authors declared that this study has received no financial support.

Etik Komite Onayı: Mevcut veriler kullanıldığından etik kurul onayına gerek yoktur.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Fikir -H.D.; Tasarım -H.D.; Denetleme -H.D.; Kaynaklar -; F.K.D.-; Makale Yazımı -F.K.D.; Eleştirel İnceleme -F.K.D.; Diğer - F.K.D.

Çıkar Çatışması: Yazarlar, çıkar çatışması olmadığını beyan etmiştir.

Finansal Destek: Yazarlar bu çalışmanın herhangi bir finansal destek almadığını beyan etmişlerdir.

References

- Andrew, W., Gao, J., Mullan, S., Campbell, N., Dowsey, A. W., & Burghardt, T. (2021). Visual identification of individual Holstein-Friesian cattle via deep metric learning. *Computers and Electronics in Agriculture*, 185, 106133.
- Awad, A. I., Zawbaa, H. M., Mahmoud, H. A., Nabi, E. H. H., Fayed, R. H., & Hassanien, A. E. (2013). A robust cattle identification scheme using muzzle print images. *Federated Conference on Computer Science and Information Systems*, Krakow, Poland, 529–534.
- Barbedo, J. G. A., & Koenigkan, L. V. (2018). Perspectives on the use of unmanned aerial systems to monitor cattle. *Outlook on Agriculture*, 47(3), 214–222.
- Barry, B., Gonzales-Barron, U. A., McDonnell, K., Butler, F., & Ward, S. (2007). Using muzzle pattern recognition as a biometric approach for cattle identification. *Transactions of the ASABE*, 50(3), 1073–1080.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: Fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31.
- Benko, A., & Lanyi, C. S. (2009). History of artificial intelligence. In Khosrow-Pour, M. (Ed.), *Encyclopedia of Information Science and Technology* (2nd ed., pp. 1759–1762). IGI Global.
- Borchers, M. R., Chang, Y. M., Proudfoot, K. L., Wadsworth, B. A., Stone, A. E., & Bewley, J. M. (2017). Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science*, 100(7), 5664–5674.
- Chen, L. J., Cui, L. Y., Xing, L., & Han, L. J. (2008). Prediction of the nutrient content in dairy manure using artificial neural network modeling. *Journal of Dairy Science*, 91(12), 4822–4829.
- Dandıl, E., Turkan, M., Boğa, M., & Çevik, K. K. (2019). Sığır yüzlerinin tanınması için daha hızlı bölgesel evrimsel sinir ağıları uygulaması. *BŞEÜ Fen Bilimleri Dergisi*, 6, 177–189.
- Dutta, P. A. (2021). Deep learning approach for animal breed classification – Sheep. *International Journal of Research in Applied Science and Engineering Technology*, 9(5), 73–76.
- El Naqa, I., & Murphy, M. J. (2015). What is machine learning? In El Naqa, I., Li, R., & Murphy, M. J. (Eds.), *Machine Learning in Radiation Oncology* (pp. 3–11). Springer.
- Fuentes, S., Gonzalez Viejo, C., Cullen, B., Tongson, E., Chauhan, S. S., & Dunshea, F. R. (2020). Artificial intelligence applied to a robotic dairy farm to model milk productivity and quality based on cow data and daily environmental parameters. *Sensors*, 20(10), 2975.
- Fuentes, S., Gonzalez Viejo, C., Tongson, E., Lipovetzky, N., & Dunshea, F. R. (2021). Biometric physiological responses from dairy cows measured by visible remote sensing are good predictors of milk productivity and quality through artificial intelligence. *Sensors*, 21(20), 6844.
- Gjergji, M., de Moraes Weber, V., Silva, L. O. C., da Costa Gomes, R., de Araújo, T. L. A. C., Pistori, H., & Alvarez, M. (2020). Deep learning techniques for beef cattle body weight prediction. *International Joint Conference on Neural Networks (IJCNN)*, 1–8.
- Görgülü, O. (2012). Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science*, 42(3), 280–287.
- Grzesiak, W., Błaszczak, P., & Lacroix, R. (2006). Methods of predicting milk yield in dairy cows—Predictive capabilities of Wood's lactation curve and artificial neural networks (ANNs). *Computers and Electronics in Agriculture*, 54(2), 69–83.
- Hamet, P., & Tremblay, J. (2017). Artificial intelligence in medicine. *Metabolism*, 69(Suppl), S36–S40.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*, 2961–2969.
- Hertz, J., Krogh, A., & Palmer, R. G. (1991). *Introduction to the Theory of Neural Computation*. Westview Press.
- Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4(2), 251–257.
- Jung, D. H., Kim, N. Y., Moon, S. H., Jhin, C., Kim, H. J., Yang, J. S., & Park, S. H. (2021). Deep learning-based cattle vocal

- classification model and real-time livestock monitoring system with noise filtering. *Animals*, 11, 357.
- Kumar, S., Pandey, A., Satwik, K. S. R., Kumar, S., Singh, S. K., Singh, A. K., & Mohan, A. (2018). Deep learning framework for recognition of cattle using muzzle point image pattern. *Measurement*, 116, 1–17.
- McLennan, K., & Mahmoud, M. (2019). Development of an automated pain facial expression detection system for sheep (*Ovis aries*). *Animals*, 9(4), 196.
- Memmedova, N. (2012). *Süt sığırlarında mastitisin bazı yapay zekâ yöntemleri kullanılarak erken dönemde tespiti* (Tez No: 315853). [Doktora Tezi, Selçuk Üniversitesi]. YÖK Tez Merkezi.
- Nabiyev, V. V. (2012). *Yapay Zekâ: İnsan-Bilgisayar Etkileşimi*. Ankara: Seçkin Yayıncılık.
- Neethirajan, S. (2021). Happy cow or thinking pig? WUR wolf-Facial coding platform for measuring emotions in farm animals. *AI*, 2(3), 342–354.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25–36.
- Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., & Schneider, D. (2020). Automated cattle counting using Mask R-CNN in quadcopter vision system. *Computers and Electronics in Agriculture*, 171, 105300.
- Zhang, X. D. (2020). *Machine Learning*. In Zhang, X. D. (Ed.), *A Matrix Algebra Approach to Artificial Intelligence* (pp. 223–440). Springer, Singapore.
- Zhang, Z. (2018). *Artificial Neural Network*. In Zhang, Z. (Ed.), *Multivariate Time Series Analysis in Climate and Environmental Research* (pp. 1–35). Springer.

Türkiye Koyun Eti Üretiminin 2023-2027 Dönemi Öngörülleri

Forecasts for Sheep Meat Production in Türkiye for the 2023–2027 Period

ÖZ

Bu çalışmanın amacı, Türkiye'nin koyun eti üretimindeki değişimleri analiz ederek 2023–2027 yılları arasındaki beş yıllık dönem için üretim tahmininde bulunmaktır. Bu kapsamda, Birleşmiş Milletler Gıda ve Tarım Örgütü İstatistik Veritabanı (FAOSTAT) tarafından sağlanan 1961–2022 dönemine ait 62 yıllık veriler kullanılmıştır. Verilerin analizinde Statistical Analysis System (SAS) istatistik yazılımı ve Autoregressive Integrated Moving (ARIMA) modeli tercih edilmiştir. Model seçim sürecinde Smallest Canonical Correlation (SCAN) ve Extended Sample Autocorrelation Function (ESACF) yöntemlerinden yararlanılmış; bu doğrultuda ARIMA (0,1,0), ARIMA (3,1,2) ve ARIMA (5,1,0) modelleri önerilmiş ve Akaike Bilgi Kriteri (AIC), Bayesyen Bilgi Kriteri (BIC), Durbin-Watson İstatistiği (DW) ve Belirlilik Katsayısı (R^2) gibi değerlendirme kriterlerine göre en iyi uyumu sağlayan model ARIMA (3,1,2) olarak belirlenmiştir. Çalışma bulgularına göre, 2022 yılındaki koyun eti üretimi, 1961 yılına kıyasla yaklaşık iki kat artış göstermiştir. Söz konusu 62 yıllık dönemde üretimin yıllık bileşik büyüme oranı %1,13 olarak hesaplanmış, 2018'e göre 2023 yılında üretim artışı %10,94 olarak tespit edilmiştir. Gelecek beş yıl için (2023–2027) ortalama büyüme oranı %1,10 düzeyindedir ve bu dönemde yıllık üretimin sırasıyla 495.303,39; 501.174,64; 514.430,42; 518.809,68 ve 523.181,87 ton olacağı, beş yıl için ortalama üretimin ise yaklaşık 510.580 ton olacağı öngörülmektedir. Bu doğrultuda, Türkiye'de özellikle son yıllarda verilen desteklerle koyun eti üretiminde gözlenen istikrarlı artış eğiliminin sürdürülebilirliği için küçükbaş hayvancılıkta verimliliği artırıcı politikalarının devam ettirilmesi, girdi ve işgücü maliyetlerinin azaltılması, yerli ırkların ıslahı ve üreticilerin ortak sorunlar için beraber hareket etmesi bu sektörde hızlı ve kaliteli üretimin güçlenmesine katkı sağlayacaktır.

Anahtar Kelimeler: Büyüme Oranı, Et Üretimi, Tarım Politikası, Zaman Serisi Analizi

ABSTRACT

The aim of this study is to analyze the trends in sheep meat production in Türkiye and to provide production forecasts for the five-year period between 2023 and 2027. For this purpose, 62 years of data (1961–2022) from the Food and Agriculture Organization of the United Nations Statistical Database (FAOSTAT) were used. The data were analyzed using the Statistical Analysis System (SAS) software and the Autoregressive Integrated Moving Average (ARIMA) model. During the model selection process, the Smallest Canonical Correlation (SCAN) and Extended Sample Autocorrelation Function (ESACF) methods were applied. As a result, ARIMA (0,1,0), ARIMA (3,1,2), and ARIMA (5,1,0) were identified as candidate models. Based on evaluation criteria such as the Akaike Information Criterion (AIC), the Bayesian Information Criterion (BIC), the Durbin-Watson statistic (DW), and the coefficient of determination (R^2), ARIMA (3,1,2) was determined to be the most suitable model. According to the findings, sheep meat production in 2022 nearly doubled compared to 1961. Over the entire 62-year period, the compound annual growth rate was calculated at 1.13%, while production increased by 10.94% in 2023 compared to 2018. The projected average growth rate for the period 2023–2027 is estimated at 1.10%. Accordingly, the annual production during this period is expected to be 495,303.39, 501,174.64, 514,430.42, 518,809.68, and 523,181.87 tons, with an average of approximately 510,580 tons. In this context, sustaining the upward trend in sheep meat production observed recently, particularly due to government support, will require policies focused on improving productivity in small-scale ruminant farming, reducing input and labor costs, supporting the genetic improvement of native breeds, and encouraging collective action among producers. These measures will contribute to strengthening efficient and high-quality production in the sector.

Keywords: Agricultural Policy, Growth Rate, Meat Production, Time Series Analysis

Ahmet Semih UZUNDUMLU¹ 
Gülsüm DEMİR¹ 

¹ Atatürk University, Faculty of Agriculture, Department of Agricultural Economics, Erzurum, Türkiye



This article is based on a part of Gülsüm DEMİR's Master's thesis.

Geliş Tarihi/Received 10.06.2025
Kabul Tarihi/Accepted 14.07.2025
Yayın Tarihi/Publication Date 24.07.2025

Sorumlu Yazar/Corresponding author:
Ahmet Semih UZUNDUMLU
E-mail: asuzsemi@atauni.edu.tr
Cite this article: Uzundumlu, A.S. & Demir, G (2025). Forecasts for Sheep Meat Production in Türkiye for the 2023–2027 Period. *Journal of Animal Science and Economics*, 4(2), 75–80.



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Giriş

İnsan yaşamının sürdürülebilirliği için elzem olan temel ihtiyaçların başında beslenme yer almaktadır. Yeterli ve dengeli beslenme ise değişen ve gelişen dünyada en önemli konulardan biri haline gelmiştir. Gritzner (2009)'un yaptığı çalışmada da belirttiği gibi dünya nüfusunun zaman içerisinde sürekli artış göstermesi, gıda üretiminin bu talebi karşılayıp karşılayamayacağına dair etik ve stratejik soruları gündeme getirmektedir. Nüfus artışıyla birlikte artan beslenme ihtiyacı, yalnızca günümüz bireylerinin değil, gelecek kuşakların da gıda güvencesini tehdit edebilecek bir gelişmedir (Thompson, 2015).

Hayvancılık sektörü, küresel sera gazı emisyonlarının başlıca kaynaklarından biri olmasının yanı sıra, amonyak salınımı ve bölgesel besin dengesizlikleri gibi çevresel sorunlarla da ilişkilidir (Gerber vd., 2013). Et ürünleri, özellikle protein ve amino asitlerin biyoyararlanımı açısından iyi bilinmekle birlikte, demir, çinko ve B12 vitamini gibi hayati mikronutrientlerin de en iyi kaynaklarıdır. Bu besinler genellikle yalnızca hayvansal kaynaklarda bulunmakta veya buralarda daha kolay emilmektedir. Ayrıca sakatatlar, A ve D vitaminleri, folat, selenyum ve kolin gibi önemli mikro besinler açısından güvenilir kaynaklardır (Stevens vd., 2022). Et, yalnızca enerji ve protein sağlamakla kalmayıp, kompleks bir gıda matrisi içinde birçok temel besin ögesi ve biyolojik açıdan aktif bileşeni bir arada sunmaktadır. Günümüzde de sağlık ve gelişim için önemli bir fonksiyon üstlenen etin diyetten çıkarılması veya tüketiminin ciddi ölçüde azaltılması, bireyler ve toplumlar için önemli beslenme riskleri doğurabilir. Etin kronik hastalık riskindeki rolü ve çevresel etkileri tartışılırken, besinsel faydalarının göz ardı edilmemesi gerekmektedir (Leroy vd., 2023).

Koyun yetiştiriciliği, insanlık tarihinin en eski hayvancılık faaliyetlerinden biri olup Arkeolojik bulgular, koyunun ilk olarak M.Ö. 9000'li yıllarda Güneydoğu Anadolu, Kuzey Mezopotamya ve İran'ın Zagros Dağları çevresinde evcilleştirildiğini göstermektedir. Bu bölge, "Bereketli Hilal" olarak da bilinen ve tarım ile hayvancılığın başladığı alanlar olarak bilinmektedir (Zeder, 2008). Koyun eti üretiminde 1961 yılında Avrupa kıtası dünya koyun eti üretiminin %37,3'lük en büyük payına sahipken, bu oran 2023'te %9,1'e kadar gerilemiştir. Benzer şekilde, Okyanusya'nın payı 21,1%'den 11,2%'ye düşmüştür. Amerika kıtasında ise 1961'de %14,9 olan pay, 2023'e gelindiğinde %3,7'ye inmiştir. Buna karşılık, Asya kıtasının koyun eti üretimindeki payı 1961'de %17,2 iken, özellikle son yıllarda ciddi bir artış göstererek 2023'te %58,6'ya ulaşmıştır. Afrika ise artan bir eğilimle, 1961'de %9,5 olan payını 2023'te %17,3'e yükseltmiştir (FAOSTAT, 2025). Bu veriler, koyun eti üretiminde küresel ölçekte coğrafi kaymaların yaşandığını ve özellikle Asya'nın üretim lideri haline geldiğini

göstermektedir. Ayrıca ülkeler bazında dikkate alındığında 2023 yılı verilerine göre dünya koyun eti üretimi yaklaşık 11,5 milyon ton olup, bu üretimde Çin %24,4 payla lider konumdadır. Hindistan, %9,9 payla ikinci sırada yer alırken, Avustralya %7,4, Türkiye %4,9, Yeni Zelanda %3,8, Cezayir %3,1, Birleşik Krallık %2,5, Sudan %2,3, Pakistan %2,2 ve Özbekistan %2,1 paylarıyla önde gelen diğer üretici ülkeler arasında bulunmaktadır (FAOSTAT, 2025). Bu veriler, özellikle Çin ve Hindistan'ın koyun eti üretiminde önemli roller üstlendiğini ve Türkiye'nin de dünya üretiminde kayda değer bir paya sahip olduğunu göstermektedir.

Koyun yetiştiriciliğinin avantajları arasında, koyunların farklı çevresel koşullara uyum sağlama yeteneği ve zorlu iklim koşullarına karşı dayanıklılığı öne çıkmakta, özellikle yarı kurak ve dağlık bölgelerde sürdürülebilir hayvancılık için önemli bir avantaj sağlamaktadır (Toro-Mujica vd., 2019). Yarı kurak bölgelerde koyun üretim sistemleri çoğunlukla yerli ırkların kullanıldığı, doğal meraya dayalı ekstansif yetiştiricilik şeklindedir (Silveira vd., 2021). Bu yerli ırklar, özellikle iklim değişikliğine karşı dayanıklılıkları nedeniyle, hayvansal üretimde adaptasyon ve koruma açısından kritik bir rol oynamaktadır (McManus vd., 2014). Ayrıca, büyükbaş hayvancılıkla karşılaştırıldığında, koyunların üreme ve adaptasyon sürelerinin kısa olması ile düşük kaliteli meralardan etkin şekilde yararlanabilmeleri, bakım ve besleme maliyetlerinin önemli ölçüde azalmasına katkı sağlamaktadır (Tamer ve Sarıözkan, 2017). Bunun yanı sıra, küçükbaş hayvancılık, et, süt, yün, tiftik, kıl, deri ve gübre gibi çeşitli ürünlerin elde edilmesini sağlamaktadır (Sevinç vd., 2022).

