

Received: 06.06.2023  
Accepted: 12.06.2023

## Süt Sığırlarının Buzağılama Zamanının Tahmininde Makine Öğrenme Yöntemlerinin Kullanımı Çalışmaları Üzerine Bir Değerlendirme

Oğuzhan SÖNMEZ<sup>1</sup>, Kenan ZENGİN<sup>2</sup>

<sup>1</sup>Tokat Gaziosmanpaşa Üniversitesi, Reşadiye Meslek Yüksekokulu, Bilgisayar Teknolojiler Bölümü, 60250, Tokat, Türkiye  
<sup>2</sup>Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 60250, Tokat, Türkiye

### Özet

Süt sığırlarının buzağılama zamanlarının tahmin edilmesindeki öneme odaklanan bu çalışmada, makine öğrenme yöntemlerinin kullanımını değerlendirilmektedir. Buzağılama zamanının tahmin edilmesi süt üretiminde önemli bir görevdir. Buzağılama zamanının erken tahmini, çiftçilerin inekleri özel bir buzağılama bölgesine ne zaman taşıyacakları veya yem miktarını ne zaman artıracakları gibi sürü yönetimi hakkında bilinçli kararlar almalarına yardımcı olabilmektedir. Çalışmada, süt sığırlarında buzağılama zamanını tahmin etmek için makine öğrenmesi yöntemlerinin kullanımı değerlendirilmiştir. Makine öğrenme yöntemleri, büyük veri kümelerindeki kalıpları ve ilişkileri tanımlayarak tahmin yapabilen bir yöntem olarak öne çıkmaktadır. İncelenen çalışmalarda destek vektör makineleri, naïve bayes, evrişimsel sinir ağları, tekrarlayan sinir ağları, rastgele orman, lojistik regresyon ve sinir ağları dâhil olmak üzere çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Bu çalışma, farklı makine öğrenme modellerinin buzağılama zamanı tahminlerini değerlendirerek, süt sığırları yetiştiricilerine daha doğru bir şekilde buzağılama zamanlarını tahmin etme konusunda rehberlik etme amacıyla hazırlanmış olup, makine öğrenmesi yöntemlerinin süt çiftçileri için değerli bir araç olabileceğini göstermektedir. Bu yöntemler, çiftçilerin sürü yönetimi hakkında daha bilinçli kararlar almasına yardımcı olabilir ve bu da hayvan refahının iyileştirilmesine ve süt üretiminin artmasına yol açabilir.

**Anahtar Kelimeler:** Buzağılama tahmini, makine öğrenmesi, süt sığırcılığı, yapay zekâ

## Using Machine Learning Methods to Predict the Calving Time of Dairy Cattle: An Overview

Oğuzhan SÖNMEZ<sup>1</sup>, Kenan ZENGİN<sup>2</sup>

### Abstract

Focusing on the importance of predicting the calving time of dairy cattle, this study evaluates the use of machine learning methods. Predicting calving time is an important task in milk production. Early prediction of calving time can help farmers to make informed decisions about herd management, such as when to move cows to a specialized calving pen or when to increase the amount of feed. This study evaluates the use of machine learning methods to predict calving time in dairy cattle. Machine learning methods stand out as a method that can make predictions by identifying patterns and relationships in large datasets. Various machine learning methods including support vector machines, naïve bayes, convolutional neural networks, recurrent neural networks, random forest, logistic regression and neural networks have been used in the reviewed studies. By evaluating the calving time predictions of different machine learning models, this study guides dairy farmers to more accurately predict calving times and shows that machine learning methods can be a valuable tool for dairy farmers. These methods can help farmers make more informed decisions about herd management, which can lead to improved animal welfare and increased milk production.

**Keywords:** Calving prediction, machine learning, dairy farming, artificial intelligence

## 1. Giriş

Buzağılama, sığır endüstrisinde önemli bir olaydır ve hayvanların doğurganlığı ve üretkenliği açısından büyük önem taşımakta ve bir ineğin gebe kalmasını takiben doğum yapması olarak tanımlanabilmektedir. Normal şartlar altında, bir ineğin gebeliği yaklaşık 280-290 gün sürmekte ve işaretler vererek doğum zamanının yaklaştığını belirtmektedir [1]. İnekler genellikle ayakta doğum yaptıkları için, doğumda ortaya çıkan problemler hayvanın ve yavrusunun sağlığı açısından buzağının kanalda sıkışması, buzağının ters durması, yaralanma, iltihaplanma ve yeterli miktarda kolostrum alamaması gibi sıralanabilir [2]. Bu komplikasyonların önüne geçebilmek için buzağılama zamanının tahmini önem teşkil etmektedir. Literatürdeki çalışmalar incelendiğinde buzağılama zamanının tahmin edilmesinde, kamerayla izleme [3], ultrason görüntülerini inceleme [4], hormonal testler [5], gözlem yoluyla ve makine öğrenmesi yöntemleri olmak üzere farklı yöntemlerin kullanıldığı görülmektedir. Bunlar arasında makine öğrenmesi en güncel tahmin yöntemi olarak kullanılmaktadır.