Koyun eti üretim tahminleri, arz-talep dengesinin korunması, fiyatların istikrara kavuşması, kaynak kullanımının optimize edilmesi, ticaret politikalarının geliştirilmesi ve gıda güvencesinin sağlanması açısından kritik bir rol oynamakta bu durumda üreticiler, tüketiciler ve politika yapıcılar, sektörde sürdürülebilirliği ve dengeyi temin etmek için bilinçli kararlar verebilmektedir.

Son yıllarda Türkiye'de koyunculukla ilgili üretim tahminlerine yer veren çalışmalar sınırlı sayıdadır. Bu alandaki önemli çalışmalardan biri olan Eser ve Erat (2025), Türkiye'de koyun üretiminin son yüzyıldaki gelişimini analiz etmiş ve mevcut veriler doğrultusunda geleceğe yönelik üretim trendlerini tahmin etmiştir. Diğer yandan Şen (2023), Türkiye'nin kırmızı et üretimini sığır, manda, koyun ve keçi etleri olarak ayrı ayrı ele almış ve bu üretim kalemleri için Grey Markov Zincir Modeli kullanarak tahminlerde bulunmuştur.

Sonuç olarak bu çalışmada dünyada koyun eti üretiminde 4. sırada yer alan Türkiye'nin 1961-2022 yıllarına ait 62 yıllık koyun eti üretim verileri ARIMA (3,1,2) modelinde analize tabi tutularak 2023-2027 yıllarına ait tahminler yapılmıştır.

Yöntem

Materyal

Çalışmanın ana materyalini ulusal düzeyde koyun ve koyun eti üretimine dair elde edilen sayısal veriler oluşturmıştır. Bunun için birincil veri kaynağı olarak Birleşmiş Milletler ve Gıda Örgütü İstatistik Veri Tabanı (FAOSTAT) ve Türkiye İstatistik Kurumu'nun (TÜİK) yayınlamış olduğu resmi istatistikler başta olmak üzere; çeşitli akademik tezler, bilimsel raporlar, kitaplar ve makaleler gibi ikincil verilerden de yararlanılmıştır. Bu doğrultuda 1961-2022 yılları arası koyun eti üretim hacmi ve diğer göstergeler incelenerek 2023-2027 arası döneme dair projeksiyonlar geliştirilmiş ve bu tarih aralığına yönelik tahmin yapılmıştır.

Yöntem

Makale kapsamında elde edilen verilerin analizinde, analiz öncesi veri düzenlemeleri ve modelleme sonuçlarının yorumlanması sürecinde SAS(Statistical Analysis System) 9.4 istatistik yazılım programı kullanılmıştır. Aynı verilerin zaman serisinde gösterdiği değişimlerin incelenmesinde geleceğe yönelik tahminsel hesaplama yapabilmek için ekonometrik bir model olan ARIMA tahmin yönteminden yararlanılmıştır. Bu yöntem zaman serilerinin dinamik yapısını göz önünde bulundurarak istatistiksel olarak güvenilir senaryolar sunmaktadır. Tahmin sonucu alınan değerlerin görselleştirilmesi ve grafiklerinin oluşturulması için ise Microsoft Excel programı destekleyici araç olarak devreye girmiştir.

Box-Jenkins (ARIMA) Tahmin Yöntemi

Hayvansal üretim bir insanın eğitilmesine benzer şekilde, yapılan politikaların ve yatırımların sonucunun uzun bir zaman diliminde görüldüğü bir sektördür. Bu nedenle geleceğe yönelik daha realist politikaların oluşturulmasında sağlıklı ve tutarlı tahminlerin yapılabilmesi için sağlam bir veri mekanizmasına ve bu verileri çözümleyebilecek zaman serisi analizlerine ihtiyaç duyulmaktadır. Bunlardan biri olan ARIMA yöntemi Gwilym Jenkins ve George Box'ın 1970 yılında birlikte geliştirdiği tek değişkenli bir zaman serisi tahmin yöntemidir ve yaygın olarak Box-Jenkins adıyla bilinen bu yaklaşım Otoregresif Model (AR) ve Hareketli Ortalama Modelinin (MA) sentezlemesiyle Bütünleşik Otoregresif Hareketli Ortalama Süreci (ARIMA) şeklinde tanımlanmıştır.

Yöntemde model belirleme, parametre tahmini ve modelin yeterlilik kontrolü yapılarak en uygun model belirlenerek bu model sonucunda tahminler yapılabilmektedir. Modelin uygunluğunu değerlendirmeye yönelik tahmin ve teşhis sürecinde çeşitli kontrol istatistikleri kullanılmakta ve parametre tahminlerine uygulanan anlamlılık testleri modelin zaman serisindeki tüm dalgalanmaları yeterli seviyede açıklama durumunu saptamak amacıyla kullanılmaktadır. Test

sonuçlarında modelde bir yetersizlik veya tutarsızlık çıkarsa daha uygun bir model meydana getirmek için sürecin başında yer alan model seçme aşamasına geri dönüşümlü gerekmektedir (Hosny vd., 2023; Uzundumlu vd., 2023). Bu aşamalar sorunsuz bir şekilde gerçekleştiği takdirde SAS istatistik programında SCAN ve ESACF yöntemleriyle belirlenen en uygun modeller AIC, BIC, Schwarz Bayesian Criterion (SBC), Sum of Squared Errors (SSE), Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), Hannan-Quinn Criterion (HQC) değerlerinin en küçüğü ile DW'nin 2.00'a ve R²'si 1'e en yakın olan sonuçlara göre en fazla kriteri sağlayan model en uygun ARIMA modeli olarak kabul edilmiştir (Uzundumlu and Dilli, 2023).

ARIMA modelinin uygulanabilme şartı serinin durağan olması olup durağan olmayan zaman serilerini ise durağan hale getirmek için veriler üzerinde fark alma işlemi uygulanmaktadır. Bu şekilde verinin trend ve mevsimsel etkilerinden arındırılmasını sağlanmaktadır. Modeli meydana getiren üç bileşen ise geçmiş değerlerin etkisinin göstergesi olan AR(p), veri dizisini durağanlaştırmak için gerekli fark alma sayısını tanımlayan I(d) ve geçmiş hata terimlerinin etkisini belirten MA(q) parametreleridir.

AR modeli formül 1'de ve değişken oluşumu formül 2'de verilmiştir (Shumway vd., 2000)

$$y_t = (\alpha + \sum_{i=1}^p \varphi_i * y_{t-i} + \varepsilon_t) \quad (1)$$

$$\alpha = \mu(1 - \varphi_1 - \varphi_2 \dots - \varphi_p) \quad (2)$$

MA modeli formül 3'teki gibidir.

$$y_t = (\alpha + \sum_{i=1}^q \theta_i * \varepsilon_{t-i}) \quad (3)$$

ARMA modeli ise formül 4'teki gibi ifade edilmiştir.

$$y_t = (\alpha + \sum_{i=1}^p \varphi_i * y_{t-i} + \varepsilon_t) + (\sum_{i=1}^q \theta_i * \varepsilon_{t-i}) \quad (4)$$

ARMA modelini açınca formül 5 elde edilmektedir (Mishra vd., 2021)

$$y_t = \alpha + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (5)$$

ARIMA modelinde 5.formüle dönemsel fark işlemi eklenerek formül 6 elde edilmiştir.

$$y_t = (\alpha + \sum_{i=1}^p \varphi_i * y_{t-i} + \varepsilon_t) * (1 - B)^d + (\sum_{i=1}^q \theta_i * \varepsilon_{t-i}) \quad (6)$$

ARIMA modelin bir başka oluşumu formül 7'de verilmiştir (SAS, 2025).

$$\varphi(B)(1 - B)^d * y_t = \theta(B) * \varepsilon_t \quad (7)$$

Altıncı formül yedinci formüle uyarlanınca 8. formül elde edilmiştir (Kadılar, 2009).

$$(1 - a_1 B^1 - a_2 B^2 \dots - a_p B^p) * (1 - B)^d y_t = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (8)$$

$(1 - B)^d$ terimi d'ninci dereceden fark işlemi olup, $(1 - B)^d y_t$ ifadesi d=1 için $By_t = y_{t-1}$ diye yazılabilir. Ayrıca d=2 için $B^2 y_t = y_{t-2}$ veya $B^1 y_{t-1} = y_{t-2}$ yazılabilmektedir.

p=3, d=1 ve q=2 olduğundaki model ARIMA (3,1,2) yani

$$(1 - a_1 B^1 - a_2 B^2 - a_3 B^3) * (1 - B)^1 y_t = (1 - \theta_1 B - \theta_2 B^2) \varepsilon_t \text{ olmaktadır.}$$

Formüllerde yer alan;

$y_t = t$ zamandaki serideki gözlem değerlerini,

$\alpha =$ sabit sayıyı,

$\varphi_i = i$ gecikme süresindeki y_t -i'nin parametrelerini,

$\varepsilon_t = t$ zamandaki beyaz gürültüyü ($WN(0, \sigma^2)$ şeklinde gösterilmektedir)

p= AR için maksimum gecikme süresini,

q= MA için maksimum gecikme süresini,

$\theta_i = i$ gecikme süresindeki ε_t -i'nin parametrelerini ve

$(1 - B)^d = d$ 'ninci dereceden fark işlemi göstermektedir.

Ayrıca a_1, a_2 ve a_3 Otoregresif (AR) terim katsayılarını (p = 3)

θ_1 ve θ_2 Hareketli ortalama (MA) terim katsayılarını (q = 2) ifade etmektedir (Uzundumlu vd., 2023).

Durağan olmayan zaman serileri, genellikle fark alma ya da logaritmik dönüşüm gibi yöntemler kullanılarak durağan hale getirilmektedir (Akgül, 2003; Hosny vd., 2023). Zaman serisinin durağan olup olmadığını belirlemek amacıyla çeşitli testler uygulanmaktadır. Bu testler arasında Augmented Dickey-Fuller (ADF) testi, Phillips-Perron (PP) testi ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) testi yer almakta olup bu çalışmada Augmented Dickey-Fuller (ADF) testi, Phillips-Perron (PP) testi kullanılmıştır (Uzundumlu vd., 2023). Zaman serilerinde durağanlığın tespitine yönelik uygulanan testlerde, sıfır hipotezi genellikle serinin birim kök içerdiği, yani durağan olmadığı yönündedir. Dolayısıyla serinin durağan olduğunun kabul edilebilmesi için, sıfır hipotezinin reddedilmesi gerekmektedir. Zira test sonuçlarına göre seride birim kök çıkması durumunda fark alınması zorunlu olmaktadır. Böyle bir durumda verilerde White Noise (Beyaz Gürültü) olma ihtimali yükselmektedir (Maity & Maity, 2018).

Tablo 1.

Türkiye için p ve q Değerlerine göre Sıralama Ölçüt Testleri

p	q	BIC	MSE	SBC	MAE	MAPE	DW	AIC	HQC	R ²
0	0	20,96	11,75	1 402,69	17,19	193,74	1,98	1.400,61	1.401,42	0,49
3	2	21,27	11,71	1 402,47	17,61	263,01	1,98	1.400,39	1.401,20	0,49
5	0	21,27	11,75	1 402,69	17,26	3180,17	1,98	1.400,61	1.401,43	0,49

* MSE değerleri 10⁸ ve MAE değerleri 10³ ile çarpılmalıdır.

Bu aşamada modelin kurulumu tamamlanmış ve ilgili parametrelerin tahminleri elde edilmiştir. İzleyen süreçte, model belirsizliğini en aza indirmek amacıyla SCAN ve ESACF yöntemleri kullanılarak önerilen modeller arasında karşılaştırma yapılmıştır. Bu çalışmada model uygunluğu, yalnızca AIC ve BIC ile sınırlı kalmaksızın; Schwarz Bayesian Criterion (SBC), Sum of Squared Errors (SSE), Mean Squared Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), Hannan-Quinn Criterion (HQC) farklı performans göstergeleri temel alınarak değerlendirilmiştir. Buna ek olarak, Durbin-Watson istatistiğinin 2.00 değerine yakınlığı ve belirleyicilik katsayısı (R²) değerinin 1'e yaklaşması da göz önünde bulundurularak, bu kriterlerin büyük bölümünü karşılayan model en uygun ARIMA modeli olarak çalışmada kullanılmıştır.

Bulgular

Türkiye'nin Mevcut ve Tahmini Koyun eti Üretimi


Tablo 1'de SCAN ve ESACF ile belirlenen en uygun modellerin belirli ölçütler açısından incelenmesi verilmiştir.

Tablodan anlaşıldığı üzere bu modellerden ARIMA (0,1,0) ise BIC, MAE, MAPE ön plana alındığında en iyi model olarak görülmektedir. Diğer yandan ARIMA (5,1,0) modeli sadece R² değeri ile en iyi model konumundadır. Son olarak ARIMA (3,1,2) modeli ise MSE, SBC, DW, AIC, HQC ve R² değerlerinde iyi olduğu için en iyi model olarak seçilmiştir.

Şekil 1'de ise 1961-2027 yıllarını kapsayan koyun eti üretim verileri ve buna bağlı olarak üretim tahminleri verilmiştir.

Türkiye'nin süregelen 62 yıllık zaman zarfında 243 bin ton bandında başlayan koyun eti üretimi 1971 ve 1981 yılları arasında 300 bin ton seviyesine çıkıp yükselerek ilk dört ülke arasında yer alırken daha sonra 1981 ve 2000 yılları arasında 100 bin tona kadar düşüş göstermiştir. Keza yaşanan siyasi olaylar, hayvancılık politikalarının yetersiz olmasının yanında gerektiği gibi uygulanamaması ve kente doğru göçlerin artması bu düşüşün nedenleri arasında sayılabilir. 2001'den sonra 2010 yılına kadar tekrar 200 bin ton seviyelerine çıkan üretim miktarı 2010 sonrası uygulanan tarım destekleri ile yeniden 350 bin ton noktasını görmüştür. Sonraki süreçte daha iyileşen bir seyir izleyerek 2022 yılına kadar 500 bin ton düzeyine çıkmıştır. Bu miktar ile Türkiye yeniden küresel koyun eti üretimi arenasında kendine yer bulmuştur.

Şekil 1.
1961-2027 yıllarında Türkiye koyun eti üretim tahmini (bin ton)



Tartışma

Bu çalışmada kullanılan ARIMA (3,1,2) modeli ile Türkiye'nin koyun eti üretimine ilişkin 62 yıllık veri analizi yapılmış ve 2023–2027 dönemi için yıllık ortalama %1,10 büyüme oranı ile sırasıyla 495.303, 501.175, 514.430, 518.810 ve 523.182 tonluk üretim tahmin edilmiştir. Bu bulgular, Eser ve Erat'ın (2025) çalışmalarında nitel bir yaklaşımla ortaya konan, 2010 sonrası tarım politikalarının üretimde artış sağladığı yönündeki tespiti nicel olarak desteklemektedir; üretimin gelecek yıllarda da artış eğiliminde olacağına dair ortak bir çerçeve sunmaktadır. Kullanılan üç farklı modelin 2023–2030 dönemi için ortaya koyduğu tahminlere göre, ARIMA modeli sabit bir seyir öngörerek koyun sayısında herhangi bir değişim öngörmemektedir. Buna karşılık, SARIMA ve Holt-Winters modelleriyle yapılan tahminlerde, 2023 yılında 42 milyon olan koyun sayısının 2030 yılına kadar 63–64 milyon seviyelerine ulaşacağı öngörülmektedir. Bu tahminler, yaklaşık %5 yıllık bileşik büyüme oranına karşılık gelmekte olup, bizim çalışmamızda elde edilen sonuçlara kıyasla daha yüksek bir büyüme eğilimini işaret etmektedir. Sen (2023) tarafından Grey Sistem Teorisi kapsamında uygulanan GM(1,1) modeli ile yapılan tahminlere göre, koyun eti üretiminin 395.876 ile 547.238 ton arasında değişeceği ve yıllık ortalama üretimin 468.296 ton olacağı öngörülmektedir. Grey-Markov zincir modeli ise üretimin 392.111 ile 476.188 ton arasında gerçekleşeceğini ve yıllık ortalama üretimin 463.842 ton düzeyinde olacağını ifade etmektedir. Bu iki yöntem ortalaması bizim çalışmayla uyumlu olup bu durum, farklı modelleme yaklaşımlarının benzer üretim eğilimlerini öngörmesi bakımından önemlidir.

SONUÇLAR

Türkiye'nin koyun eti üretimindeki küresel payı, 1971–1980 döneminde yaklaşık 300.000 tonluk üretim düzeyi ve %5,34'lük oranıyla dünya sıralamasında ilk dört ülke arasında yer alırken; izlenen yetersiz hayvancılık politikaları, kırsal göçün artması ve tüketici tercihlerindeki olumsuz değişimlerin etkisiyle 1981–2000 yılları arasında üretim 100.000 ton seviyelerine kadar gerilemiştir. 2001–2010 döneminde üretimde kısmi bir toparlanma gözlenmiş ve 200.000 ton civarlarına ulaşılmıştır. Özellikle 2011–2020 yılları arasında uygulanan tarımsal destek programlarının etkisiyle üretim 350.000 tona yükselmiş; 2020–2022 döneminde ise bu ivme devam ederek üretim miktarı 500.000 tona ulaşmış ve Türkiye %4,31'lik küresel payla yeniden ilk dört üretici ülke arasında yer almayı başarmıştır. Önümüzdeki beş yıllık dönemde (2023–2027), üretimdeki artışın daha ılımlı bir seyir izlemesi ve yıllık bileşik büyüme oranının %1,10 düzeyinde gerçekleşmesi beklenmekte; bu doğrultuda 2027 yılında koyun eti üretiminin yaklaşık 525.000 tona ulaşacağı öngörülmektedir. Mevcut olumlu eğilimin sürdürülmesi için hayvancılıkta sürdürülebilir politikaların uygulanması, üretici desteklerinin artırılması ve iklimsel ya da epidemiyolojik olumsuzluklara karşı hazırlıklı olunması halinde, Türkiye'nin küçükbaş hayvancılık potansiyelini daha da geliştirerek küresel üretimdeki konumunu güçlendirmesi mümkündür.

Etik Komite Onayı: FAOSTAT veriler kullanıldığından etik kurul onayına gerek yoktur.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Fikir - A.S.U.; Tasarım - A.S.U.; Denetleme - A.S.U.; Kaynaklar -; A.S.U.-; Makale Yazımı - A.S.U., G.D.; Eleştirel İnceleme - A.S.U.; Diğer - G.D.

Çıkar Çatışması: Yazarlar, çıkar çatışması olmadığını beyan etmiştir.

Finansal Destek: Yazarlar bu çalışmanın herhangi bir finansal destek almadığını beyan etmişlerdir.

Ethics Committee Approval: Ethics committee approval is not required as FAOSTAT data were used.

Peer-review: Externally peer-reviewed.

Author Contributions: Concept - A.S.U.; Design - A.S.U.; Supervision - A.S.U.; Resources -; A.S.U.; Writing Manuscript - A.S.U., G.D.; Critical Review - A.S.U.; Other - G.D.

Conflict of Interest: The authors have no conflicts of interest to declare.

Financial Disclosure: The authors declared that this study has received no financial support.

Kaynaklar

- Akgül, İ. (2003). *Zaman serilerinin analizi ve ARIMA modelleri*. Der Yayınları.
- Eser, E., & Erat, S. (2024). Türkiye koyunculüğünün yüzyılı ve gelecek tahmini. In P. A. Demir (Ed.), *Bozırık'ta koyunculuk: Tarımsal üretim döngüsünün*

- sürdürülebilirliği açısından stratejik bir sektör (Bölüm 1, ss. 3-22). İksad Yayın Evi.
- FAOSTAT. (2025). *Meat production*. <http://www.fao.org/faostat/en/#data/QC> (Erişim tarihi: 05.06.2025)
- Gerber, P. J., Steinfeld, H., Henderson, B., Mottet, A., Opio, C., Dijkman, J., ... & Tempio, G. (2013). *Enfrentando el cambio climático a través de la ganadería*. Food and Agriculture Organization of the United Nations (FAO), Rome. <http://www.fao.org/3/i3437e.pdf>.
- Gritzner, C. F. (2009). *Feeding a hungry world*. Infobase Publishing.
- Hosny, S., Elsaid, E., & Hosny, H. (2023). Prediction of construction material prices using ARIMA and multiple regression models. *Asian Journal of Civil Engineering*, 1-14. <https://doi.org/10.1007/s42107-023-00597-2>
- Kadılar, C. (2009). *SPSS uygulamalı zaman serileri analizi*. Bizim Büro Kitabevi.
- Leroy, F., Smith, N. W., Adesogan, A. T., Beal, T., Iannotti, L., Moughan, P. J., & Mann, N. (2023). The role of meat in the human diet: Evolutionary aspects and nutritional value. *Animal Frontiers*, 13(2), 11-18. <https://doi.org/10.1093/af/vfac093>.
- Maity, R., & Maity, R. (2018). Time series analysis. In *Statistical methods in hydrology and hydroclimatology* (pp. 305-379), Springer.
- McManus, C., Hermuche, P., Paiva, S., Ferrugem Moraes, J., de Melo, C., & Mendes, C. (2014). Geographical distribution of sheep breeds in Brazil and their relationship with climatic and environmental factors as risk classification for conservation. *Brazilian Journal of Science and Technology*, 1(3). <https://doi.org/10.1186/2196-288x-1-3>
- Mishra, S., Swain, D. K., Mishra, D., & Santra, G. H. (2021). Time series analysis of rainfall for Puri District of Odisha using ARIMA modelling. In *Intelligent and Cloud Computing: Proceedings of ICICC 2019, Volume 2* (pp. 419-426).
- SAS Institute Inc. (2014). *SAS 13.2 user's guide: The ARIMA procedure*. <https://support.sas.com/documentation/onlinedoc/ets/132/ARIMA.pdf> (Erişim tarihi: 09.06.2025)
- Şen, H. (2023). Estimation of red meat production in Turkey according to the Grey-Markov Chain Model. *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, 23, 179-188. <http://www.epstem.net/tr/download/article-file/3430996>.
- Sevinç, G., Şahin, Z., & Aydoğdu, M. (2022). Türkiye'nin küçükbaş hayvan varlığı ile süt üretimindeki gelişmelerin son dönemlerindeki trend analizi. *ASR Journal*, 35(7), 377-384. <https://doi.org/10.29228/ASRJOURNAL.57885>.
- Shumway, R. H., & Stoffer, D. S. (2000). *Time series analysis and its applications* (Vol. 3). Springer.
- Silveira, R. M. F., Vasconcelos, A. M., Silva, J. V. da, Vega, W. H. O., Toro-Mujica, P., & Ferreira, J. (2021). Typification, characterization and differentiation of sheep production systems in the Brazilian semiarid region. *NJAS - Impact in Agricultural and Life Science*, 1, 48-73. <https://doi.org/10.1080/27685241.2021.19562>
- Stevens, G. A., Beal, T., Mbuya, M. N., Luo, H., Neufeld, L. M., Addo, O. Y., ... & Young, M. F. (2022). Micronutrient deficiencies among preschool-aged children and women of reproductive age worldwide: A pooled analysis of individual-level data from population-representative surveys. *The Lancet Global Health*, 10(11), e1590-e1599. [https://doi.org/10.1016/S2214-109X\(22\)00367-9](https://doi.org/10.1016/S2214-109X(22)00367-9).
- Tamer, B., & Sarıözkan, S. (2017). Yozgat merkez ilçede koyunculuk yapan işletmelerin sosyo-ekonomik yapısı ve üretim maliyetleri. *Erciyes Üniversitesi Veteriner Fakültesi Dergisi*, 14(1), 39-47.
- Thompson, P. B. (2015). From world hunger to food sovereignty: Food ethics and human development. *Journal of Global Ethics*, 11(3), 336-350. <https://doi.org/10.1080/17449626.2015.1100651>.
- Toro-Mujica, P., Arraño, C., Vera, R., Robles, L., Río, C. del, Corvalán, E., & Riveros, J. L. (2019). Perspectives of abandonment/continuity of typological groups of sheep farms in the semi-arid region of Central Chile. *Economía Agraria y Recursos Naturales*, 19(2), 113-132. <https://doi.org/10.7201/earn.2019.02.06>
- Uzundumlu, A. S., Zeynalova, A., & Engindeniz, S. (2023). Cotton production forecasts of Azerbaijan in the 2023-2027 periods. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 60(2), 235-245. <https://doi.org/10.20289/zfdergi.1296642>
- Uzundumlu, A. S., & Dilli, M. (2023). Estimating chicken meat productions of leader countries for 2019-2025 years. *Ciência Rural*, 53(2), 1-12. <https://doi.org/10.1590/0103-8478cr20210477>.
- Zeder, M. A. (2008). Domestication and early agriculture in the Mediterranean Basin: Origins, diffusion, and impact. *Proceedings of the National Academy of Sciences*, 105(33), 11597-11604. <https://doi.org/10.1073/pnas.0801317105>.

Aspir Küspesine (*Carthamus tinctorius*) yem katkı maddesi olarak Çınar Yaprığının (*Platanus orientalis* L.) ilavesinin; *In Vitro* Gaz Üretimi ve Sindirilebilirlik Parametreleri Üzerine Etkisi

The Effect of Supplementing Safflower Meal (*Carthamus tinctorius*) with Plane Tree Leaf (*Platanus orientalis* L.) as a Feed Additive on *In Vitro* Gas Production and Digestibility Parameters

Atilla BAŞER¹

Ali KAYA²

Tuğba BAKIR¹

Bilal SELÇUK³

¹ Kahramanmaraş Sütçü İmam University, Faculty of Agriculture, Department of Animal Science, Kahramanmaraş, Türkiye

² Atatürk University, Faculty of Agriculture, Department of Animal Science, Erzurum, Türkiye

³ Ondokuz Mayıs University, Ladik Vocational School, Department of Crop and Animal Production, Ladik, Samsun, Türkiye



ÖZ

Bu çalışma, ruminant beslenmesinde alternatif yem katkı maddeleri kullanımı kapsamında, aspir küspesine (*Carthamus tinctorius*) ilave olarak çınar yaprağının (*Platanus orientalis* L.) potansiyelini değerlendirmek amacıyla yürütülmüştür. Çalışmada, aspir küspesine farklı oranlarda çınar yaprağı (%0, %1, %2 ve %4) ilavesiyle oluşturulan deneme gruplarının *in vitro* gaz üretimi, tahmini sindirim ve enerji parametreleri, pH, TUYA ve NH₃-N değerleri belirlenmiştir. Gaz üretimi, Hohenheim gaz üretim tekniğiyle 24 saatlik inkübasyon sürecinde ölçülmüş, elde edilen veriler doğrultusunda metabolik enerji (ME), net enerji laktasyon (NE_L) ve organik madde sindirim derecesi (OMSD) hesaplanmıştır. Ayrıca rumen fermentasyonunu etkileyen tanen içeriği de dikkate alınarak mikrobiyal faaliyetler üzerindeki olası etkiler yorumlanmıştır. Elde edilen sonuçlar incelendiğinde gerçek sindirilen kuru madde miktarı, mikrobiyal protein, gerçek sindirim derecesi ve NH₃-N değerleri bakımından gruplar arasındaki farklılıklar linear olarak önemli bulunmuştur ($p < 0.05$). Katkı maddesi olarak katılan çınar ağacı yaprağının yapısında bulunan tanenin anti-mikrobiyal ve anti-nutrisyonel özelliklerinden dolayı sindirimi ve sindirim sonucu oluşan parametreleri olumsuz etkilediği sadece hayvansal üretim açısından önem arz eden NH₃-N değerinin azalmasında destekleyici etki gösterdiği tespit edilmiştir. Bu bağlamda çınar yaprağı gibi tanen içeren kaynakların sürdürülebilir ve yerel kaynaklı bir yem katkı maddesi olarak protein içeriği yüksek yemlerde ya da rasyonlarda kullanılabileceği öngörülmüş olup *in vivo* çalışmalarla desteklenmesi kanaatine varılmıştır.

Anahtar Kelimeler: Aspir küspesi, Çınar yaprağı, *In vitro* gaz üretimi, Ruminant beslenmesi, Sindirilebilirlik, Yem katkı maddesi

ABSTRACT

This study was conducted to evaluate the potential of plane tree leaf (*Platanus orientalis* L.) as a substitute for safflower meal (*Carthamus tinctorius*) within the scope of utilizing alternative feed additives in ruminant nutrition. In the study, experimental groups were prepared by supplementing safflower meal with plane tree leaf at different inclusion levels (0%, 1%, 2%, and 4%). For these groups, *in vitro* gas production, estimated digestibility and energy parameters, pH, total volatile fatty acids (VFA), and NH₃-N concentrations were determined. Gas production was measured using the Hohenheim gas production technique during a 24-hour incubation period, and based on the obtained data, metabolizable energy (ME), net energy for lactation (NE_L), and organic matter digestibility (OMD) were calculated. Additionally, considering the tannin content of plane tree leaf, its potential effects on microbial activity related to rumen fermentation were interpreted. Upon evaluation of the results, differences among groups in terms of truly digested dry matter, microbial protein synthesis, true digestibility, and NH₃-N concentrations were found to be linearly significant ($p < 0.05$). It was determined that tannins present in plane tree leaf, when used as a feed additive, exhibited antimicrobial and anti-nutritional properties, which negatively affected digestibility and the resulting fermentation parameters, while showing a beneficial effect by reducing NH₃-N levels a parameter of particular importance in animal production. In this context, it was concluded that tannin-containing resources such as plane tree leaf may be utilized as sustainable and locally sourced feed additives, especially in high-protein feeds or rations, although this potential should be further supported by *in vivo* studies.

Keywords: Digestibility, Feed additive, *In vitro* gas production, Plane tree leaves, Ruminant nutrition, Safflower meal



Geliş Tarihi/Received 18.06.2025
Kabul Tarihi/Accepted 18.07.2025
Yayın Tarihi/Publication Date 24.07.2025

Sorumlu Yazar/Corresponding author:

Atilla BAŞER

E-mail: atillaabaser@gmail.com

Cite this article: Başer, A., Kaya, A., Bakır, T. & Selçuk, B (2025). The Effect of Supplementing Safflower Meal (*Carthamus tinctorius*) with Plane Tree Leaf (*Platanus orientalis* L.) as a Feed Additive on *In Vitro* Gas Production and Digestibility Parameters. *Journal of Animal Science and Economics*, 4(2), 81-87.



Content of this journal is licensed under a Creative Commons Attribution-Noncommercial 4.0 International License.

Giriş

Hayvancılık sektöründe artan çevresel zorluklardan dolayı ruminantların beslenmesinde ekonomik ve sürdürülebilir yem kaynaklarının etkin kullanımı giderek önem kazanmaktadır. Bu zorlukların üstesinden gelmek için, ekonomik, sürdürülebilir ve kolay erişilebilir yerel olarak mevcut, yeni yem ve yem bileşeni seçeneklerinin araştırılması ve kullanılması gerekmektedir. Yerel olarak hazır yem kaynaklarının kullanılması üretim maliyetlerini düşürebilir, istihdam olanakları yaratabilir ve sürdürülebilir tarım yöntemlerini geliştirebilir (Herrero vd., 2014; Paul, 2019; Chisoro vd., 2023). Hayvansal üretim maliyetlerini azaltmak ve çevresel etkileri en aza indirmek amacıyla, ruminant rasyonlarına farklı yan ürünlerin ve bitkisel katkıların dâhil edilmesi yaygın bir araştırma konusu olmuştur (Ban & Guan, 2021; Dumlu, 2024). Üretimin her geçen gün artmasının bir sonucu olarak, gelişmiş ülkelerdeki mevcut tarımsal gıda sektörü, önemli miktarda ürün tüketimi ve bertaraf edilmesi gereken atık akışları ile karakterize edilmektedir. Bu nedenle, ekonomik kalkınmayı çevre ve kaynak koruma ile dengeleyen dairesel bir ekonomi modeline geçişi desteklemek üzere stratejilerin korunması tüm tarımsal gıda sektörü için önemli bir konudur (Serrapica vd., 2019). Bu bağlamda, aspir (*Carthamus tinctorius*) küspesi, yüksek protein ve enerji içeriği ile yem endüstrisinde dikkat çeken alternatif bir yem hammaddesi olarak değerlendirilmektedir (Gümüş & Küçükersan, 2016). Ayrıca aspir küspesinin yem değeri soya fasulyesi küspesine (SFK) yakın olup, ülkemizde SFK'ya alternatif olabilme potansiyeline sahip olduğu bildirilmektedir (Özek, 2017). Bitkisel polifenoller, özellikle tanenler, rumen mikrobiyal fermantasyonuna müdahale ederek protein parçalanmasını azaltmakta ve by-pass protein miktarını artırmaktadır (Jayanegara vd., 2018; Besharati vd., 2022). Tanenlerin proteinlerle kompleks oluşturma özelliği, rumende mikrobiyal protein sentez miktarını azaltmadan proteinlerin sindirilmesini engelleyerek ince bağırsakta daha fazla sindirilebilir protein sağlamak ve azot kullanım verimliliğini artırmaktadır (Patra & Saxena, 2011; Besharati vd., 2022). Ayrıca, tanenlerin rumen metan salınımını azaltma potansiyeli olduğu da bildirilmiştir, bu da hem enerji kayıplarını azaltır hem de çevresel sürdürülebilirliğe katkı sağlar (Beauchemin vd., 2008; Arisya vd., 2019). Çınar yaprağı (*Platanus spp.*) tanenler açısından zengin bir bitki olup (Irtiza vd., 2016; Kamalak ve Özkan, 2021), ruminant beslemede yem katkı maddesi olarak kullanıma potansiyeline sahiptir (Kamalak & Özkan, 2021). Çınar yaprağında bulunan tanenlerin, rumendeki protein parçalanmasını baskılayarak bypass protein miktarını artırabileceği ve metan üretimini azaltabileceği düşünülmektedir. Bu özellikleriyle çınar yaprağı, ruminant beslemede hem besin madde verimliliğini artırma hem de çevresel etkileri azaltma açısından önemli bir katkı sağlayabilir.

Bu çalışmada, aspir küspesine farklı oranlarda (%1, %2 ve %4) çınar yaprağı ilavesinin, ruminantlarda *in vitro* gaz üretimi, metan salınımı, metabolik enerji (ME) içeriği, organik madde sindirilebilirlik derecesi (OMSD), mikrobiyal protein sentezi üzerindeki etkileri araştırılacaktır. Çalışma hem ekonomik yem katkılarının değerlendirilmesi hem de hayvancılık sektöründe çevresel sürdürülebilirlik hedeflerine katkı sağlamayı amaçlamaktadır. Bu bağlamda, elde edilecek bulguların, ruminant beslemede alternatif yem katkı maddelerinin geliştirilmesine ışık tutacağı düşünülmektedir.