İnsanların yaptıkları işleri makinelerle yaptırma fikri 1956 yılında John McCarthy tarafından ortaya konulmuştur ve böylece yapay zekânın temelleri atılmıştır [6]. Yapay zekânın temelini oluşturan diğer bir buluş olan Turing makinesini ise Alan Turing tarafından ortaya çıkartılmıştır. Farklı birçok bilim dalının katkısıyla yapay zekâ gelişerek bugüne gelmiştir. Yapay zekânın alt dalı olan makine öğrenmesi, verilerden öğrendiğini model ve algoritmalar sayesinde sonuç çıkarmayı sağlamaktadır [7]. Makine öğrenmesi birçok alanda sınıflandırma ve tahmin problemlerine çözüm olmaktadır. Makine öğrenmesi, büyük veri setlerinden güvenilir, doğru ve hızlı anlamlar çıkarmak için önemli bir katkı sağlamaktadır. Bu algoritma ve teknikler, karmaşık veri yapıları arasındaki ilişkileri ve desenleri keşfederek, verilerdeki bilgileri çözümlememize yardımcı olmaktadır. Hayvancılık sektöründe önemli bir yere sahip ve büyük bir endüstri olan süt sığırcılığının, buzağılamayla doğrudan ilişkisi bulunmaktadır. Buzağılama tahmini, sığırların sağlığını korumak, buzağılama kayıplarını önlemek, hayvanın refahını artırmak, işletme maliyetlerini düşürmek için önemli yere sahiptir [8]. Buzağılama kayıplarının Türkiye’de %15 civarında hayvancılıkta gelişmiş ülkelerde ise %2 ile %25 arasında değiştiği görülmektedir [9,10]. Buzağı kayıplarının büyük bir bölümünün önlenemez olduğu söylenebilir [11].

Bu çalışmanın amacı, süt sığırcılığı alanında buzağılama zaman tahmini için makine öğrenme yöntemlerinin kullanılması ve modellerin katkıları hakkında genel bir bakış açısı sunmaktır. Çalışmada buzağılama tahmininde kullanılan makine öğrenmesi modellerine odaklanılmıştır.

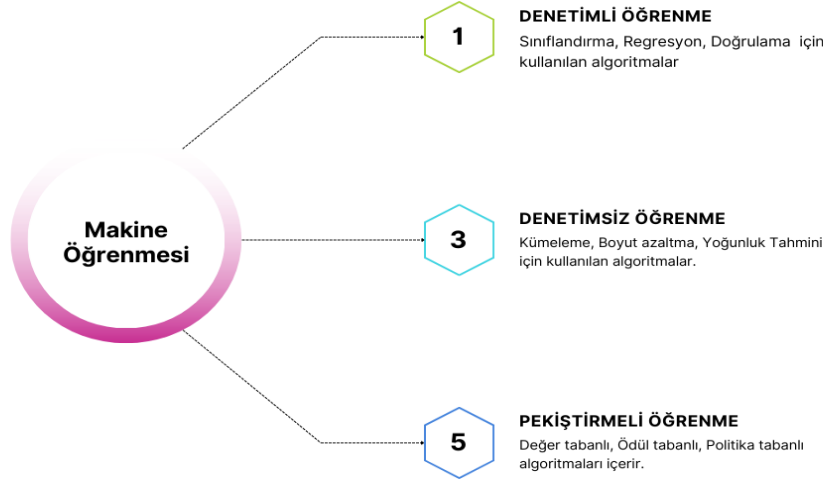
Derleme Web of Science ve Google Akademik veri tabanında indekslenen süt sığırlarında buzağılama çalışmaları değerlendirilerek yapılmıştır. İlgili yayınlar, Medline, CAB Abstracts, BIOSIS Citation Index ve Zoological Record veri tabanlarında eş zamanlı arama yapılmasına imkan sağlayan Web of Science platformu ve Google akademik veri tabanında aranmıştır. Ek makaleler, veri tabanı aramalarında tespit edilen makalelerde atıfta bulunulan referanslardan elde edilmiştir. Arama anahtar kelimeleri arasında buzağılama, doğum, tahmin, makine öğrenmesi, yapay zeka, süt, sığır, inek, davranışsal hareket, otomatik ve bunların kombinasyonları yer almıştır.

## 2.Makine Öğrenmesi ve Buzağılama Tahmini

### 2.1. Makine Öğrenmesi

Makine öğrenmesi, insan zekasını taklit etmek amacıyla çevresel bilgilerden öğrenme yeteneği sağlayan hesaplama algoritmalarının bir dalıdır [12]. Temel amacı, verilerden öğrenme yeteneği kazanmak ve bu öğrenmeyi kullanarak bilgi çıkarabilmektir [13]. Makine öğrenmesi algoritmaları,

veri setindeki deęişkenler arasındaki ilişkileri ortaya çıkarmak için çeşitli yöntemler kullanır. Şekil 1’ de makine öğrenmesi sınıfları gösterilmektedir.



Şekil 1. Makine Öğrenmesi

Son yıllarda dijitalleşmenin hızla yaygınlaşması ile birlikte, verilerin düzenli bir şekilde kaydedilmesi ve toplanması daha da önem kazandı. Bu büyük miktardaki verinin işlenmesi ve analiz edilmesi için makine öğrenmesi teknikleri kullanımı da gün geçtikçe artmaktadır. Bu sayede, verilerden elde edilecek değerli bilgiler daha etkin bir şekilde kullanılabilen ve karar alma mekanizmalarında daha doğru sonuçlar elde edilebilmektedir. Makine öğrenmesinin geleneksel yöntemlere göre bazı avantajları vardır. Tahmin ve genelleme yeteneği, eğitim verilerinden öğrendikleri desenleri kullanarak yeni veriler üzerinde tahmin yapabilirler ve genelleme yeteneği ile eğitim verileri dışındaki veriler üzerinde de iyi performans gösterebilirler [13]. Geleneksel yöntemlere göre zor ve zaman alıcı karmaşık ilişkilerin tanımlanmasını kolaylaştırır. Otomatik öğrenme ve adaptasyon sayesinde, makine öğrenme algoritmaları, veriler üzerinde otomatik öğrenme yapabilmekte ve modellerini sürekli olarak güncelleyebilmektedir [14]. Makine öğrenmesi karmaşık ve büyük veri setlerinin ilişkileri hızlı ve etkili bir şekilde keşfedebilir ve işleyebilir [15]. Veri setindeki önemli öznitelik çıkarımı yaparak doğru sonuçlara ulaşabilmektedir. Makine öğrenmesi ölçeklenebilirlik özelliğiyle büyük veri setleriyle geleneksel yöntemlere göre daha kolay çalışabilmektedir.

## 2.2. Buzağılama Tahmini

Literatür incelendiğinde buzağılama tahmini için kullanılan bazı parametreler ve yöntemler öne çıkmaktadır [21-34]. Bu parametreler, ineklerin davranışsal farklılıklarını oluşturan özelliklerdir. Adım sayısı, yatma süresi, ayakta kalma süresi, yatma sıklığı, geviş getirme süresi, sıcaklık değerleri, kuyruk kaldırma sayısı, başını çevirme sayısı, sütündeki protein değeri, vücut ve meme genetik değeri gibi farklı birçok parametreden oluşmaktadır. Buzağılama zamanı yaklaştıkça parametreler arasında ilişkiler belirginleşmektedir. Makine öğrenmesi algoritmaları, yukarıdaki özelliklerden oluşan veri setindeki deęişkenlerin birbirleriyle olan ilişkilerini analiz etmekte ve bu ilişkileri

modellemek için matematiksel teknikler uygulamaktadır. Bu sayede, değişkenler arasındaki ilişkiler anlaşılabilir ve gelecekteki sonuçları tahmin etmek için kullanılabilir.

### 2.3. Yapılan Çalışmalar

Berglund ve ark. [16], Kornmatitsuk ve ark. [17], Streyl ve ark. [18] araştırmacıların yaptıkları 3 farklı çalışmada, buzağılamaya hazırlık sürecince vulvanın şişmesi ve pelvik bağların gevşemesi ile doğrusal bir ilişki olduğunu tespit etmişlerdir. Bu belirtilerin buzağılamanın 12 saat içinde olacağına dair en güvenilir ve yararlı işaretler olduğunu ortaya koymuşlardır.

Matsas ve ark. [5], 45 inekten aldıkları kan örneklerinde progesteron konsantrasyonlarını incelemişlerdir. Konsantrasyonun düşük olduğunda buzağılama için pozitif, yüksek olduğunda ise buzağılama için negatif olarak sınıflandırmışlardır. 187 plazma örneğinde %89.8 doğrulukla sınıflandırma başarıları göstermiştir. İneklerin %95' den fazlası plazma progesteronu <1,3 ng/ml'ye ulaştığında 24 saat içinde buzağılamıştır. Yöntemin ineklerde buzağılama gününü tahmin etmek için hızlı ve pratik bir yöntem olduğunu tespit etmişlerdir.

Burfeind ve ark. [19], yaptıkları çalışmada ineğin vajinasına yerleştirdikleri sıcaklık ölçerler sayesinde günde 2 defa sıcaklık ölçümlerini yapmışlardır. Farklı saatlerde yaptıkları ölçümlerin ilkinde ortalama %67 duyarlılık ve %84 özgüllükle buzağılamanın 24 saat içinde olacağını öngörmüşlerdir. Sabah saatlerinde yaptıkları diğer ölçümde ise ortalama %56 duyarlılık ve %87 özgüllükle buzağılamanın 24 içinde olacağını tahmin etmişlerdir. Vajinal sıcaklık, rektal sıcaklık ve sıcaklık-nem indeksi arasındaki ilişki Pearson korelasyonu ile hesaplanmıştır. Vajinal ve rektal sıcaklık düşüşünün buzağılama ile ilişkili olduğunu ortaya koymuşlardır.

Cangar ve ark. [3], ineklerin buzağılamadan önceki son 24 saatini kameralar yardımıyla sınıflandırma işlemine tabi tutmuştur. Bu sayede ineklerin ayakta durma ve yatma davranışlarını %85 yeme ve içme işlemlerini %87 doğrulukla sınıflandırmışlardır. Bu yöntemin ineklerin buzağılama zamanını tespit için alarm olabileceğini önermişlerdir.

Palombi ve ark. [20], 360 inek üzerinde yaptıkları çalışmada ineklerin buzağılama belirtileri görüldüğünde vajinalarının kranial bölgesine yerleştirdikleri protip cihaz ile buzağılama zamanını ölçümlemişlerdir. Doğum sürecinde prototip cihaz hayvanın vücudundan çıktığında sinyal göndererek doğumun başladığını işaret etmektedir. Alarmdan  $15 \pm 5$  dakika sonra fetüslerin %68.9' u ön ayakları vulva çıkışının dışında olduğunu tespit etmişlerdir. Oluşturdukları prototip sayesinde buzağılama zamanı hayvanın yanında bulunmuş ve buzağılama yapan hayvanların % 33' ünün yardıma ihtiyaç duyduğunu tespit etmişlerdir.

Clark ve ark. [21], çalışmalarında, Avustralya'da 27 inek için geviş getirme süresi ve aktivite seviyesi profillerini belirlemek amacıyla sensör ve ivmeölçer kullanılmıştır. Cihazlardan alınan veriler, her bir inek için saatlik olarak kaydedilmiştir. Buzağılama zaman tahmini için kısıtlı maksimum olabilirlik modelini kullanarak hayvanların aktivite ve geviş getirme verileri analiz edilmiş ve %70 doğrulukla sınıflandırma yapmışlardır.

Borchers ve ark. [22], çalışmalarında sensör ve ivmeölçerler sayesinde 53 Holstein süt sığırından geviş getirme süresi, toplanan adım sayısı, yatma süresi, ayakta kalma süresi, ayaktan yatmaya geçiş sayısı ve toplam hareket sayıları geliştirilen model için girdi olarak kullanılmıştır. Veriler buzağılamadan önceki 14 gün içinde 2 saatlik periyotlarla tutulmaktadır. Çalışmada gün ve saat tahmini için makine öğrenme yöntemlerinden Rastgele Orman (RF), Doğrusal Diskriminant Analizi (LDA) ve Sinir Ağı (NN) algoritmaları kullanılmıştır. Çizelge 1'de buzağılamadan önceki son 8 saati Tablo 2'de buzağılama günü tahmin sonuçları bulunmaktadır.