Yöntem

Materyal

Çalışma da kullanılan Aspir küspesi, Kahramanmaraş ilinde bulunan özel bir yem fabrikasından temin edilmiştir. Yem katkı maddesi olarak kullanılan Çınar ağacı (*Platanus orientalis* L.) yaprakları, Kahramanmaraş ili Onikişubat ilçesinde yetiştirme adaptasyonu bulan en az 10 adet ağaçtan olacak şekilde Nisan 2025 tarihinde hasat edilmiştir. Temin edilen Aspir küspesi ve Çınar ağacı yaprakları laboratuvarında gölgede kurutulduktan sonra analiz yapılmak üzere öğütülmüştür. Çalışma da kullanılacak olan rumen sıvısı, Kahramanmaraş ilinde bulunan özel bir kesimhaneden Kılıç ve Abdiwali (2016) bildirdiği şekilde alınmıştır.

Yöntem

Çalışma da kullanılan aspir küspesi ve çınar ağacı yapraklarının kuru madde (KM), ham kül (HK), ham yağ (HY) ve ham protein (HP) içerikleri AOAC (1990)'a göre Nötr deterjan fiber (NDF) ve Asit deterjan fiber (ADF) içerikleri Van soest vd. (1991)'e göre tespit edilmiş olup, tanen içerikleri ise Makkar vd. (1995)'e göre saptanmıştır.

Tablo 1.

Aspir küspesi ve Çınar ağacı yaprağının kimyasal kompozisyonu

Yemler	Aspir Küspesi	Çınar Yaprığı
KM (%)	91,03	92,08
HK (%)	2,23	5,35
HY (%)	10,71	5,22
HP (%)	23,50	2,93
NDF (%)	66,58	53,37
ADF (%)	52,14	37,77
GÜ (0,2gr/30ml)	26,32	15,60
MÜ(0,2gr/30ml)	3,74	2,02
KT (%)	-	16,45

Kuru madde: KM, Ham kül: HK, Ham yağ: HY, Ham protein: HP, Nötr deterjan fiber: NDF, Asit deterjan fiber: ADF, Gaz üretimi: GÜ, Metan üretimi: MÜ, Kondanse tanen: KT.

Aspir küspesi ve çınar ağacı yapraklarının analiz sonuçları Tablo 1'de verilmiştir. Çalışmanın deneme gruplarını A0 (%0 çınar yaprağı içeren aspir küspesi), A1 (%1 çınar yaprağı içeren aspir küspesi), A2 (%2 çınar yaprağı içeren aspir küspesi) ve A4 (%4 çınar yaprağı içeren aspir küspesi) oluşturmaktadır. Deneme gruplarının gaz üretim miktarları (GÜ) Menke vd. (1979)' da bildirdiği *in vitro* Hohenheim gaz üretim tekniği kullanılarak belirlenmiştir. İnkübasyonun 24. saati sonunda sonunda açığa çıkan gazın metan düzeyleri Infrared Metan Analiz cihazı ile (Sensor Europe GmbH, Erkrath, Germany) tespit edilmiştir (Goel vd., 2008). Deneme gruplarının metabolik enerjisi (ME), net enerji laktasyon (NE_L) ve organik madde sindirim derecesi (OMSD) değerleri Menke ve Steingass (1988)'ın önerdiği eşitlikler ile hesaplanmıştır. İnkübasyon sonrasında gaz ölçümü yapılan şırıngalarda kalan yemlerin gerçek sindirim derecesi (GSD), gerçek kuru madde sindirim miktarı (GSKM), taksimat faktörü (TF), mikrobiyal protein üretimi (MPÜ) ve mikrobiyal protein sentezleme etkinliği (MPSE) ise Blümmel vd. (1997) bildirdiği metoda göre belirlenmiştir. Şırıngalarda bulunan yemlerin pH değerleri, HI 2211 PH/ORP METER (Hanna Instruments, İtalya) cihazı kullanılarak, her numune homojenize edildikten sonra doğrudan ölçülmüştür. Ölçümler, cihazın

kalibrasyonu çift nokta standart tampon çözeltiler (pH 4.01 ve 7.00) ile yapıldıktan sonra gerçekleştirilmiştir. Toplam uçucu yağ asitleri (TUYA) ve amonyak-azot (NH₃-N) analizleri için numuneler santrifüj edilerek süzölmüştür. Süzöntüdeki TUYA ve NH₃-N miktarı, Markham (1942)' de belirttiği prosedürlerine uygun olarak tayin edilmiştir.

İstatistiksel Analiz

Deneme de incelenen parametrelere ait veriler IBM SPSS (IBM SPSS Corp., Armonk, NY, ABD) 20.0 (2011) paket programında varyans analizine tabi tutulmuştur. Gruplara ait ortalamaların karşılaştırılmasında Duncan çoklu karşılaştırma testi (Duncan, 1955), seviyenin etkisini belirlemek için ise polynomial analiz testi kullanılmıştır.

Bulgular

Aspir küspesi içerisine farklı oranlarda katkı maddesi olarak ikame edilen çınar ağacı yapraklarının fermentasyon parametrelerine etkisi tablo 2'de verilmiştir. Elde edilen fermentasyon parametrelerinde yem katkı maddesi olarak katılan çınar ağacı yaprağı sadece gerçek sindirilebilen kuru madde miktarı, mikrobiyal protein üretimi ve gerçek sindirim derecesini önemli derece de etkilemiştir.

Tablo 2.

Aspir küspesine yem katkı maddesi olarak kullanılan çınar yaprağının in vitro fermentasyon parametreleri

Yemler	GÜ (ml)	CH ₄ (ml)	CH ₄ (%)	GSKM (mg)	TF (mg/ml)	MPÜ (mg)	MPSE (%)	GSD (%)
A0	60,89	11,11	18,25	276.34 ^a	5.60	167.79 ^a	60,72	54.47 ^a
A1	60,48	10,96	18,12	267.34 ^{ab}	5.46	159.53 ^b	59,67	53.11 ^{ab}
A2	60,07	10,81	18,00	256.00 ^{bc}	5.26	148.93 ^c	58,17	50.63 ^{ab}
A4	56,77	10,10	17,77	248.67 ^c	5.42	147.46 ^c	59,37	49.54 ^b
SHO	1,74	0,35	0,14	3.96	0.09	1,44	0,68	0,77
P	0,382	0,260	0,209	0.005	0.161	0,001	0,148	0,007
Polinomiyal analiz								
Linear	0,141	0,078	0,047	0.001	0.124	0.001	0,107	0,001
Kuadratik	0,433	0,449	0,736	0.839	0.134	0.046	0,139	0,867
Kübik	0,722	0,719	0,840	0.730	0.353	0.114	0,331	0,486

^{a,b,c} aynı sütunda yer alan farklı simgeye sahip olan ortalamalar birbirinden farklıdır. GÜ: Gaz üretimi (500mg/ KM), CH₄ (ml) ve CH₄ (%): metan üretim miktarı, GSKM: Gerçek sindirilebilir kuru madde (500 mg/ KM), GSD: Gerçek sindirim derecesi (%), TF: Taksimat faktörü, MPÜ: Mikrobiyal protein üretimi (mg), MPSE: Mikrobiyal protein sentezleme etkinliği (%), SHO: Standart hata ortalaması P: Önem seviyesi.

Deneme gruplarının gaz üretim değerleri en yüksek A0 grubunda en düşük A4 grubunda, metan üretimi (ml) en yüksek A0 grubunda en düşük A4 grubunda, metan üretimi (%) en yüksek A0 grubunda en düşük A4 grubunda gözlemlenmiştir. Ruminant beslenmesinde tanen kaynaklı ürünlerin kullanımının yemin lezzetini etkileyerek yem tüketimini azalttığı, rumen ortamındaki

mikroorganizmalara karşı anti-mikrobiyal etki gösterdiği ve rumen ortamında, yemin yapısındaki proteinle bileşik oluşturmamasından dolayı mikrobiyal parçalanmadan etkilenmediği yapılan çalışmalarda ifade edilmektedir (Yanza vd., 2021; Fouts vd., 2022). Elde edilen sonuçlara bakıldığında, kontrol grubuna göre çınar yaprağının artışına bağlı olarak deneme gruplarında gaz üretimi, metan üretimi

ve metan (%) değerlerinin azaldığı fakat istatistik olarak önemsiz olduğu görülmektedir ($p>,05$). Blummel vd. (1997) yemlerin sadece elde edilen gaz üretim değerlerine göre değil aynı zamanda sindirilen madde miktarlarının da dikkate alınarak ruminant beslenmesinde yemlerin kullanılmasının gerektiğini rapor etmişlerdir. Tablo 1’de verilen GSKM değerleri çınar yaprağının artışına bağlı olarak azalmış olup nedenini Fonseca vd. (2023) rumende bulunan mikroorganizmalara tanenin anti-mikrobiyal etki göstermesinden kaynaklı olduğunu belirtmiştir. Deneme grupları arasında GSKM değeri en yüksek A0 grubunda gözlemlenmiş olup çınar yaprağı artışına bağlı olarak GSKM linear olarak azalmıştır. Elde edilen sonuçlar önemli bulunmuştur ($p<,05$). Blummel vd. (1997) taksimat faktörü ile ilgili yaptığı çalışmada, *in vitro* olarak parçalanmış organik maddenin ürettiği gaz hacmine oranı olarak tanımlamaktadır. Taksimat faktörü değerini 2.75 ile 4.41 oranında değişim göstermesi gerektiğine değinmiştir. Mevcut çalışmada bu referans aralığından yüksek bulunmuş olup çınar yaprağı artışına bağlı olarak taksimat faktörü değeri düşüş göstermekte ve gruplar arası farklılık önemsiz bulunmuştur ($p>,05$). Ruminant hayvanlar, ihtiyaç duyduğu proteinin bir kısmını mikrobiyal proteinden karşıladığı belirtilmektedir. İhtiyaç duyulan mikrobiyal proteinin, rumen mikroorganizmaları tarafından karşılanabilmesi için tüketilen yemin ham protein içeriğinin en az %7 olması gerekmektedir (NRC, 2001). Yapılan çalışmada deneme grupları arasında en yüksek MPÜ değeri A0 grubunda en

düşük A4 grubunda gözlemlenmiştir. Çınar yaprağı artışına bağlı olarak MPÜ değeri linear olarak düşüş göstermekte ve gruplar arasında farklılık önemli bulunmuştur ($p<,05$). Vercoe vd. (2010) taksimat faktörü yüksek olan bir yemin, parçalanmış maddenin orantılı olarak daha fazlasının mikrobiyal kütleyle dahil edileceğini, yani mikrobiyal protein sentezi verimliliğinin daha yüksek olacağını ifade etmiştir. Yapılan çalışma da MPSE değeri en yüksek A0 grubunda en düşük A2 grubunda gözlemlenmiştir. Elde edilen sonuçlar, Vercoe vd. (2010) bildirişleriyle tutarlılık göstermektedir. GSD değeri, bir yemin rumen mikroorganizmaları tarafından sindirimi sonucu elde edilen bir parametre olduğu ifade edilmektedir. Bitkilerin yapısındaki fenolik içeriklerin anti-mikrobiyal ve anti-nutrisyonel etkilerinden dolayı mikroorganizmalarının çalışmasını baskılayarak yemin sindirilebilirliğini olumsuz etkilediği bildirilmektedir (Habib vd., 2016). Brutti vd. (2023), düşük dozlarda bile tanen içerikli ürünlerin yeme ya da rasyona ilave edilmesi sindirim derecelerini olumsuz etkilediğini belirtmiştir. Deneme grupları içerisinde en yüksek GSD değeri A0 grubunda en düşük A4 grubunda gözlemlenmiş olup değerler çınar yaprağı artışına bağlı olarak linear azalmıştır ($p<,05$). Aspir küspesi içerisine farklı oranlarda ilave edilen çınar ağacı yapraklarının tahmini enerji parametreleri, TUYA ve $\text{NH}_3\text{-N}$ değerlerine etkisi tablo 3’de verilmiştir. Yem katkı maddesi olarak katılan çınar ağacı yaprağı söz konusu parametrelerden sadece $\text{NH}_3\text{-N}$ değerini önemli derecede etkilemiştir.

Tablo 3.

Aspir küspesine yem katkı maddesi olarak kullanılan çınar yaprağının tahmini enerji parametreleri, TUYA ve $\text{NH}_3\text{-N}$ değerlerine etkisi

Yemler	ME (mj/kgKM)	NE _L (mj/kgKM)	OMSD (%)	pH	TUYA (mmol/l)	NH_3N (mg/l)
A0	7,38	2,70	48,35	7,20	85,28	178,60 ^a
A1	7,34	2,68	48,13	7,18	84,52	170,73 ^a
A2	7,30	2,66	47,92	7,22	85,30	81,63 ^b
A4	7,07	2,50	46,61	7,19	84,37	62,37 ^c
SHO	0,110	0,08	0,62	0,02	1,40	5,38
p	0,259	0,355	0,269	0,522	0,943	0,001
Polinomiyal analiz						
Linear	0,082	0,127	0,087	0,968	0,761	0,001
Kuadratik	0,408	0,428	0,406	0,788	0,954	0,321
Kübik	0,700	0,717	0,703	0,163	0,616	0,001

^{a,b,c} aynı sütunda yer alan farklı simgeye sahip olan ortalamalar birbirinden farklıdır. ME: Metabolik enerji (mj/kgKM), NE_L: Net enerji laktasyonu (mj/kgKM), OMSD: Organik madde sindirim derecesi, TUYA: Toplam uçucu yağ asitleri, NH_3N : Amonyak-azot SHO: Standart hata ortalaması P: Önem seviyesi.

Tanen içerikli ürünlerin yeme ya da rasyona ilavesinin rumen ortamında yemin sindirilebilirliğini olumsuz etkilediği bildirilmektedir (Woodward vd., 2001). Bu bağlamda deneme gruplarına ait *in vitro* gaz üretim değerleri çınar

yaprağı dozunun artışına bağlı olarak azalmış ve metabolik, net enerji laktasyon ile organik madde sindirim derecesi olumsuz anlamda etkilenmiştir. Deneme gruplarının metabolik enerji, net enerji laktasyon ve organik madde

sindirim derecesi değerleri artan düzeyde çınar yaprağı ilavesiyle rakamsal olarak düşmüş olup gruplar arasındaki farklılıklar önemsiz bulunmuştur ($p>.05$). Rumen ortamında mikroorganizmaların optimum çalışabilmeleri için ortam pH değerinin 5,5-7,0 arasında olması gerekmektedir (Özel & Sarıççek, 2010). Deneme gruplarının pH değeri Özel ve Sarıççek, 2010 ifade etmiş olduğu değerden yüksek bulunmuştur. Yüksek protein düşük enerji kaynaklı yemlerde ortam pH'nın bazik yönlü yükseleceği ifade edilmiştir (Xia vd., 2018). Yemlerin rumen ortamında fermentasyonu sonucu açığa uçucu yağ asitleri, amonyak, CO₂, CH₄, vb. ürünler açığa çıkmakta ve yemin sindirilebilirliği hakkında tahmini bilgi vereceği ifade edilmektedir (Menke vd., 1979; Tapio vd., 2017). Hassanat ve Benchaar (2013), tanen konsantrasyonu arttıkça gaz üretimi ve toplam uçucu yağ asidi (TUYA) konsantrasyonun azaldığını bildirmişlerdir. Deneme gruplarının TUYA değerleri önemsiz bulunmuştur ($p>.05$). Norris vd. (2020) hayvansal üretim verimliliği azaltabilen ve çevreyi olumsuz etkileyen bir ürün olarak değerlendirilen amonyakın her yıl hayvan başına 50 kg emisyonu (Wang vd., 2018) sebep olduğunu rapor etmiştir. Amonyak üretimi, yemler ile alınan proteinler ve azotlu bileşiklerin (üre, amonyak vb.) rumen mikroorganizmalarının fermentasyonu sonucunda oluşmaktadır (Russell vd., 1992). Rumen ortamında oluşan amonyak, mikroorganizmalar için temel azot kaynağıdır ve mikrobiyal protein sentezi için kullanılır (Özel & Sarıççek, 2010). Amonyak üretiminin yüksek olduğu durumlar genellikle rasyonda yüksek miktarda protein veya enerji yönünden zengin bileşiklerin yetersiz olduğu durumlardır. Fazla miktarda NH₃ üretimi protein kayıpları ve ekstra enerji maliyeti anlamına gelmektedir. Bu yüzden bazı araştırmalar hayvanlara iz miktarda tanen ya da tanen içerikli ürünlerin verilmesi sonucu amonyak konsantrasyonun önemli miktarda azalacağı ve by-pass protein miktarının artacağı ifade edilmektedir (Brutti vd., 2023; Martello vd., 2020). Mevcut çalışmada deneme grupları arasında en yüksek A0 grubunda en düşük A4 grubunda amonyak değeri tespit edilmiş olup çınar yaprağı artışına bağlı olarak amonyak değeri linear olarak azalmış ve gruplar arası farklılıklar önemli bulunmuştur ($p<.05$).

Sonuçlar

Bu çalışmada, sabit protein içerikli aspir küspesi içerisine farklı oranlarda çınar ağacı yaprağı ilave edilerek *in vitro* gaz üretimi ve rumen fermentasyonu üzerindeki etkiler incelenmiştir. Sonuçlar, çınar yaprağı ilavesinin *in vitro* sindirim derecesini, mikrobiyal protein üretimini ve amonyak oluşumunu istatistiksel olarak anlamlı düzeyde azalttığını göstermiştir. Özellikle tanen kaynaklı yem katkı maddesi olarak kullanılacak ürünün, ruminantlarda azot dengesini iyileştirme potansiyeli taşıdığı ortaya konmuştur. Bu etkilerin, çınar yapraklarında bulunan fenolik bileşiklerden birisi olan tanenin,

rumen mikro-florası üzerine hem anti-mikrobiyal hem de anti-nutrisyonel etkilerinden kaynaklandığı düşünülmektedir. Sonuç olarak yapılan çalışma, daha sonra yapılacak *in vivo* çalışmalarda karaciğerde, bitkisel kaynaklı tanenin, amonyakın üreye dönüşümü sırasında oluşan enerji kayıplarını sınırlayabileceğine ve dolayısıyla idrarla atılan üre miktarını azaltabileceğine yönelik ön bir değerlendirme sunmaktadır.