**Tablo 1.**Buzağılamadan önceki son 8 saat tahmini [22]

	<b>Duyarlılık (%)</b>	<b>Özgüllük(%)</b>	<b>Pozitif Tahmin Değeri (PPV) (%)</b>	<b>Negatif Tahmin Değeri (NPV) (%)</b>
RF	72.4	82.1	67.7	85.2
LDA	75.9	75	61.1	85.7
NN	82.8	80.4	68.6	90

**Tablo 2.** Buzağılama Günü Tahmini [22]

	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>	<b>PPV (%)</b>	<b>NPV(%)</b>
RF	25	90	16.7	93.1
LDA	75	93.4	50	97.7
NN	100	86.8	40	100

Tablo 1-2' de başarı kriterleri incelendiğinde, saatlik buzağılama zamanı tahmininde %82.8 duyarlılık ve %68.6 PPV değerleriyle yapay sinir ağları, buzağılama günü tahmininde ise %100 duyarlılık ve %40 PPV değerleriyle doğrusal yapay sinir ağlarının başarılı tahminler yaptığı bildirilmiştir.

Ouellet ve ark. [23], çalışmalarında yatma süresi, yatma nöbetleri, geviş getirme verilerini 1 dakika ve 1 saat aralıklı şekilde kaydeden üç otomatik cihaz kullanmıştır. 42 Holstein ineğin 6-12-24 saat içinde buzağılama zamanını tahmin etmek için hayvanların davranışsal hareket verilerini kullanarak, lojistik regresyon modeli kullanmışlardır. Tablo 3'de 3 farklı saat dilimi için modelin performansı gösterilmiştir. PPV en iyi buzağılamadan önceki son 24 saatte elde edilmiştir.

**Tablo 3.** 24-12-6 saatlik test performansları [23]

<b>Buzağılamadan önceki saat</b>	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>	<b>PPV (%)</b>	<b>NPV (%)</b>
24	77	77	56	90
12	70	72	30	93
6	68	68	15	96

Negatif tahmin değerinin (NPV) yüksek çıkması, doğum olmayacağı zaman dilimindeki tahmin başarısı anlamına gelmektedir. Bu değer yüksek olmasının başlıca nedeni 0 olarak etiketlenen veri miktarını 1 olarak etiketlenen veri miktarının çok daha fazla olmasından kaynaklandığı düşünülmektedir. Araştırmacıların önerdikleri yöntemle, buzağılamadan 24 saati içinde gerçekleşeceğini tahmin etmede %68 duyarlılık ve %56 PPV başarı oranına ulaşmışlardır.

Yıldız [24], çalışmasında sığırlarda kızgınlığı yapay sinir ağlarıyla tahmin etmek için, 186 kızgınlık gösteren sığırın 78 tanesinin davranışsal verileri, sığırların yaşları, laktasyon sayıları, kızgınlıktan sonra geçen gün sayıları ve iklimsel verilerini kayıt altına almıştır. Oluşturulan YSA modeli sayesinde sığırların kızgınlık dönemi başarıyla tahmin etmiş olup başarı kriteri olarak ROC eğrisini kullanmıştır. Modelin, 0.97 ROC puanıyla kızgınlık dönemini tahmin etmede faydalı olacağı görüşündedir.

Rutten ve ark. [25], çalışmalarında Hollanda’da bir süt çiftliğinde 400 ineğin geviş getirme, yemleme, sıcaklık ve aktivitelerini kulağa takılan sensörlerle kayıt altına almışlardır. 1 yıllık veri toplama sürecinde 417 buzağılama meydana gelmiş olup buzağılama alanı 5 dakikalık aralıklarla görüntü olarak kayıt altına almışlardır. Elde edilen veriler lojistik regresyon yöntemine girdi değişkeni olarak kullanılmış olup 1-3-6-12 saatlik tahmin sonuçları Tablo 4’ de gösterilmektedir.

**Tablo 4.** Saatlik periyotlarda lojistik regresyon modelinin performansı [25]

Saat	Duyarlılık (%)	Özgüllük (%)	Doğru Pozitif Sayısı (TP)	Doğru Negatif Sayısı (TN)
1	21.2	99.1	7	148
3	42.84	99.2	14	135
6	48.5	99.3	16	124
12	51.5	99.4	17	110

Çalışmada geliştirilen model ile buzağılamanın 12 saat içerisinde olacağını %51.5 duyarlılık oranıyla tahmin edilmiştir. Ayrıca bu model ile 17 tane TP tahmin edilmiştir. TP sayısının az olması modelin 0’ ları tahmin etmede başarılı 1’ leri tahmin etmede ise daha az başarılı olduğunu göstermektedir. Başarı oranının düşük olması sınıflandırmak için 0 ve 1’ lerin dengesiz dağılımından kaynaklandığı düşünülmektedir.

Fadul ve ark. [26], çalışmalarında, Holstein-Friesian türünde ilk kez doğum yapacak (P) veya daha önce en az bir doğum yapmış (M) 33 inek üzerinde yaptıkları çalışmalarında, en az 10 gün öncesinde taktıkları ivmeölçer ve burun bandı sensöründen aktivite değerleri ve geviş getirme değerlerini elde etmişlerdir. 3 Saatlik şekilde toplanan bu verilerle, lojistik regresyon ve ROC analizi yöntemleriyle buzağılamadan önceki 3 saati tahmin etmeye çalışmışlardır. Tablo 5’ te modelin performansı gösterilmektedir.

**Tablo 5.** Modelin performansı [26]

	Duyarlılık (%)	Özgüllük (%)
P	85	74
M	88,9	93.3

Araştırmacılar önerdikleri modelde, ilk defa buzağılama yapacak inekler için %85 birden fazla buzağılama yapan inekler için %88.9 duyarlılık oranıyla başarılı bir tahmin yapmışlardır.