Etik Komite Onayı: Etik kurul onayına gerek yoktur.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Konsept - A.B.,A.K.,T.B.,B.S.; Tasarım - A.B.,A.K.,T.B.,B.S. ; Denetim - A.B.,A.K.,T.B.,B.S. ; Kaynaklar - A.B.,A.K.,T.B.,B.S. ; Malzemeler - A.B.,A.K.,T.B.,B.S. ; Veri Toplama ve/veya İşleme - A.B.,A.K.,T.B.,B.S. ; Analiz ve/veya Yorum - A.B.,A.K.,T.B.,B.S. ; Literatür Taraması - A.B.,A.K.,T.B.,B.S. ; Yazma - A.B.,A.K.,T.B.,B.S. ; Eleştirel İnceleme - A.B.,A.K.,T.B.,B.S. ; Diğer - A.B.,A.K.,T.B.,B.S.

Çıkar Çatışması: Yazarlar, çıkar çatışması olmadığını beyan etmiştir.

Finansal Destek: Yazarlar bu çalışmanın herhangi bir finansal destek almadığını beyan etmişlerdir.

Ethics Committee Approval: Ethics committee approval is not required.

Peer-review: Externally peer-reviewed.

Author Contributions: Concept - A.B.,A.K.,T.B.,B.S. ; Design - A.B.,A.K.,T.B.,B.S. ; Supervision - A.B.,A.K.,T.B.,B.S. ; Resources - A.B.,A.K.,T.B.,B.S. ; Materials - A.B.,A.K.,T.B.,B.S. ; Data Collection and/or Processing - A.B.,A.K., T.B.,B.S. ; Analysis and/or Interpretation - A.B.,A.K.,T.B.,B.S. ; Literature Review - A.B.,A.K.,T.B.,B.S. ; Writing - A.B.,A.K.,T.B.,B.S. ; Critical Review - A.B.,A.K.,T.B.,B.S. ; Other - A.B.,A.K.,T.B.,B.S.

Conflict of Interest: The author has no conflicts of interest to declare.

Financial Disclosure: The author declared that this study has received no financial support.

Kaynaklar

- Amarowicz, R., & Pegg, R. B. (2024). Condensed tannins—Their content in plant foods, changes during processing, antioxidant and biological activities. *Advances in Food and Nutrition Research*, 110, 327–398. <https://doi.org/10.1016/bs.afnr.2024.02.005>
- AOAC. (1990). *Official method of analysis* (15th ed.). Association of Official Analytical Chemists.
- Arisya, W., Ridwan, R., Ridla, M., & Jayanegara, A. (2019, October). Tannin treatment for protecting feed protein degradation in the rumen *in vitro*. *In Journal of Physics: Conference Series*, 1360(1), 012022. <https://doi.org/10.1088/1742-6596/1360/1/012022>
- Ban, Y., & Guan, L. L. (2021). Implication and challenges of direct-fed microbial supplementation to improve ruminant production and health. *Journal of Animal Science and Biotechnology*, 12, 109. <https://doi.org/10.1186/s40104-021-00617-3>

- Besharati, M., Maggiolino, A., Palangi, V., Kaya, A., Jabbar, M., Eseceli, H., ... & Lorenzo, J. M. (2022). Tannin in ruminant nutrition. *Molecules*, 27(23), 8273. <https://doi.org/10.3390/molecules27238273>
- Blümmel, M., Steingäß, H., & Becker, K. (1997). The relationship between in vitro gas production, in vitro microbial biomass yield and 15N incorporation and its implications for the prediction of voluntary feed intake of roughages. *British Journal of Nutrition*, 77(6), 911–921. <https://doi.org/10.1079/BJN19970089>
- Brutti, D. D., Canozzi, M. E. A., Sartori, E. D., Colombatto, D., & Barcellos, J. O. J. (2023). Effects of the use of tannins on the ruminal fermentation of cattle: A meta-analysis and meta-regression. *Animal Feed Science and Technology*, 306, 115806. <https://doi.org/10.1016/j.anifeedsci.2023.115806>
- Chisoro, P., Jaja, I. F., & Assan, N. (2023). Incorporation of local novel feed resources in livestock feed for sustainable food security and circular economy in Africa. *Frontiers in Sustainability*, 4, 1251179. <https://doi.org/10.3389/frsus.2023.1251179>
- Dumlu, B. (2024). Importance of nano-sized feed additives in animal nutrition. *Journal of Agricultural Production*, 5(1), 55–72.
- Duncan, D. B. (1955). Multiple range and multiple F tests. *Biometrics*, 11(1), 1–42. <https://doi.org/10.2307/3001478>
- Fonseca, N. V. B., da Silva Cardoso, A., Granja-Salcedo, Y. T., Siniscalchi, D., Camargo, K. D. V., Dornellas, I. A., ... & Reis, R. A. (2024). Effects of condensed tannin-enriched alternative energy feedstuff supplementation on performance, nitrogen utilization, and rumen microbial diversity in grazing beef cattle. *Livestock Science*, 287, 105529. <https://doi.org/10.1016/j.livsci.2024.105529>
- Fouts, J. Q., Honan, M. C., Roque, B. M., Tricarico, J. M., & Kebreab, E. (2022). Enteric methane mitigation interventions. *Translational Animal Science*, 6(2), txac041. <https://doi.org/10.1093/tas/txac041>
- Goel, G., Makkar, H. P., & Becker, K. (2008). Effects of Sesbania sesban and Carduus pycnocephalus leaves and Fenugreek (Trigonella foenum-graecum L.) seeds and their extracts on partitioning of nutrients from roughage- and concentrate-based feeds to methane. *Animal Feed Science and Technology*, 147(1–3), 72–89.
- Gümüş, E., & Küçükersan, S. (2016). The use of safflower in ruminant nutrition. *Journal of Lalahan Livestock Research Institute*, 56(1).
- Habib, G., Khan, N. A., Sultan, A., & Ali, M. (2016). Nutritive value of common tree leaves for livestock in the semi-arid and arid rangelands of Northern Pakistan. *Livestock Science*, 184, 64–70.
- Hassanat, F., & Benchaar, C. (2013). Assessment of the effect of condensed (acacia and quebracho) and hydrolysable (chestnut and valonea) tannins on rumen fermentation and methane production in vitro. *Journal of the Science of Food and Agriculture*, 93(2), 332–339.
- Herrero, M., Havlik, P., McIntire, J., Palazzo, A., & Valin, H. (2014). *African Livestock Futures: Realizing the potential of livestock for food security, poverty reduction and the environment in Sub-Saharan Africa*. World Bank.
- Irtiza, S., Bhat, G. A., Ahmad, M., Ganaie, H. A., Ganai, B. A., Kamili, A. N., ... & Tantry, M. A. (2016). Antioxidant and anti-inflammatory activities of Platanus orientalis: An oriental plant endemic to Kashmir plains. *Pharmacologia*, 7, 217–222.
- Jayanegara, A., Ridla, M., Laconi, E. B., & Nahrowi, N. (2018, November). Tannin as a feed additive for mitigating enteric methane emission from livestock: Meta-analysis from RUSITEC experiments. In *IOP Conference Series: Materials Science and Engineering*, 434(1), 012108
- Kamalak, A., & Ozkan, C. O. (2021). Potential nutritive value and anti-methanogenic potential of some fallen tree leaves in Turkey. *Livestock Research for Rural Development*, 33, 132.
- Karabulut, A., & Canbolat, Ö. (2005). *Yem değerlendirme ve analiz yöntemleri*. Uludağ Üniversitesi Yayınları.
- Makkar, H. P. (2003). Effects and fate of tannins in ruminant animals, adaptation to tannins, and strategies to overcome detrimental effects of feeding tannin-rich feeds. *Small Ruminant Research*, 49(3), 241–256.
- Makkar, H. P. S., Blümmel, M., & Becker, K. (1995). Formation of complexes between polyvinyl pyrrolidones or polyethylene glycols and tannins, and their implication in gas production and true digestibility in in vitro techniques. *British Journal of Nutrition*, 73(3), 315–331.
- Markham, R. (1942). A steam distillation apparatus suitable for micro-Kjeldahl analysis. *Biochemical Journal*, 36(10–12), 790.
- Martello, H. F., De Paula, N. F., Teobaldo, R. W., Zervoudakis, J. T., Fonseca, M. A., Cabral, L. S., & Moraes, E. H. B. K. (2020). Interaction between tannin and urea on nitrogen utilization by beef cattle grazing during the dry season. *Livestock Science*, 234, 103988. <https://doi.org/10.1016/j.livsci.2020.103988>
- Menke, K. H., & Steingass, H. (1988). Estimation of the energetic feed value obtained from chemical analysis and in vitro gas production using rumen fluid. *Animal Research and Development*, 28, 7–55.

- Menke, K. H., Raab, L., Salewski, A., Steingass, H., Fritz, D., & Schneider, W. (1979). The estimation of digestibility and metabolizable energy content of ruminant feedstuffs from the gas production when they are incubated with rumen liquor in vitro. *Journal of Agricultural Science*, 93, 217–222.
- Min, B. R., Barry, T. N., Attwood, G. T., & McNabb, W. C. (2003). The effect of condensed tannins on the nutrition and health of ruminants fed fresh temperate forages: A review. *Animal Feed Science and Technology*, 106(1–4), 3–19.
- National Research Council, Committee on Animal Nutrition, & Subcommittee on Dairy Cattle Nutrition. (2001). *Nutrient requirements of dairy cattle: 2001*. National Academies Press.
- Norris, A. B., Crossland, W. L., Tedeschi, L. O., Foster, J. L., Muir, J. P., Pinchak, W. E., & Fonseca, M. A. (2020). Inclusion of quebracho tannin extract in a high-roughage cattle diet alters digestibility, nitrogen balance, and energy partitioning. *Journal of Animal Science*, 98(3), skaa047.
- Özek, K. (2017). Aspirin yem değeri ve çiftlik hayvanlarının beslenmesinde kullanılabilme olanakları: II. Ruminantların beslenmesinde kullanımı ve etkileri. *Kahramanmaraş Sütçü İmam Üniversitesi Doğa Bilimleri Dergisi*, 20(1), 35–41.
- Özel, O. & Sarıççek, B. (2009). Ruminantlarda rumen mikroorganizmalarının varlığı ve önemi. *TÜBAV Bilim Dergisi*, 2(3), 277–285.
- Patra, A. K., & Saxena, J. (2011). Exploitation of dietary tannins to improve rumen metabolism and ruminant nutrition. *Journal of the Science of Food and Agriculture*, 91(1), 24–37.
- Paul, B. K. (2019). At a crossroads: Potential impacts and trade-offs of improved livestock feeding and forages in smallholder farming systems of East Africa (Doctoral dissertation, Wageningen University and Research).
- Russell, J. B., O'Connor, J. D., Fox, D. G., Van Soest, P. J., & Sniffen, C. J. (1992). A net carbohydrate and protein system for evaluating cattle diets: I. Ruminant fermentation. *Journal of Animal Science*, 70(11), 3551–3561. <https://doi.org/10.2527/1992.70113551x>
- Salem, H. B., Makkar, H. P. S., Nefzaoui, A., Hassayoun, L., & Abidi, S. (2005). Benefit from the association of small amounts of tannin-rich shrub foliage (*Acacia cyanophylla* Lindl.) with soybean meal given as supplements to Barbarine sheep fed on oaten hay. *Animal Feed Science and Technology*, 122(1–2), 173–186.
- Serrapica, F., Masucci, F., Raffrenato, E., Sannino, M., Vastolo, A., Barone, C. M. A., & Di Francia, A. (2019). High fiber cakes from Mediterranean multipurpose oilseeds as protein sources for ruminants. *Animals*, 9(11), 918. <https://doi.org/10.3390/ani9110918>
- Singh, S., Singh, T., Kumar, N., Koli, P., Das, M. M., Mahanta, S. K., ... & Katiyar, R. (2025). Verim, besin özellikleri ve silajlama kalitesi açısından Sehima nervosum'daki genetik çeşitliliğin değerlendirilmesi. *Heliyon*, 11(2).
- Tapio, I., Snelling, T. J., Strozzi, F., & Wallace, R. J. (2017). The ruminal microbiome associated with methane emissions from ruminant livestock. *Journal of Animal Science and Biotechnology*, 8, 7.
- Van Soest, P. J., Robertson, J. B., & Lewis, B. A. (1991). Methods for dietary fiber, neutral detergent fiber, and nonstarch polysaccharides in relation to animal nutrition. *Journal of Dairy Science*, 74, 3583–3597.
- Vercoe, P. E., Makkar, H. P. S., & Schlink, A. C. (Eds.). (2010). *In vitro screening of plant resources for extra-nutritional attributes in ruminants: Nuclear and related methodologies*. Springer.
- Wang, X., Bai, Z., Yao, Y., Gao, B., Chadwick, D., Chen, Q., ... & Ma, L. (2018). Composting with negative pressure aeration for the mitigation of ammonia emissions and global warming potential. *Journal of Cleaner Production*, 195, 448–457.
- Woodward, S. L., Waghorn, G. C., Ulyatt, M. J., & Lassey, K. R. (2001, April). Early indications that feeding Lotus will reduce methane emissions from ruminants. In *Proceedings of the New Zealand Society of Animal Production*, 61, 23–26.
- Xia, C., Rahman, M. A. U., Yang, H., Shao, T., Qiu, Q., Su, H., & Cao, B. (2018). Effect of increased dietary crude protein levels on production performance, nitrogen utilisation, blood metabolites and ruminal fermentation of Holstein bulls. *Asian-Australasian Journal of Animal Sciences*, 31(10), 1643–1652.
- Yanza, Y. R., Fitri, A., Suwignyo, B., Elfahmi, Hidayatik, N., Kumalasari, N. R., Irawan, A., & Jayanegara, A. (2021). The utilisation of tannin extract as a dietary additive in ruminant nutrition: A meta-analysis. *Animals*, 11(11), 3317. <https://doi.org/10.3390/ani11113317>

Erzurum İli Yakutiye İlçesi Mahallelerinde Küçükbaş Hayvancılığın Son Dört Yılda Değişimi

Changes in Small Ruminant Farming in the Neighborhoods of Yakutiye District of Erzurum Province in the Last Four Years

Hasan ÖZSAYGIN¹



¹ Atatürk University, Institute of Science, Department of Animal Science, Erzurum, Türkiye



ÖZ

Bu çalışma, Erzurum ili Yakutiye ilçesine bağlı mahallelerde 2021-2024 yılları arasında küçükbaş hayvancılık faaliyetlerinde yaşanan hayvan varlığındaki dalgalanmaları analiz etmeyi amaçlamaktadır. Araştırmanın temel hedefi, Erzurum ili Yakutiye ilçesi mahallelerinde yetiştirilen küçükbaş hayvan sayılarındaki artış ve azalışları ortaya koymak, mahallelerde yetiştirilen hayvan sayılarındaki farklılıkların nedenlerini ortaya koymak ve küçükbaş hayvancılığın sürdürülebilirliğine yönelik değerlendirmelerde bulunmaktır. Araştırmada kullanılan veriler Türkiye İstatistik Kurumu (TÜİK), Tarım ve Orman Bakanlığı Hayvan Kayıt Sistemi (TURKVET), Erzurum İl Tarım ve Orman Müdürlüğü ile yerel yönetim kaynaklarından elde edilmiştir. 2021-2024 yıllarına ait veriler tablolaştırılmış, mahalleler düzeyinde yıllık karşılaştırmalar yapılmış ve değişim oranları hesaplanarak analiz edilmiştir. Araştırma sonuçları, Yakutiye ilçesine bağlı mahallelerde küçükbaş hayvan varlığı açısından ciddi farklılıklar olduğunu ortaya koymuştur. Örneğin, Dumlupınar Mahallesi %69,7'lik bir artışla 2021'de 5.295 baştan 2024'te 8.987 başa ulaşmış ve olumlu bir gelişim sergilemiştir. Öte yandan, Altınbulak ve Altıntepe mahallelerindeki küçükbaş hayvan sayısı 2021 yılında sırasıyla 149 ve 319 baş iken, bu sayılar 2024 yılında sıfıra düşmüştür. Köşk Mahallesi'nde ise %56,4'lük bir azalma ile 2021 yılında 3.317 olan hayvan sayısı 2024'te 1.447'ye gerilemiştir. Bu bulgular, küçükbaş hayvancılığın ilçede mahalleler bazında oldukça heterojen bir yapı sergilediğini göstermektedir. Bu doğrultuda, bölgesel kalkınma stratejileri bu sonuca yol açan sebepler göz önüne alınarak mahalle ölçeğinde planlanması, yem maliyetlerinin düşürülmesi, iklim değişikliğine uyum politikalarının geliştirilmesi, gençlerin sektöre kazandırılması ve kırsal göçü azaltacak sosyal desteklerin artırılması gerekmektedir. Ayrıca mahalle bazlı izleme ve destek sistemlerinin geliştirilmesi, sürdürülebilirlik açısından önem arz etmektedir.