Zehner ve ark. [27], 3 çiftlikte 35 süt ineğine takılan burun bandı sayesinde geviş getirme davranışlarını izledikleri çalışmalarında, buzağılamadan 1 saat öncesini tahmin etmeye çalışmışlardır. 168 saatlik veri setini naïve bayes (NB) sınıflandırıcı ile eğitip test ederek modelin başarısını belirlemişlerdir. Tablo 6’ da modelin performansı gösterilmektedir.

**Tablo 6.** Modelin performansı [27]

	Duyarlılık (%)	Özgüllük (%)	PPV (%)
Ortalama	69	89	3

Buzağılamanın 1 saat içerisinde olacağını %69 duyarlılık başarı oranıyla tahmin etmişlerdir. PPV değerinin düşük olması ise “buzağılama başladı-başlıyor” diye etiketledikleri sınıfın başarısını

göstermektedir. Özgüllük başarı kriterinin yüksek olması buzağılamanın gerçekleşmediği zaman diliminde verinin çok olmasından ve o kısımları doğru sınıflandırmasından kaynaklanabilmektedir. Miller ve ark. [28], besi ve süt inekleri olmak üzere 254 ineğe sensör ve ivmeölçer yerleştirerek geviş getirme, yeme, kuyruk kaldırmalarını ve aktivite seviyelerini RF algoritmasını kullanarak ölçümlemişlerdir. Buzağılamanın doğrulaması kapalı devre televizyon kamera görüntüleri izlenerek yapılmıştır. Modelin başarısı Matthew's korelasyon katsayısı (MCC) ile ölçümlenmiştir. Buzağılamadan önceki 2 saati tahmin etmek için sadece kuyruk sensörlerinin varlığının yeterli olduğunu tespit etmişlerdir. Tablo 7' de modelin başarısı gösterilmektedir.

**Tablo 7.** Modelin performansı [28]

	Duyarlılık (%)	Özgüllük (%)	MCC
TAIL	78.6	83.5	0.29
TAIL+RUM+EAT+ACT	79.2	81.3	0.3

MCC katsayısına bakarak modelin, rastgele sınıflandırmadığı ama daha iyileşme potansiyeline sahip olduğunu söyleyebiliriz. Birden fazla sensörün kullanımı modelin başarısını yukarı yönlü etkilemektedir. %79.2 duyarlılık oranı ile başarılı bir tahmin yaptığı görülmektedir. Keceli ve ark. [29], Kentucky üniversitesi coldstream mandırasında 53 süt sığırından elde edilen davranışsal hareket verilerini kullanarak makine öğrenmesi yöntemleriyle buzağılama tahmini yapmışlardır. Gün tahmini için tekrarlayan sinir ağlarından çift uzun kısa süreli bellek (Bi-LSTM) ve saat tahmini için ise Rusboosted Tree (RT) sınıflandırıcısını kullanmışlardır.

**Tablo 8.** Buzağılamadan önceki son 8 saat tahmini [29]

Saat	Duyarlılık (%)	Özgüllük (%)	PPV (%)	NPV (%)
<8	66	95	89	82

**Tablo 9.** Buzağılama gününü tahmin [29]

Model	Duyarlılık (%)	Özgüllük (%)	PPV (%)	NPV (%)
LSTM	72	98	71	98
Bi-LSTM	82	99	83	99
K-NN	22	12	18	98
SVM	23	37	38	90
LDA	75	93	50	97
RF	25	89	16	93

Tablo 8' de buzağılamadan önceki son 8 saati tahmin etmek için RT sınıflandırıcısı kullanılmış olup %66 duyarlılık ve %89 PPV oranıyla başarılı bir sınıflandırma gerçekleştirildiği bildirilmiştir. Tablo 9' da ise buzağılama gününü tahmin etmede Bi-LSTM derin öğrenme modeli %82 duyarlılık ve %83 PPV başarılı sınıflandırma yapmışlardır.

Peng ve ark. [30], çalışmalarında, ineklerin davranışsal hareketleri yatma, geviş getirme, ayakta durma parametrelerinden yararlanarak buzağılama zamanını tahmin etmişlerdir. Buzağılamadan önceki son 72 saat içerisindeki davranışsal hareket verilerini giriş değişkeni olarak kullanmışlar ve

makine öğrenmesi modellerinden uzun kısa süreli bellek (LSTM) modeline sahip tekrarlayan sinir ağı (RNN) geliştirmişlerdir. LSTM-RNN modelinin başarı metrikleri Tablo 10' da gösterilmektedir.

**Tablo 10.** Modelin performansı [30]

	<b>Doğruluk (%)</b>	<b>Kesinlik (%)</b>	<b>Duyarlılık (%)</b>	<b>F1-Skor (%)</b>
Ortalama	79,7	81,1	79,7	79,8

Çalışmada önerilen model % 79.7 duyarlılık ve %79.7 doğruluk oranı ile başarılı bir sınıflandırma yapmıştır.

Higaki ve ark. [31], süt sığırlarının kuyruklarına taktıkları sıcaklık sensöründen elde ettikleri verileri kullanarak buzağılamadan önceki son 24 saati denetimli makine öğrenme yöntemlerinden destek vektör makineleri algoritmasını kullanarak tahmin etmeye çalışmışlardır. Ortam sıcaklıkları <15°C, >15°C ile <25°C ve >25°C olmak üzere iki farklı çiftlikten 75 ve 33 gebe sığır üzerinde testlerini gerçekleştirmişlerdir. Araştırmacılar, çalışma sonunda buzağılamanın 24 içinde gerçekleşeceğini %70 kesinlik ve %84.3 duyarlılık oranıyla başarılı bir tahmin etmişlerdir.