Anahtar Kelimeler: Erzurum, Hayvan varlığı, Keçi, Koyun

ABSTRACT

This study aims to analyze changes in the number of small ruminants in the neighborhoods of Yakutiye District in Erzurum Province between 2021 and 2024. The main objective of the research is to identify increases and decreases in the number of small ruminants raised in these neighborhoods, to investigate the reasons behind the changes in livestock numbers, and to assess the sustainability of small ruminant farming. The data used in this research were obtained from the Turkish Statistical Institute (TurkStat), the Ministry of Agriculture and Forestry's Animal Registration System (TURKVET), the Erzurum Provincial Directorate of Agriculture and Forestry, and local government sources. Data for the years 2021-2024 were presented in tables, annual comparisons were made at the neighborhood level, and the rate of change was calculated and analyzed. The research findings revealed significant differences in the number of small ruminants across the neighborhoods of the district. For example, Dumlupınar Neighborhood showed positive growth, increasing by 69.7%, from 5,295 head in 2021 to 8,987 head in 2024. Conversely, in Altınbulak and Altıntepe neighborhoods, the number of small animals, which was 149 and 319 head in 2021 respectively, dropped to zero by 2024. In Köşk neighborhood, the number of small ruminants decreased by 56.4%, from 3,317 in 2021 to 1,447 in 2024. These findings demonstrate that small ruminant farming exhibits a highly heterogeneous structure at the neighborhood level. Consequently, regional development strategies should be planned on a neighborhood scale, taking into account the underlying causes of these variations. Measures should include reducing feed costs, developing climate change adaptation policies, involving young people in the sector, and increasing social support to mitigate rural migration. Additionally, the development of neighborhood-based monitoring and support systems is essential for ensuring sustainability.

Keywords: Erzurum, Goat, Number of animals, Sheep

Geliş Tarihi/Received 03.06.2025
Kabul Tarihi/Accepted 16.07.2025
Yayın Tarihi/Publication Date 24.07.2025

Sorumlu Yazar/Corresponding author:
Hasan ÖZSAYGIN
E-mail: hasanozsaygin08@gmail.com
Cite this article: Özsaygin, H (2025).
Changes in Small Ruminant Farming in the
Neighborhoods of Yakutiye District of
Erzurum Province in the Last Four Years.
Journal of Animal Science and Economics,
4(2), 88-97.



Content of this journal is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Giriş

Hayvancılık sektörü, Türkiye'de tarım faaliyetleri içinde önemli bir yere sahiptir. Hayvansal üretim, yalnızca beslenme ihtiyacını karşılamakla kalmaz aynı zamanda sanayiye hammadde sağlayarak stratejik bir rol üstlenir (Karagöz, 2009; Özdemir vd., 2024). Küçükbaş hayvancılık, düşük maliyetli yapısıyla özellikle kırsal bölgelerde temel ekonomik faaliyetlerden biridir (Koyuncu, 2012). Türkiye'nin coğrafi yapısı, iklim özellikleri ve geniş mera alanları, koyun ve keçi yetiştiriciliğine uygun koşullar sunar. Bu durum, küçükbaş hayvancılığın düşük maliyetle sürdürülebilmesini mümkün kılmaktadır (Alkan, 2010).

Küçükbaş hayvanlar, otlaklardan doğrudan yararlanabilen, soğuğa ve hastalıklara karşı dayanıklı, büyükbaş hayvanlara göre daha az yemle beslenebilen türlerdir. Bu nedenle, yetersiz bakım ve besleme şartlarına sahip küçük aile işletmeleri için koyun ve keçi yetiştiriciliği önemli bir gelir kaynağı olarak ön plana çıkmaktadır (Kaymakçı, 2006). Buna rağmen son yıllarda Türkiye genelinde küçükbaş hayvan varlığında azalmalar yaşanmıştır (Barıt vd., 2025). Bunun başlıca nedenleri arasında çoban bulma zorluğu, yüksek üretim maliyetleri, kentleşme baskısı, yetersiz desteklemeler ve genç nüfusun sektöre ilgisizliği sayılabilir (Ertuğrul vd., 2010; Aksoy ve Yavuz., 2012).

Buna karşın Türkiye küçükbaş hayvancılıkta hâlâ önemli fırsatlara sahiptir. Üretim dışı alanların değerlendirilmesi, hayvansal proteinin uygun maliyetle sağlanması ve ihracat potansiyeli gibi unsurlar dikkate alındığında sektörün stratejik önemi artmaktadır (Ertuğrul vd., 2010).

Doğu Anadolu Bölgesi, Türkiye'de küçükbaş hayvancılığın en yoğun şekilde yapıldığı bölgelerin başında gelmektedir. Bu bölge, özellikle düşük verimli yerli ırklarla ve meraya dayalı üretim sistemiyle faaliyet göstermektedir (Özen vd., 1993; Aksoy, 2008).

Çalışmada üzerinde durulduğu yıllar esas alındığında, Erzurum ili ise geniş mera alanları, iklim özellikleri ve geleneksel üretim biçimiyle küçükbaş hayvancılıkta öne çıkan illerden biridir. 2020 yılında ilde toplam küçükbaş hayvan sayısı 904.587 iken, bu sayı 2021 yılında 900.623'e gerilemiştir (Kopuzlu, 2023). Bu düşüş, sektördeki yapısal sorunların Erzurum'da da benzer şekilde yaşandığını ortaya koymaktadır.

Erzurum'un merkez ilçelerinden biri olan Yakutiye hem kırsal hem de kentsel yerleşim birimlerini barındırması nedeniyle hayvancılık açısından karmaşık ve dinamik bir yapıya sahiptir. 945 km² yüzölçümüne sahip olan ilçe, 44 mahalleden oluşmaktadır (Anonim, 2025a). Bu mahalleler, sosyal ve kültürel yapının yanı sıra ekonomik faaliyetlerin, özellikle de küçükbaş hayvancılığın dağılımında da belirleyici olmaktadır. 2021 yılında ilçede küçükbaş hayvan sayısı 34.415 olarak kaydedilmiş, bu sayı 2023'te 48.684'e

yükselmiş ve 2024'te ise %17'lik bir düşüşle 41.558'e gerilemiştir (Anonim, 2025a). Bu veriler, ilçedeki küçükbaş hayvancılığın değişkenliğini ve kırılganlığını açıkça göstermektedir. Yakutiye ilçesine yönelik akademik araştırmalar oldukça sınırlı olup, mevcut çalışmalar genellikle Erzurum'un küçükbaş hayvancılığın genel yapısı ve karşılaşılan sorunlar üzerine odaklanmaktadır (Gökmener & Öztürk, 2022).

Bu çalışmanın temel amacı; 2021–2024 yıllara ait Türkiye İstatistik Kurumu (TÜİK), Hayvan Kayıt Sistemi (TURKVET), Erzurum İl Tarım ve Orman Müdürlüğü ve yerel idare kaynaklarından temin edilen Erzurum ili Yakutiye ilçesine bağlı mahallelere ait veriler dikkate alınarak mahallelerde küçükbaş hayvan varlığında yaşanan değişimleri ele alarak analiz etmek, bu değişimlerin altında yatan nedenleri ve sürdürülebilirliğini belirleyerek küçükbaş hayvancılık politikalarına katkı sunacak öneriler geliştirmektir.

Yöntem

2021–2024 yılları arasında Erzurum İli Yakutiye ilçesine bağlı 44 mahallenin küçükbaş hayvan varlığına ilişkin Türkiye İstatistik Kurumu (TÜİK), Hayvan Kayıt Sistemi (TURKVET), Erzurum İl Tarım ve Orman Müdürlüğü ve yerel idare kaynaklarından temin edilen veriler değerlendirilmiştir. Veriler, Excel ortamında yıllar bazında tablolara dökülmüş ve mahalleler arındaki karşılaştırmalı analizlerle yorumlanmıştır.

Bulgular

Bölgenin Küçükbaş Hayvan Varlığındaki Değişimler

Türkiye genelindeki küçükbaş hayvan sayısı, dalgalı bir seyir izlemiştir. 2021 yılında 57.519.204 baş olan küçükbaş hayvan sayısı, 2022 yılında 56.265.750 başa, 2023 yılında 52.363.410 başa gerilemiş; 2024 yılında ise yeniden artış göstererek 54.902.668 başa ulaşmıştır. Erzurum ili küçükbaş hayvan varlığı bakımından Türkiye küçükbaş hayvan varlığının %1,5–%1,8'lik bir kısmını oluşturmaktadır. Erzurum'da 2021 yılında 900.623 olan küçükbaş hayvan varlığı, 2022'de 1.002.118 ile zirveye ulaşmış; ardından 2023'te 877.869'a ve 2024'te 837.683'e gerilemiştir. Küçükbaş hayvan varlığı bakımından 4 yıl içerisinde Erzurum ili Yakutiye ilçesindeki değişim Erzurum'da gözlenen değişimin paralelinde gözlenmiştir. İlçede küçükbaş hayvan sayısı 2021'de 34.415 iken, 2022'de 43.890'a, 2023'te 48.684'e yükselmiş; ancak 2024'te %17 oranında bir azalma ile 41.558'e gerilemiştir. Küçükbaş hayvan varlığı tür bazında incelendiğinde Türkiye'deki koyun sayısı 2021'de 45.177.690 başken, 2022'de 44.687.888'e, 2023'te 42.060.470'e gerilemiş; 2024'te ise 44.080.584'e yükselmiştir. Erzurum ilinde koyun sayısı 2021'de 809.771 iken 2022'de 912.343'e çıkmış; ardından

2023'te 799.595'e, 2024'te 758.270'e düşmüştür. Yakutiye ilçesinde de benzer şekilde koyun sayısı 2021'de 32.487 iken 2022'de 42.058'e, 2023'te 46.831'e yükselmiş; ancak 2024'te 39.732'ye düşerek yaklaşık %15'lik bir azalma göstermiştir. Bu veriler, Yakutiye ilçesinin koyunculukta bölgesel eğilimleri yansıttığını, ancak genel üretim azalmalarından doğrudan etkilendiğini ortaya koymaktadır. Keçi varlığı açısından ise Türkiye genelinde sürekli bir azalma yaşanmıştır. 2021 yılında 12.341.514 olan toplam keçi varlığı, 2022'de 11.577.862'ye, 2023'te 10.302.940'a düşmüş; 2024'te ise 10.822.084 olarak sınırlı bir toparlanma göstermiştir. Erzurum'da bu sayı 2021'de 90.852, 2022'de 89.775, 2023'te 78.274 ve 2024'te 79.413 olarak kaydedilmiştir. Yakutiye ilçesi ise oldukça sabit bir yapı sergileyerek 2021'de 1.928, 2022'de 1.832, 2023'te 1.853 ve

2024'te 1.826 keçi varlığına sahip olmuştur. Bu istikrar, ilçede keçi yetiştiriciliğinin sınırlı kaldığını ve küçükbaş hayvancılığın büyük ölçüde koyunculuk odaklı olduğunu göstermektedir (Anonim, 2025b).

Yakutiye İlçesi Mahallelerinde Küçükbaş Hayvancılığın Son Dört Yıldaki Değişimi

Tablo 1 incelendiğinde Akdağ Mahallesi'nde, 2021 yılında 201 baş olan küçük baş varlığı, 2022 yılında %56,7 artışla 315 başa ulaşan küçükbaş hayvan sayısı, 2023'te küçük bir azalmayla 309 başa gerileme ve 2024'te ise tekrar artarak 365 başa ulaşmıştır. Dört yıl içinde gözlenen bu artışlar, mahalledeki hayvancılığın sürdürüldüğünü ve desteklendiğini, özellikle 2024 yılında erkek koyun sayısında dikkat çekici bir yükseliş olduğunu göstermektedir.

Tablo 1.

2021–2024 Yılları Arasında Akdağ, Aktoprak, Altıbulak, Altıntepe, Arıbahçe ve Çayırtepe Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Akdağ	2021	174	27	201	0	0	0	201
	2022	263	52	315	0	0	0	315
	2023	298	11	309	0	0	0	309
	2024	258	107	365	0	0	0	365
Aktoprak	2021	1.050	40	1.090	139	7	146	1.236
	2022	2.378	55	2.433	103	13	116	2.546
	2023	3.275	469	3.744	120	20	140	3.884
	2024	2.467	322	2.789	120	4	124	2.913
Altıbulak	2021	124	25	149	0	0	0	149
	2022	120	25	145	0	0	0	145
	2023	48	0	48	0	0	0	48
	2024	0	0	0	0	0	0	0
Altıntepe	2021	304	5	309	10	0	10	319
	2022	39	83	122	11	12	23	145
	2023	0	0	0	0	0	0	0
	2024	0	0	0	0	0	0	0
Arıbahçe	2021	807	60	867	33	20	53	920
	2022	1.510	214	1.724	53	38	91	1.815
	2023	1.606	281	1.887	63	19	82	1.969
	2024	1.266	409	1.675	62	5	67	1.742
Çayırtepe	2021	461	82	543	103	23	126	669
	2022	297	11	308	48	18	66	374
	2023	479	71	550	66	24	90	640
	2024	279	44	323	42	13	55	378

Aktoprak Mahallesi, ilçe genelinde küçükbaş hayvancılığın en güçlü yürütüldüğü mahallelerden biridir. 2021 yılında toplam 1.236 baş olan küçükbaş sayısı, 2022'de %106 artışla 2.546'ya, 2023'te ise %52,5 artışla 3.884'e yükselmiştir. Ancak 2024'te %25'lik bir düşüş yaşanarak toplam hayvan sayısı 2.913'e gerilemiştir. Bu düşüşe rağmen, mahalle hâlâ oldukça yüksek bir hayvan varlığına sahiptir. Keçi sayıları

2022'den sonra sabit kalırken, koyun varlığı mahalledeki temel üretim kaynağıdır.

Altıbulak Mahallesi'nde, 2021 yılında 149 baş olan küçükbaş hayvan varlığı, 2022'de çok küçük bir azalmayla 145 başa düşmüştür. 2023 yılında düşüş devam ederek hayvan sayısı 48 başa gerilemiş ve 2024 yılı itibarıyla tamamen sıfırlanmıştır. Bu sonuca gelinmesinin muhtemel nedenleri

göç, ekonomik zorluklar veya mera kullanımı ile ilgili sorunlar yer alabildiği düşünülmektedir. Altıntepe Mahallesi, 2021 yılında 319 baş küçükbaş hayvana sahipken, 2022 yılında %54,5 oranında azalarak toplam sayı 145 başa düşmüştür. 2023 ve 2024 yıllarında ise hayvan varlığı tamamen sıfırlanmıştır. Bu durum, mahallede hayvancılığın hızla terk edildiğini ve sürdürülemez hâle geldiğini işaret etmektedir.

Arıbahçe Mahallesi, güçlü bir hayvancılık yapısına sahiptir. 2021 yılında 920 baş olan küçükbaş sayısı, 2022'de %97 artışla 1.815'e ulaşmış, 2023'te ise 1.969'a çıkarak zirveye ulaşmıştır. Ancak 2024 yılında toplam hayvan varlığında %11,5'lik bir azalma yaşanarak mevcut sayı 1.742'ye gerilemiştir. Bu azalma, sınırlı düzeyde olup üretimin hâlen yüksek seviyelerde sürdüğünü göstermektedir. Arıbahçe, koyun yetiştiriciliğinde olduğu kadar keçi varlığı bakımından da dengeli bir yapı sergilemektedir.

Çayırtepe Mahallesi'nde, 2021 yılında 669 baş küçükbaş hayvan mevcudu bulunmaktaydı. Ancak bu sayı 2022'de %44,1 azalarak 374'e düşmüştür. 2023 yılında toparlanma belirtileri görülmüş ve sayı 640 başa kadar çıkmıştır. Ancak 2024 yılında hayvan varlığında yeniden bir düşüş yaşanmış ve sayı 378'e gerilemiştir. Bu inişli çıkışlı seyir; yem

maliyetlerindeki artış, çoban bulma zorlukları, iklim koşullarındaki değişkenlik ve destekleme politikalarının yetersizliği gibi faktörlerin mahallede üretimi doğrudan etkilediğini göstermektedir. Keçi varlığı ise 2021 sonrasında azalma eğilimi gösterse de belirli bir düzeyde korunmuştur.

Yakutiye ilçesindeki diğer mahallelerle karşılaştırıldığında, Çiftlik Mahallesi'nde 2021 yılında toplam 2.042 baş küçükbaş hayvan (2.039 koyun ve 3 keçi) ile hayvancılık oldukça yüksek bir düzeyde başlamıştır. Ancak 2022 yılında %46,7'lik ciddi bir azalma ile toplam sayı 1.088 başa düşmüştür. 2023 yılında sınırlı bir toparlanma gözlemlenmiş ve toplam hayvan sayısı 1.262'ye kadar ulaşmıştır. Ancak 2024 yılında dikkat çekici bir şekilde toplam sayı 5'e düşerek adeta yok denecek seviyeye inmiştir. Bu önemli miktarda düşüş, mahallede küçükbaş hayvancılığın ya tamamen terk edildiğini ya da ciddi dış etkenlerden (göç, arazi sorunu, iklim, hastalık vs.) olumsuz etkilendiğini göstermektedir.

Dadaşköy Mahallesi, 2021 yılında 731 baş küçükbaş hayvan varlığına sahipken, takip eden iki yılda sırasıyla %1 ve %51,8 oranında artışlar gözlenmiştir. Bu artış hayvancılığın mahallede desteklendiğini ve büyüdüğünü göstermektedir.

Tablo 2.