Liseune ve ark. [32], Süt ineklerinin belirli zaman aralıklarında buzağılama zaman tahmini için önerdikleri modelde, ineklerin boyunlarına ve ayaklarına takılan sensörler sayesinde hareket davranışları olan yatma, ayağa kalkma, yürüme, geviş getirme ve yürüme değerlerini ölçmüşler ve dakikalık bazda kayıt etmişlerdir. Buzağılamadan önceki son 24, 12, 6, 3 ve 1 saatleri tahmin ederken makine öğrenmesi yöntemlerinden lojistik regresyon (LR) ve rastgele orman (RF) derin öğrenme modellerinden ise Uzun-Kısa Süreli Bellek (LSTM), evrişimli sinir ağları (CNN) ve kendi geliştirdikleri CNN ve LSTM birlikte kullanmışlardır. Tablo 11'de görüldüğü üzere buzağılamanın 24 saat içerisinde gerçekleşeceğini tahmin etmişler ve CNN algoritması en iyi sonucu vermiştir.

**Tablo 11.** Tahmin performansı [32]

Saat	LR	RF	LSTM	CNN	C-LSTM
24	%32	%65	%72	%75	%73

Çalışma sonunda, önerilen CNN derin öğrenme modeliyle buzağılamanın 24 saat içinde gerçekleşeceği %75 doğrulukla tahmin edilmiştir.

Sumi ve ark. [33], Japonya'nın Oita eyaletindeki bir çiftlikte ağıllara koydukları kameralarla 25 süt sığırlarının davranışlarını kamera ile kayıt altına almışlardır. Sığırların davranışlarını analiz etmek için, yatma, kalkma, ayakta durma ve pozisyon sayılarının yanı sıra kuyruklarını kaldırma ve başlarını çevirme gibi davranışları da içeren video görüntülerini işleyerek elde etmişlerdir. Saklı markov modelinde (HMM) giriş parametreleri olarak bu değişkenleri kullanarak buzağılamadan önceki 3 günü bulmak için önerdikleri modelin başarı metrikleri Tablo 12' de gösterilmektedir.

**Tablo 12.** Performans analizi [33]

	<b>Duyarlılık (%)</b>	<b>Kesinlik (%)</b>
Ortalama	91.05	93.28



Önerilen model, %91.05 duyarlılık ve %93.28 kesinlik oranıyla başarılı bir tahmin yapmıştır. Araştırmacılar ruminasyon ve yatarak geçirilen süre gibi ek aktiviteler eklenerek doğruluğun daha artacağını düşündüklerini bildirmişlerdir.

Weleszczuk ve ark. [34], Polonya sığır yetiştiricileri ve çiftçileri federasyonu tarafından bilgileri tutulan Polonya'nın 16 farklı bölgesinden 2000 Holstein cinsi inek ve düve üzerinde yaptıkları çalışmalarında, buzağılama gününü tahmin etmek için doğrusal regresyon, karar ağacı, K-en yakın komşu, Rastgele orman, Gradyan artırma (GB) ve Sinir ağı gibi makine öğrenme yöntemleri kullanılmıştır. Modellerinde sütteki yağ, protein, vücut ve meme genetik değeri gibi 27 farklı giriş parametresi kullanarak tahmin yapılmıştır. Makine öğrenme modellerinden; doğrusal regresyon, karar ağacı, K-en yakın komşu, Rastgele orman, Gradyan artırma (GB) ve Sinir ağı gibi farklı modelleri uygulanmıştır. Araştırmacılar çalışmada, tahmin doğruluğunu ölçmek için ortalama mutlak hata (MAE) ve kök ortalama kare hatası (RMSE) başarı kriterlerini kullanmışlardır.

**Tablo 13.** Modellerin performanslarının karşılaştırılması [34]

Model	Kök Ortalama Kare Hatası (RMSE)
CE	1,87
RF	1,45
KNN	2,11
GB	1,27
XGB	1,3
sol	1,39
NN	1,47

Modeller içerisinde en düşük RMSE değerine sahip olan GB diğer modellere göre daha iyi tahmin performansı gösterdiği ifade edilmiştir.

### 3. Tartışma

Bu alandaki literatür incelendiğinde, son yıllarda makine öğrenme yöntemlerinin bu konuda oldukça başarılı sonuçlar verdiği Tablo 13' te gösterilmiştir. İlgili çalışmalar incelendiğinde LR, RF, LSTM, Bi-LSTM, CNN, DVM, RT, NB, K-NN, HMM gibi makine öğrenme modellerinin kullanıldığı tespit edilmiştir. Bu modellerin buzağılama zamanını doğru tahmin etmede gösterdiği performans Kesinlik, Duyarlılık, Özgüllük, Doğruluk, F1-skor, PPV ve NPV gibi değerlendirme kriterleri ile ölçülmüştür. Buzağılama tahmini yaparken başarılı sonuçlara ulaşılan çalışmalarda, hayvanların özellikle davranışsal verileri olan adım sayısı, yatma süresi, ayakta geçirdiği süre, yatma sıklığı, geniş getirme sayısı ve vücut sıcaklıklarından yararlandığı görülmüştür.

**Tablo 13.** Literatürdeki çalışmaların Performansları

Saat	Yazar	Model	Duyarlılık	Özgüllük	PPV	NPV	Kesinlik
<3	Liseune ve ark. (2021)	Cnn-lstm	%57	%85	%85		%49

<72	Sumi ve ark. (2021)	HMM	%91.05				% 93.28
<8	Keceli ve ark. (2020)	Rusboosted Tree	%66	%95	%89	%82	
<24	Higaki ve ark. (2020)	Destek Vek.Mak.	%70				
<1	Zehner ve ark. (2019)	Navie Bayes	%69	%89	%3		
<2	Miller ve ark. (2019)	Rastgele Orman	%79.2	%81.3			
<8	Borchers ve ark. ( 2017)	Sinir Ağları	%82	%80	%69	%90	
<3	Fadul ve ark. (2017)	Lojistik Regresyon	%88.9	%93.3			
<8	Borchers ve ark. ( 2017)	Doğrusal diskriminant analizi	%76	%75	%61	%85	
<8	Borchers ve ark. ( 2017)	Rastgele Orman	%72	%82	%68	%85	
<3	Rutten ve ark. (2017)	Lojistik Regresyon	%42	%99			
<24	Ouellet ve ark. (2016)	Lojistik Regresyon	%71	%71	%16	%97	

Çalışmaları incelediğimizde makine öğrenmesi yöntemleri, yüksek doğruluk oranları ile öne çıkmaktadır [29]. Makine öğrenmesi, insan hatası riskini azaltarak performansı optimize eder ve daha tutarlı sonuçlar elde edilir. Bunun yanı sıra, makine öğrenimi modelleri otomatikleştirilebilir. Yani, bir kez eğitildikten sonra, sürecin tamamı insan müdahalesi olmadan tamamlanabilir. Ayrıca, makine öğrenimi modelleri büyük veri setleri üzerinde işlem yapabilirken, geleneksel yöntemler bu kadar büyük veri setlerinin işlenmesi için yeterince hızlı ve verimli değildir. Geleneksel yöntemlerde, ölçümler insanlar tarafından yapılır ve bu da birçok risk faktörüne neden olabilir. Makine öğrenmesi yöntemleri ise, verilerin otomatik olarak işlenmesi sayesinde bu risk faktörlerini ortadan kaldırır. Sonuç olarak, makine öğrenmesi yöntemleri geleneksel yöntemlere göre daha avantajlıdır. Büyük veri setleri ve hesaplama kaynaklarına ihtiyaç duyulsa da, maliyet tasarrufu, yüksek doğruluk, özelleştirilebilme ve otomatikleştirme gibi birçok avantaj sunarlar [35].

#### 4.Sonuç

Makine öğrenme yöntemlerinin sığırların buzağılama zamanlarını tahmin etme konusunda kullanılmasıyla ilgili yapılan araştırmalar, olumlu sonuçlar göstermektedir. Bu çalışmalar, sığırların doğum zamanlarını tahmin etmek için çeşitli makine öğrenme tekniklerinin kullanılabileceğini ve yüksek doğruluk elde edilebileceğini göstermektedir. Ancak, doğru sonuçlar elde etmek için bazı faktörlere dikkat edilmelidir. Bunlar arasında veri setinin kalitesi önemlidir. Yeterli, doğru ve temsilci verilerin kullanılması, tahmin modelinin doğruluğunu etkileyen kritik bir faktördür. Veri setinde

doğru bir şekilde toplanan ve önceden işlenmiş verilerin kullanılması, modelin daha güvenilir tahminler yapmasına yardımcı olabilir.

Yapılan araştırmalar, daha büyük veri kümeleri kullanarak daha genel sonuçlar elde edilmesini beklemektedir. Büyük veri setleri, daha geniş bir örneklem üzerinde çalışarak ve daha genellemeler yaparak modelin performansını artırabilir. Bu nedenle, gelecekteki çalışmalarda daha büyük veri setleri kullanılması ve buzağılama zamanlarını tahmin etmek için daha genel sonuçlar üretmesi beklenmektedir.

Makine öğrenme yöntemlerinin sığırların buzağılama zamanlarını tahmin etmek için kullanılması, tarım sektöründe verimliliği artırabilir ve sığırcılık işletmelerinin yönetimini geliştirebilir. Ancak, bu alanın daha fazla araştırma ve geliştirme gerektirdiği unutulmamalıdır.

## 5. Kaynaklar

- [1] Hamşa H (2002). Ceylanpınar Tarım İşletmesinde yetiştirilen siyah alaca sığırlarda yetiştirme ve süt verim özellikleri, VAN: Yüzüncü Yıl Üniversitesi.
- [2] Calcante A, Tangorra F ve Marches G (2014). A GPS/GSM based birth alarm system for grazing cows, *Computers and electronics in agriculture*, pp. 123-130.
- [3] Cangar Ö, Leroy T, Guarino M, Vranken E, Fallon R, Lenahan J, Berckmans D ve Mee J (2008) Automatic real-time monitoring of locomotion and posture behaviour of pregnant cows prior to calving using online image analysis, *Computers and Electronics in Agriculture*, pp. 53-60.
- [4] Wright I, White I, Russel A, Whyte T ve Bean Mc (1988). Prediction of calving date in beef cows by real-time ultrasonic scanning., *The Veterinary Record*, pp. 228-229.
- [5] Matsas D, Nebel R ve Pelzer K (1992). Evaluation of an on-farm blood progesterone test for predicting the day of parturition in cattle, *Theriogenology*, cilt 37, no. 4, pp. 859-868.
- [6] Andresen S (2002). John McCarthy: father of AI, *IEEE Intelligent Systems*, cilt 17, no. 5, pp. 84-85.
- [7] Sönmez O ve Zengin K (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma, *Avrupa Bilim ve Teknoloji*, pp. 302-308.
- [8] Vasseur A, Borderas F, Cue R, Lefebvre D, Rushen J, Wade K ve Passillé A (2010). A survey of dairy calf management practices in Canada that affect animal welfare, *Journal of Dairy Science*, pp. 1307-1316.
- [9] Karşlı M ve Evcı Ş (2018). Buzağı Kayıplarının Önlenmesinde İnek ve Buzağı Beslemesinin Önemi, *Lalahan Hayvancılık Araştırma Enstitüsü*, cilt 58, no. Özel, pp. 23-34.
- [10] Akbaş, O., Yılmaz, S., & Başalan, M. (2017). Buzağı Kayıpları Sempozyumu. Kırıkkale: Kırıkkale Üniv.
- [11] Mee J (2004). Managing the dairy cow at calving time, *Veterinary Clinics: Food Animal Practice*, cilt 20, no. 3, pp. 521-546.
- [12] El Naqa I ve Murphy M (2020). What Is Machine Learning? , Springer International Publishing., 2015.
- [13] Mahesh B (2020). Machine Learning Algorithms- A Review, *International Journal of Science and Research* , pp. 381-386.
- [14] Alpaydin, E. (2021). Machine learning. Mit Press.
- [15] Zhou, L., Pan, S., Wang, J., & Vasilakos, A. V. (2017). Machine learning on big data: Opportunities and challenges. *Neurocomputing*, 237, 350-361.