2021-2024 Yılları Arasında Çiftlik, Dadaşköy, Değirmenler, Dumlu, Gökçeyamaç ve Güngörmez Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Çiftlik	2021	2.009	30	2.039	1	2	3	2.042
	2022	1.019	60	1.079	4	5	9	1.088
	2023	1.201	52	1.253	4	5	9	1.262
	2024	2	0	2	3	0	3	5
Dadaşköy	2021	502	167	669	46	16	62	731
	2022	627	53	680	51	7	58	738
	2023	839	234	1.073	45	3	48	1.121
	2024	378	71	449	35	13	48	497
Değirmenler	2021	100	63	163	0	49	49	212
	2022	281	116	397	0	53	53	450
	2023	268	85	353	0	4	4	357
	2024	17	2	19	0	0	0	19
Dumlu	2021	4.193	583	4.776	413	106	519	5.295
	2022	4.843	1.366	6.209	227	51	278	6.487
	2023	7.093	1.461	8.554	272	44	316	8.870
	2024	7.745	942	8.687	264	36	300	8.987
Gökçeyamaç	2021	81	57	138	0	0	0	138
	2022	110	46	156	0	2	2	158
	2023	41	79	120	0	2	2	122
	2024	0	0	0	0	0	0	0
Güngörmez	2021	849	89	938	50	12	62	1.000
	2022	590	16	606	37	0	37	643
	2023	480	49	529	31	0	31	560
	2024	326	42	368	102	12	114	482

Ancak Buna karşın 2024 yılında %55,7 oranında ciddi bir düşüşle toplam hayvan sayısı 497'ye gerilemiştir. Bu ani düşüş, ekonomik ya da çevresel nedenlerden kaynaklı geçici bir daralma olabilir.

Değirmenler Mahallesi'nde ise hayvan sayılarındaki değişimler yıllar itibariyle inceleldiğinde 2021 yılında 212 baş küçükbaş hayvan bulunurken, 2022 yılında iki katın üzerinde gözlenen artışla bu sayı 450'ye yükselmiştir. Bu büyüme, üretimdeki potansiyelino yıl itibariyle maalle halkının değerlendirildiğini göstermektedir. Ancak 2023 yılında küçük bir düşüşle 357'ye gerileme yaşanmış ve 2024 yılı itibariyle ise %94,7 gibi dramatik bir azalma yaşanarak hayvan varlığı yalnızca 19'a inmiştir. Bu durum, mahallede küçükbaş hayvancılığın neredeyse tamamen sona erdiğini ortaya koymaktadır.

Dumlu Mahallesi, Yakutiye ilçesi genelinde küçükbaş hayvan varlığı bakımından en yüksek sayıda olan mahalle olarak öne çıkmaktadır. 2021 yılında 5.295 baş olan küçükbaş sayısı, her yıl artarak 2024 yılına kadar 8.987'ye ulaşmıştır. Bu artış sırasıyla 2022'de %22,5, 2023'te %36,7 ve 2024'te %1,3 oranında gerçekleşmiştir. Bu veriler, mahallede hayvancılığın

sürekli desteklendiğini ve sürdürülebilir bir gelişim içinde olduğunu göstermektedir. Dumlu, ilçede bulunduğu konumunun avantajının sayesinde bölgedeki hayvancılığın lokomotif mahallelerinden biri olarak değerlendirilebilir.

Yakutiye ilçesindeki diğer mahallelerle kıyaslandığında, Gökçeyamaç Mahallesi'nde küçükbaş hayvan sayısının oldukça düşük olduğu görülmektedir. 2021 yılında 138 olan toplam hayvan sayısı, 2022'de 158'e yükselmiş ancak 2023'te tekrar 122'ye gerilemiştir. 2024 yılı itibariyle ise hayvan varlığı tamamen sıfırlanmıştır. Bu durum, mahallede hayvancılığın ya ekonomik olarak sürdürülemez hale geldiğini ya da terk edildiğini göstermektedir.

Güngörmez Mahallesi'nde, 2021 yılında 1.000 baş küçükbaş hayvan bulunmaktayken, takip eden iki yıl boyunca istikrarlı bir azalma yaşanmış, 2023'te sayı 560'a düşmüştür. Ancak 2024 yılında keçi sayısındaki dikkat çekici artışla birlikte toplam sayı 482'ye ulaşmıştır. Bu durum, keçi yetiştiriciliğine yönelimin artmış olabileceğini göstermektedir. Genel olarak hayvan varlığında bir azalma olsa da tür bazında kayma ve çeşitlenme gözlenmektedir (Tablo 2).

Tablo 3.

2021-2024 Yılları Arasında Güzelova, Güzelyayla, İbrahimhakkı, Karagöbek, Karasu ve Kırkgöze Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Güzelova	2021	1.513	26	1.539	82	0	82	1.621
	2022	1.802	159	1.961	90	5	95	2.056
	2023	1.769	261	2.030	62	6	68	2.098
	2024	1.355	59	1.414	58	0	58	1.472
Güzelyayla	2021	276	8	284	26	1	27	311
	2022	637	59	696	62	22	84	780
	2023	604	27	631	44	10	54	685
	2024	1.950	529	2.479	109	23	132	2.611
İbrahimhakkı	2021	0	1	1	0	0	0	1
	2022	0	1	1	0	0	0	1
	2023	0	0	0	0	0	0	0
	2024	0	0	0	0	0	0	0
Karagöbek	2021	985	113	1.098	2	8	10	1.108
	2022	1.957	326	2.283	1	8	9	2.292
	2023	3.254	153	3.407	4	10	14	3.421
	2024	2.069	0	2.069	1	0	1	2.070
Karasu	2021	0	0	0	0	0	0	0
	2022	1.299	213	1.512	99	38	137	1.649
	2023	1.136	271	1.407	94	18	112	1.519
	2024	920	143	1.063	78	17	95	1.158
Kırkgöze	2021	380	28	408	62	4	66	474
	2022	313	37	350	60	18	78	428
	2023	500	141	641	106	14	120	761
	2024	800	126	926	163	52	215	1.141

Güzelova Mahallesi, ilçede küçükbaş hayvancılıkta önemli bir üretim merkezi olmaya devam etmektedir. Nitekim 2021 yılında 1.621 baş olan küçükbaş hayvan sayısı, 2022 yılında %26,8 artarak 2.056'ya yükselmiştir. Ancak, 2023 yılında %2,1'lik daha düşük bir artışla 2.098 başa ulaşmış, 2024 yılı itibarıyla bir önceki yıla göre %29,9 azalma göstererek toplam 1.472 başa gerilemiştir. Özellikle 2024'te koyun dişi sayısında önemli bir düşüş yaşandığı görülmektedir. 2023 yılı ise, keçi varlığında küçük bir azalma yaşansa da, koyun sayısında artış yaşanmış olmasıyla dikkat çekmektedir (Tablo 3). Güzelyayla Mahallesi'nde küçükbaş hayvan varlığı sürekli bir artış göstermektedir. 2021'de 311 baş olan küçükbaş sayısı, 2022'de %151,8 oranında bir artışla 780'e, 2023'te %15,3 artışla 685'e yükselmiştir. Ancak 2024 yılı itibarıyla büyük bir değişim yaşanmış ve küçük baş hayvan sayısı 2.611'e çıkarak %280'lik bir artış kaydedilmiştir. Özellikle koyun dişi ve erkek sayılarındaki önemli artışlar dikkat çekmektedir. Keçi varlığı da artmaya devam etmiştir, ancak koyun varlığı başta olmak üzere küçükbaş varlık miktarı büyük bir büyüme göstermektedir.

İbrahimhakkı Mahallesinde, sürekli olarak çok düşük sayılarla hayvancılık yapılmış ve son iki yılda küçükbaş

hayvan sayısı tamamen sıfırlanmıştır. Bu veriler, mahalledeki küçükbaş hayvancılıkla ilgili herhangi bir üretimin yapılmadığını göstermektedir.

Karagöbek Mahallesi, 2021-2024 yılları arasında ki küçükbaş hayvan sayıları dikkate alındığında sürekli artış gösterdiği belirlenmiştir. 2021 yılında 1.108 baş küçükbaş hayvana sahipken, 2022'de %106,5 oranında artarak 2.292'ye, 2023'te %49,3 artışla 3.421'e çıkmıştır. Ancak, 2024 yılı itibarıyla mahallenin toplam küçükbaş hayvan sayısında %39,5'lik bir azalma yaşanmış olup bu sayı 2.070 kadar gerilemiştir. 2024 yılında erkek koyun sayısındaki azalma dikkat çekmekte fakat yine de mahalle küçükbaş hayvan üretimi konusunda güçlü bir potansiyele sahiptir.

Karasu mahallesine ait ilgili veriler incelendiğinde, 2021 yılı itibarıyla küçükbaş hayvan varlığına sahip değildi. Ancak 2022 yılında 1.649 başla küçükbaş hayvan üretimine başlamıştır. Bu sayı, 2023'te %7,6 artarak 1.519'a, 2024'te ise %24,3 azalarak 1.158'e kadar gerilemiştir. 2024 yılındaki düşüş, keçi sayısındaki azalmaya ve koyun varlığındaki değişikliklere dayanmaktadır. Karasu'da küçükbaş hayvancılığın, özellikle koyun yetiştiriciliği alanında, gelişmeye devam ettiği söylenebilir.

Tablo 4.

2021-2024 Yılları Arasında Kırmızıtaş, Kösememet, Köşk, Kurtuluş, Lalapaşa ve Muratgeldi Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Kırmızıtaş	2021	312	0	312	13	0	13	325
	2022	433	64	497	36	29	65	562
	2023	367	108	475	53	26	79	554
	2024	388	57	445	36	18	54	499
Kösememet	2021	840	72	912	22	24	46	958
	2022	864	136	1.000	41	51	92	1.092
	2023	784	170	954	14	7	21	975
	2024	828	92	920	19	5	24	944
Köşk	2021	3.015	246	3.261	52	4	56	3.317
	2022	2.143	25	2.168	31	0	31	2.199
	2023	1.658	309	1.967	30	0	30	1.997
	2024	1.384	45	1.429	16	2	18	1.447
Kurtuluş	2021	890	152	1.042	73	9	82	1.124
	2022	1.975	270	2.245	118	19	137	2.382
	2023	1.097	207	1.304	108	59	167	1.471
	2024	1.026	528	1.554	70	32	102	1.656
Lalapaşa	2021	96	0	96	0	0	0	96
	2022	96	0	96	0	0	0	96
	2023	25	27	52	0	0	0	52
	2024	0	0	0	0	0	0	0
Muratgeldi	2021	528	64	592	46	4	50	642
	2022	523	71	594	48	3	51	645
	2023	489	34	523	56	1	57	580
	2024	495	95	590	55	18	73	663

Kırkgöze Mahallesi, 2021 yılı itibarıyla 474 baş küçükbaş hayvanla faaliyet göstermekteydi. 2022 yılında %9,7'lik bir azalma ile 428'e düşerken, 2023'te %77,8 oranında büyük bir artış yaşanarak 761'e yükselmiştir. 2024 yılında ise, %50 artışa bağlı olarak 1.141'e ulaşmıştır. Koyun varlığındaki artış, özellikle 2024 yılına kadar devam etmiştir. Keçi sayısı ise, belirli bir düzeyde sabit kalmıştır. Kırkgöze Mahallesi'nde küçükbaş hayvancılığın oldukça güçlü bir şekilde büyüdüğü ve sürdürülebilir bir üretim modeline sahip olduğu gözlemlenmiştir.

Kırmızıtaş Mahallesi, 2021'de 325 baş küçükbaş hayvanla faaliyete başlamıştır. 2022'de, koyun dişi ve erkek sayısındaki artışla toplam küçükbaş hayvan sayısı %73,0 artarak 562'ye yükselmiştir. 2023 yılında kısmi bir azalma yaşanmış ve küçükbaş hayvan sayısı 554'e gerilemiştir. Ancak, 2024 yılına gelindiğinde, %10'luk bir azalma kadar daha yaşanarak toplam 499'a düşmüştür. Koyun dişi sayısındaki düşüş, keçi sayısının azalmasıyla birlikte küçükbaş sayısındaki genel azalmayı göstermektedir.

Kösememet Mahallesi, 2021 yılında 958 baş küçükbaş hayvan yetiştirilmektedir (Tablo4). Mahallede 2022 yılında hem dişi hem de erkek koyunlarda artış göstererek toplam küçükbaş hayvan

varlığı %13,9 oranında artarak 1092 başa kadar yükselmiştir. Daha sonraki yıllarda mevcut sayı da düşüş yaşanarak 2023 yılında bu sayı 975 başa ve 2024 yılında ise 944'e kadar gerilemiştir.

2021 yılında 3.317 baş küçükbaş hayvan varlığıyla Köşk Mahallesi, Yakutiye ilçesindeki diğer mahallelerle kıyaslandığında yüksek bir üretim kapasitesine sahiptir. Ancak, 2022 yılında bu sayı %30,4 oranında azalarak 2.199'a düşmüştür. 2023 yılında bir başka düşüş daha yaşanarak küçükbaş sayısı 1.997'ye gerilemiştir. 2024 yılı itibarıyla, küçükbaş hayvan sayısında bir azalma daha yaşanarak bu sayı 1.447'ye düşmüştür. Dişi ve erkek koyun sayılarındaki düşüş, küçükbaş üretimiyle ilgili büyük bir azalmayı göstermektedir.

Kurtuluş Mahallesinde yetiştirilen küçükbaş hayvan varlığındaki 4 yıllık değişim Tablo 4'de verilmiş olup yıllar itibarıyla 2021 yılında 1124 baş olan hayvan sayısı 2. Yılda %112,5 oranında artış, 3. Yılda %38,3 oranında düşüş son yılda ise bir önceki yıla göre bir artış kaydederek toplam 1656 başa ulaşmıştır. Bu mahalledeki koyun dişi ve erkek sayısındaki artışlar, keçi sayısının stabil kalması ve genel küçükbaş hayvancılığın bu mahalle için sürdürülebilirliğini göstermektedir.

Tablo 5.

2021-2024 Yılları Arasında Mülk, Ortadüzü, Söğütyanı, Şenyurt, Şükrüpaşa ve Umudum Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Mülk	2021	168	0	168	1	0	1	169
	2022	421	0	421	1	0	1	422
	2023	324	15	339	2	0	2	341
	2024	438	0	438	8	2	10	448
Ortadüzü	2021	1.779	52	1.832	8	1	9	1.840
	2022	2.536	103	2.639	8	1	9	2.648
	2023	2.670	291	2.961	84	0	84	3.045
	2024	1.485	317	1.802	105	10	115	1.917
Söğütyanı	2021	0	0	0	0	0	0	0
	2022	83	23	106	23	8	31	137
	2023	83	23	106	0	0	0	106
	2024	0	0	0	0	0	0	0
Şenyurt	2021	709	216	925	27	9	36	961
	2022	172	530	702	1	0	1	703
	2023	310	578	888	0	0	0	888
	2024	139	48	187	0	0	0	187
Şükrüpaşa	2021	57	5	62	2	0	2	64
	2022	29	5	34	2	0	2	36
	2023	28	0	28	2	0	2	30
	2024	20	0	20	0	0	0	20
Umudum	2021	951	9	960	23	2	25	985
	2022	1.031	61	1.092	20	2	22	1.114
	2023	1.309	132	1.441	29	0	29	1.470
	2024	1.643	248	1.891	43	1	44	1.935

Lalapaşa Mahallesi, 2021 yılında sadece 96 baş küçükbaş hayvana sahipken, 2022'de sayı değişmemiştir. 2023 yılına gelindiğinde, küçükbaş hayvan sayısı %45,8 oranında azalmış ve 52'ye düşmüştür. 2024 yılında ise bu mahallede küçükbaş hayvan yetiştiriciliği tamamen sona ermiştir.

Muratgeldi Mahallesi, 2021 yılı itibarıyla 642 baş küçükbaş hayvana sahiptir. 2022'de çok küçük bir artışla 645 başa çıkmış, 2023'te ise %9,7'lik bir azalma ile 580'e düşmüştür. Ancak, 2024 yılında %14,3 artış yaşanmış olup bu artışla mahallenin toplam hayvan varlığı 663 başa ulaşmıştır. Keçi ve koyun sayısındaki değişimler, mahallede küçükbaş hayvancılığın stabil şekilde devam ettiğini ancak zaman zaman dalgalanma yaşandığını göstermektedir.

Mülk Mahallesi, 2021 yılında küçükbaş hayvancılık faaliyetlerine 169 başla başlamıştır. Bir sonraki yılda bu sayı, koyun dişi sayısındaki artışa paralel olarak toplam hayvan varlığında yaklaşık %150 kadar bir artışla 422 başa ulaşmış, 2023 yılında artış yerini azalışa bırakarak 341 başa düşmüştür. Ancak 2024 yılına gelindiğinde, küçükbaş hayvan sayısında bir artış kaydederek bu sayı 448 başa kadar çıkmıştır. Bu yıllık artış, koyun sayısındaki yükselişle birlikte, keçi sayısındaki artışla da

desteklenmiştir. Mülk Mahallesi'nde küçükbaş hayvan sayısı genel olarak dalgalı bir seyir izlemiş, ancak 2024 itibarıyla bir toparlanma yaşanmıştır.

Ortadüzü Mahallesi, 2021 yılında 1.840 baş küçükbaş hayvanla faaliyet göstermeye başlamıştır. 2022'de küçükbaş sayısı %44 artışla 2.648'e çıkmıştır. 2023 yılında ise, koyun ve keçi sayısındaki ciddi artışlarla birlikte küçükbaş hayvan sayısı 3.045'e yükselmiştir. Ancak 2024 yılında, önceki yıllarda yaşanan artışın tersine, küçükbaş hayvan sayısı %37,1 oranında azalarak 1.917'ye düşmüştür. Koyun dişi ve erkek sayılarındaki düşüş, küçükbaş üretimle ilgili bazı olumsuz gelişmeleri işaret etmektedir.