- [16] Berglund B, Philipsson J ve Danell ö (1987). External signs of preparation for calving and course of parturition in Swedish dairy cattle breeds, *Animal Reproduction Science*, cilt 15, no. 1-2, pp. 61-79.
- [17] Kornmatitsuk B, Önigsson K, Kindahl H, Gustafsson H, Forsberg M ve Madej A (2000). Clinical Signs and Hormonal Changes in Dairy Heifers after Induction of Parturition with Prostaglandin F<sub>2α</sub>, *Journal of Veterinary Medicine Series A*, cilt 47, no. 7, pp. 395-409.
- [18] Streyll D, Sauter-Louis C, Braunert A, Lange D, Weber F ve Zerbe H (2011). Establishment of a standard operating procedure for predicting the time of calving in cattle, *Journal of Veterinary Science*, cilt 12, no. 2, pp. 177-185.
- [19] Burfeind O, Suthar V, Voigtsberger R, Bonk S ve Heuwieser W (2011). Validity of prepartum changes in vaginal and rectal temperature to predict calving in dairy cows, *Journal of Dairy Science*, pp. 5053-5061.
- [20] Palombi C, Paolucci M, Stradaoli G, Corubolo M, Pascolo P ve Monaci M (2013). Evaluation of remote monitoring of parturition in dairy cattle as a new tool for calving management, *BMC Veterinary Research*, pp. 1-9.
- [21] Clark C, Lyons N, Millapan L, Talukder S, Cronin G, Kerrisk K ve Garcia S (2015). Rumination and activity levels as predictors of calving for, *Animal*, pp. 691-695.
- [22] Borchers M, Chang Y, Proudfoot K, Wadsworth B, Stone A ve Bewley J (2016). Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle, *Journal of dairy science*, no. 100, pp. 1-11.
- [23] Ouellet V, Vasseur E, Heuwieser W, Burfeind O, Maldague X ve Charbonneau É (2016). Evaluation of calving indicators measured by automated monitoring devices to predict the onset of calving in Holstein dairy cows, *Journal of Dairy Science*, cilt 99, no. 2, pp. 1539-1548.
- [24] Yıldız A (2016). Büyükbaş Hayvanlarda Kızgınlığın (Östrus) , Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Tokat.
- [25] Rutten C, Kamphuis C, Hogeveen H, Huijps K, Nielen M ve Steeneveld W (2017). Sensor data on cow activity, rumination, and ear temperature improve prediction of the start of calving in dairy cows, *Computers and Electronics in Agriculture*, no. 132, pp. 108-118.
- [26] Fadul M, Bogdahn C, Alsaad M, Hüsler J, Starke A, Steiner A ve Hirsbrunner G (2017). Prediction of calving time in dairy cattle, *Animal Reproduction Science*, no. 187, pp. 37-46.
- [27] Zehner N, Niederhauser J, Schick M ve Umstatter C (2019). Development and validation of a predictive model for calving time based on sensor measurements of ingestive behavior in dairy cows, *Computers and Electronics in Agriculture*, no. 161, pp. 62-71.
- [28] Miller G, Mitchell M, Barker Z, Giebel K, Codling E, Amory J, Michie C, Davison C, Tachtatzis C, Andonovic I ve Duthie C (2019). Using animal-mounted sensor technology and machine learning to predict time-to-calving in beef and dairy cows, *Animal*, pp. 1-9.
- [29] Keceli A, Catal C, Kaya A ve Tekinerdoğan B (2020). Development of a recurrent neural networks-based calving prediction model using activity and behavioral data, *Computers and Electronics in Agriculture*, no. 170, pp. 1-9.
- [30] Peng Y, Kondo N, Fujiura T, Suzuki T, Ouma S, Wulandari, Yoshioka H ve Itoyama E (2020). Dam behavior patterns in Japanese black beef cattle prior to calving:, *Computers and Electronics in Agriculture*, cilt 169, pp. 1-7.
- [31] Higaki S, Koyama K, Sasaki Y, Abe K, Honkawa K, Minamino Y, Mikurino Y, Okada H, Miwakeichi F, Darhan H ve Yoshioka K (2020). Technical note: Calving prediction in dairy

- cattle based on continuous measurements of ventral tail base skin temperature using supervised machine learning, *Journal of dairy science*, no. 103, pp. 8535-8540.
- [32] Liseune A, Poel V, Hut P, Eerdenburg F ve Hostens M (2021). Leveraging sequential information from multivariate behavioral sensor data to predict the moment of calving in dairy cattle using deep learning, *Computers and Electronics in Agriculture*, no. 191.
- [33] Sumi K, Maw S, Zin T, Tin P, Kobayashi I ve Horii Y (2021). Activity-Integrated Hidden Markov Model to Predict Calving Time, *Animals*, cilt 11.
- [34] Weleszczuk J, Kosinska-Selbi B ve Cholewińska P (2022). Prediction of Polish Holstein's economical index and calving interval using, *Livestock Science*.
- [35] Khanzode, K. C. A., & Sarode, R. D. (2020). Advantages and disadvantages of artificial intelligence and machine learning: A literature review. *International Journal of Library & Information Science (IJLIS)*, 9(1), 3.