Söğütyanı Mahallesi, 2021'de küçükbaş hayvancılığa başlamamıştır. Ancak 2022 yılında, küçük bir başlangıç yaparak 137 başa ulaşmıştır. 2023'te, mevcut hayvan sayısının sabit kaldığı ve hiçbir yeni üretim yapılmadığı gözlemlenmiştir. 2024 yılı itibarıyla ise, küçükbaş hayvancılık tamamen sona ermiştir ve 0 başa düşmüştür. Söğütyanı Mahallesi'nde küçükbaş hayvancılığın düşük seviyede ve kısa vadeli bir faaliyet olduğu, yerel üretimde bir istikrarsızlık yaşandığı görülmektedir.

Tablo 6.

2021-2024 Yılları Arasında Uzunyayla, Üniversite, Yazıpınarı, Yerlisu, Yeşilyayla ve Yolgeçti Mahallelerinde Küçükbaş Hayvan Varlığı

Mahalleler	Yıl	Koyun			Keçi			Küçükbaş Toplam
		Dişi	Erkek	Toplam	Dişi	Erkek	Toplam	
Uzunyayla	2021	2.035	799	2.834	103	4	107	2.941
	2022	3.421	699	4.120	71	16	87	4.207
	2023	2.791	865	3.656	67	16	83	3.739
	2024	3.290	154	3.444	44	26	70	3.514
Üniversite	2021	0	0	0	0	0	0	0
	2022	563	255	818	8	2	10	828
	2023	522	214	736	8	2	10	746
	2024	657	328	985	8	2	10	995
Yazıpınarı	2021	2.663	400	3.063	141	15	156	3.219
	2022	3.541	635	4.176	136	21	157	4.333
	2023	3.640	729	4.369	174	21	195	4.564
	2024	2.219	372	2.591	82	9	91	2.682
Yerlisu	2021	0	0	0	0	0	0	0
	2022	4	0	4	0	0	0	4
	2023	0	0	0	0	0	0	0
	2024	182	0	182	0	0	0	182
Yeşilyayla	2021	218	0	218	0	0	0	218
	2022	291	78	369	0	0	0	369
	2023	405	91	496	1	3	4	500
	2024	555	71	626	3	0	3	629
Yolgeçti	2021	881	118	999	91	39	130	1.129
	2022	0	0	0	0	0	0	0
	2023	0	0	0	0	0	0	0
	2024	0	0	0	0	0	0	0

Şenyurt Mahallesi, 2021'de 961 baş küçükbaş hayvanla faaliyete başlamıştır. 2022'de koyun sayısındaki artışla birlikte küçükbaş sayısı 703'e düşmüş ve ardından 2023'te tekrar bir artış yaşanarak 888'e çıkmıştır. 2024 yılında ise küçükbaş hayvan sayısı %78,9 oranında büyük bir düşüşle 187'ye gerilemiştir. 2024'te koyun sayısındaki kayıplar, Şenyurt Mahallesi'nde küçükbaş hayvancılığın olumsuz bir yıl geçirdiğini göstermektedir.

Şükrüpaşa Mahallesi, 2021 yılında 64 baş küçükbaş hayvanla başlamış ve 2022'de sayıda %43,7 bir düşüş yaşamıştır, 36 başa gerilemiştir. 2023 yılı itibarıyla küçükbaş sayısı 30'a düşerken, 2024 yılına gelindiğinde küçükbaş hayvancılık tamamen sona ermiştir. 2024'te 0 başa düşen sayılar, bu mahallede küçükbaş hayvancılığın tamamen sonlandığını gösteriyor.

Umudum Mahallesi, 2021'de 985 başla küçükbaş hayvancılığa başlamıştır. 2022'de 1.114'e çıkarak %13,1 oranında bir artış göstermiştir. 2023'te küçükbaş hayvan sayısı 1.470'e yükselmiş ve 2024 yılı itibarıyla büyük bir artışla 1.935'e çıkmıştır. Bu mahallede, küçükbaş hayvancılık faaliyetleri sürekli bir büyüme göstermiş ve 2024 yılına gelindiğinde büyük bir artış yaşanmıştır.

Uzunyayla, 2021 yılında 2.941 baş küçükbaş hayvanla faaliyetlerine başlamıştır. 2022'de, koyun ve keçi sayılarındaki artışla küçükbaş hayvan sayısı 4.207'ye yükselmiştir. 2023'te, koyun dişi sayısındaki azalmalara rağmen toplam küçükbaş sayısı 3.739'a gerilemiştir. 2024 yılında ise, koyun sayısındaki artışla birlikte 3.514'e çıkmıştır. Uzunyayla Mahallesi'nde, küçükbaş hayvancılık çoğunlukla koyun üretimine dayanmakta olup, 2024'te keçi sayısında azalma gözlemlenmiştir. Bu mahalledeki küçükbaş hayvancılık, zaman zaman dalgalanma gösterse de, genel olarak yüksek seviyelerde devam etmiştir.

Üniversite Mahallesi, 2021'de küçükbaş hayvancılık faaliyeti yürütmemiştir. 2022 yılına gelindiğinde, 818 başa ulaşarak bir başlangıç yapmıştır. 2023'te bu sayı 746'ya gerilemiş olsa da, 2024 yılı itibarıyla yeniden artarak 995'e çıkmıştır. Üniversite Mahallesi'nde küçükbaş hayvancılık faaliyetleri sınırlı olmakla birlikte, ilerleyen yıllarda belli bir büyüme göstermiştir. Özellikle koyun sayısı artırılmaya çalışılmış ve keçi üretimi sabit kalmıştır. Yıllık artışlar, mahallede küçükbaş hayvancılığa yönelik bir gelişim olduğunu ancak bunun başlangıç aşamasında olduğunu göstermektedir.

Yazıpınarı, 2021 yılında 3.219 baş küçükbaş hayvanla faaliyete başlamıştır. 2022 yılında 4.333'e çıkarak %34'lük bir artış yaşanmıştır. 2023'te ise 4.564 başla faaliyetler devam etmiştir. Ancak 2024 yılında, koyun dişi sayısındaki azalma ve küçükbaş toplamındaki düşüşle 2.682 başa gerilemiştir. Yazıpınarı Mahallesi, başlangıçta hızlı bir büyüme göstermiş, ancak 2024 yılı itibarıyla koyun üretimi azalmış ve küçükbaş hayvan sayısında düşüş yaşanmıştır. Mahallede, koyun sayısındaki azalmaya rağmen keçi sayısının nispeten stabil kalması dikkat çekmektedir.

Yerlisu, 2021 yılında küçükbaş hayvancılık yapmamıştır. 2022 yılında ise sadece 4 başla faaliyete başlamıştır. 2023 yılında hiçbir küçükbaş hayvan üretimi yapılmamış, 2024 yılında ise 182 başa ulaşılmıştır. Yerlisu, küçükbaş hayvancılık faaliyetlerine oldukça geç başlamış ve üretim sınırlı kalmıştır. 2024'teki artış, mahalledeki üretimin artmaya başladığını gösteriyor. Ancak Yerlisu'nun küçükbaş üretimi, sınırlı ve dalgalı bir seyir izlemektedir.

Yeşilyayla, 2021 yılında 218 baş küçükbaş hayvanla faaliyetlerine başlamıştır. 2022'de 369'a çıkarak önemli bir artış göstermiştir. 2023'te 496'ya çıkmış, ardından 2024 yılına gelindiğinde ise küçükbaş hayvan sayısı 629'a ulaşmıştır. Yeşilyayla Mahallesi, özellikle koyun üretiminde bir artış trendi göstermiştir. Keçi üretimi ise sabit kalmıştır. Mahallede küçükbaş hayvancılık sürekli olarak artış göstermiş ve 2024 yılı itibarıyla büyümesini sürdürmüştür.

Yolgeçti, 2021'de 1.129 başla faaliyetlerine başlamıştır. Ancak 2022, 2023 ve 2024 yıllarında hiçbir üretim yapılmamıştır. Yolgeçti Mahallesi'nde küçükbaş hayvancılık, 2021 yılı sonrası tamamen durmuştur. 2024'te de hiçbir küçükbaş hayvan sayısı kaydedilmemiştir, bu da mahalledeki küçükbaş hayvancılıkla ilgili faaliyetlerin tamamen sona erdiğini göstermektedir.

Sonuçlar ve Öneriler

Bu çalışma, Erzurum ili Yakutiye ilçesinde 2021–2024 yılları arasında küçükbaş hayvancılığın mahalle düzeyinde küçükbaş hayvan sayıları ele alınış olup yıllar itibarıyla değişimde nasıl bir seyir izlediğini kapsamlı biçimde ortaya koymuştur. Elde edilen bulgular, ilçedeki yürütülen küçükbaş hayvancılığın 4 yıllık bir zaman aralığında homojen olmayan bir dağılım gösterdiğini ve mahalleler arasında ciddi farklar bulunduğunu açıkça göstermektedir. Bazı mahalleler, küçükbaş hayvan sayılarında istikrarlı ve dikkat çekici artışlar sergileyerek hayvancılık açısından önemli merkezler haline gelmiştir. Özellikle Dumlulu, Güzelyayla, Umudum, Aktoprak, Uzunyayla ve Karagöbek mahallelerinde küçükbaş hayvan varlığında yüksek oranlarda artışlar yaşanmış, bu mahalleler ilçede küçükbaş hayvancılık açısından öncü konuma gelmiştir. Dumlulu Mahallesi'nde küçükbaş hayvan sayısı dört yıl içinde yaklaşık %70 oranında artışla 8.987'ye ulaşarak, ilçedeki en güçlü hayvancılık merkezlerinden biri haline gelmiştir. Güzelyayla Mahallesi'nde ise 2021–2024 arasında gerçekleşen artış oranı %739 gibi dikkat çekici bir artış olarak kaydedilmiştir. Buna karşılık, bazı mahallelerde küçükbaş hayvancılığın ya ciddi biçimde azaldığı ya da tamamen sona erdiği görülmektedir. Altınbulak, Altıntepe, Söğütyanı, Şükrüpaşa, Yolgeçti ve İbrahimhaklı mahallelerinde 2024 itibarıyla küçükbaş hayvan varlığı sıfırlanmıştır. Çiftlik, Değirmenler, Lalapaşa ve Gökçeyamaç gibi bazı mahallelerde de büyük oranlı azalmalar yaşanmıştır. Bu azalmaların temelinde; göç, üretim maliyetlerinin artması, meraya erişim sorunları, pazarlama zorlukları veya üreticilerin sektörden çekilmesi gibi etkenlerin

bulunduğu düşünülmektedir. Köşk, Karasu ve Ortadüzü gibi mahallelerde ise bir dönem artış yaşanmış, ardından ciddi düşüşler gözlemlenmiştir. Bu durum, küçükbaş hayvancılığın bu mahallelerde bölgelerde istikrarsız bir yapı sergilediğine işaret etmektedir. Özellikle Köşk Mahallesi'nde 2021 yılında 3.317 olan küçükbaş sayısının 2024'te 1.447'ye düşmesi, üretimin sürdürülebilirliği açısından ciddi bir tehdit oluşturmaktadır. Bunun yanında bazı mahallelerde küçük çaplı ama dengeli bir üretim yapısının sürdüğü anlaşılmaktadır. Mülk, Muratgeldi, Yeşilyayla, Kurtuluş, Kırkgöze ve Kırmızıtaş mahallelerinde dalgalanmalara rağmen üretim devam etmiş, özellikle koyun yetiştiriciliği ön planda olmuştur. Keçi yetiştiriciliği ise ilçenin genelinde sınırlı kalmakta, bazı mahallelerde ise hiç bulunmamaktadır.

Sonuç olarak, Yakutiye ilçesinde küçükbaş hayvancılık mahalle bazında oldukça farklılık göstermektedir. Bazı mahalleler hayvan sayısını artırırken, bazıları sektörden tamamen çekilmiştir. Bu durum, yerel kalkınma politikalarının mahalle bazında planlanması gerektiğini ortaya koymaktadır. Küçükbaş hayvancılığın sürdürülebilirliğini artırmak için şu öneriler geliştirilebilir: Üreticilere yönelik yem sübvansiyonları ve girdi desteklerinin artırılması, meraya erişimi artıracak düzenlemelerin yapılması, iklim değişikliğine dirençli üretim sistemlerinin yaygınlaştırılması, genç nüfusun hayvancılığa yönlendirilmesi amacıyla teşvik programlarının uygulanması, mahalle bazlı teknik destek ve yayım hizmetlerinin güçlendirilmesi, hayvan sağlığı ve hijyen standartlarının iyileştirilmesi, küçükbaş hayvan ırklarının ıslahı ve genetik gelişiminin sağlanması, pazar çeşitliliği ve değer zinciri oluşturulması, hayvancılıkla ilgili eğitim programlarının yaygınlaştırılması, su kaynaklarının verimli kullanımı, yerli tohum ve yem üretiminin desteklenmesi, coğrafi işaretlerin kullanımı ve yerel markaların desteklenmesi, hayvancılık sektöründe dijitalleşme ve teknoloji kullanımı, hayvancılık işletmelerinin kooperatifleşmesi. Bu çerçevede, kırsal alanlarda hayvancılığın sadece ekonomik değil aynı zamanda sosyo-kültürel bir faaliyet olduğu unutulmamalı ve küçük üreticilerin sürdürülebilirliğini sağlayacak yapısal önlemler ivedilikle hayata geçirilmelidir.

Etik Komite Onayı: Etik kurul onayına gerek yoktur.

Hakem Değerlendirmesi: Dış bağımsız.

Çıkar Çatışması: Yazar, çıkar çatışması olmadığını beyan etmiştir.

Finansal Destek: Yazar bu çalışmanın herhangi bir finansal destek almadığını beyan etmişlerdir.

Ethics Committee Approval: Ethics committee approval is not required.

Peer-review: Externally peer-reviewed.

Conflict of Interest: The author has no conflicts of interest to declare.

Financial Disclosure: The author declared that this study has received no financial support.

Kaynaklar

- Aksoy, A., (2008). Doğu Anadolu Hayvancılığının Avrupa Birliğine Uyumu ve Rekabet Edebilirliğinin Analizi (Tez No: 177745). [Doktora Tezi, Atatürk Üniversitesi].
- Aksoy, A., & Yavuz, F. (2012). Çiftçilerin küçükbaş hayvan yetiştiriciliğini bırakma nedenlerinin analizi: Doğu Anadolu bölgesi örneği. *Anadolu Tarım Bilimleri Dergisi*, 27(2), 76-79.
- Alkan, M. (2010). *Küçükbaş hayvancılığın acı sonu*. <http://www.ciftlikdergisi.com.tr/kucukbas-hayvanciligin-aci-sonu.html>
- Anonim, (2025a). Türkiye İstatistik Kurumu Hayvansal üretim verileri. <https://biruni.tuik.gov.tr/medas/?kn=101&locale=tr>
- Anonim, (2025b). https://en.wikipedia.org/wiki/Yakutiye#cite_note-3
- Barıt, B., Cengiz, B. N., Belgemen, F., Has, B., Varalan, A., & Çevrimli, M. B. (2025). Türkiye'de Planlamanın Evrimi ve Hayvancılık Sektöründe Planlamalar –Ulaşılan Hedefler. *Veteriner Farmakoloji ve Toksikoloji Derneği Bülteni*, 16(1), 9-21.
- Ertuğrul, M., Savaş, T., Dellal G., Taşkın T., Koyuncu, M., Cengiz, F., Dağ, B., Koncagül, S. & Pehlivan, E. (2010). *Türkiye'de Küçükbaş Hayvancılığın İyileştirilmesi*. Ziraat Mühendisliği VII. Teknik Kongresi, 11-15 Ocak, Ankara.
- Gökmener, H., & Öztürk, A. (2022). Erzurum İli Uzundere İlçesinde Küçükbaş Hayvancılık Faaliyetleri ve Genel Sorunlar. *Bahri Dağdaş Hayvancılık Araştırma Dergisi*, 11(1), 21-29.
- Karagöz, H. (2009). Türkiye ve Konya'da hayvancılık sektörü, sektörün sorunları ve çözüm önerileri. *Konya Ticaret Odası Etüd Araştırma Servisi, Konya*.
- Kaymakçı, M. (2006). *İleri Koyun Yetiştiriciliği*. "Ders Kitabı Bornova, İzmir."
- Kopuzlu, S. (2023). Erzurum İli'nde Küçükbaş ve Büyükbaş Hayvancılığın Mevcut Durumu ve Meralar Açısından Potansiyeli. *Uluslararası Gıda Tarım ve Hayvan Bilimleri Dergisi*, 3(2), 41-51.
- Koyuncu, M. (2012). *Türkiye hayvancılığında küçükbaş hayvancılığının yeri*. Bursa Tarım Kongresi, (27-29 Eylül 2012), Bursa.
- Özdemir, V. F., Tarhan, O., & Bayram, B. (2024). Farm Management and Socio-Economic Structure of Cattle Enterprises in Eastern Anatolia: A Case Study of Selim District, Kars Province. *Journal of Agricultural Production*, 5(4), 272-282.
- Özen, N., Çakır, A., Haşimoğlu, S. & Aksoy, A. (1993). *Yemler ve yem teknolojisi*. Atatürk Üniversitesi Ziraat Fakültesi Ders Yayınları.