



T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**YİNELEMELİ SİNİR AĞLARINDA ÇOK DEĞİŞKENLİ ZAMAN
SERİSİ ANALİZİ YÖNTEMLERİ İLE SÜT SIĞIRCILIĞI
ÜREME SÜREÇ YÖNETİMİ**

DOKTORA TEZİ
OĞUZHAN SÖNMEZ

Danışman: Dr. Öğr. Üyesi Kenan ZENGİN

TOKAT-2023

ETİK SÖZLEŞME SAYFASI

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Kenan ZENGİN danışmanlığında hazırlamış olduğum “Yinelemeli Sinir Ağlarında Çok Değişkenli Zaman Serisi Analizi Yöntemleri İle Süt Sığırcılığı Üreme Süreç Yönetimi” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

05.07.2023

Oğuzhan SÖNMEZ

JÜRİ KABUL VE ONAY

Oğuzhan SÖNMEZ tarafından hazırlanan “Yinelemeli Sinir Ağlarında Çok Değişkenli Zaman Serisi Analizi Yöntemleri İle Süt Sığırcılığı Üreme Süreç Yönetimi” adlı tez çalışmasının savunma sınavı 05/07/2023 tarihinde yapılmış olup aşağıda verilen Jüri tarafından oy birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü MEKATRONİK MÜHENDİSLİĞİ ANABİLİM dalında DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri	(Ünvanı, Adı Soyadı)	İmza

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

ÖNSÖZ/TEŞEKKÜR

Danışmanım Dr. Öğr. Üyesi Kenan ZENGİN' e beni bu süreçte yönlendirdiği ve destek verdiği için minnettarım. Benimle birlikte çalıştığı için teşekkür ediyorum.

Tez İzleme komitesinde bana yol gösterdikleri için Dr. Öğr. Üyesi Bülent TURAN ve Dr. Öğr. Üyesi Emre ÇAM' a teşekkürlerimi sunuyorum.

Fikirleri ve önerileriyle tezime değer kattığı için İlker GÜNAY' a teşekkür ederim.

Benim için her zaman yanımda olduklarını hissettiğim aileme çok teşekkür ederim.

Canım kızlarım Aslı ve İnci, sizler benim motivasyon kaynağımsınız. Sizlerin hayatına dokunmak ve sizleri gururlandırmak ve benim için harika bir duygu.

Sevgili eşim, sen her zaman yanımda oldun ve destek verdin. Zaman zaman benimle birlikte çalışarak, zaman zaman da evde işleri tek başına hallederek bana zaman ayırdın. Senin sayende tezimi tamamlayabildim. Sağladığın paha biçilmez katkılar için çok teşekkür ederim.

ÖZET

DOKTORA TEZİ

YİNELEMELİ SİNİR AĞLARINDA ÇOK DEĞİŞKENLİ ZAMAN SERİSİ ANALİZİ YÖNTEMLERİ İLE SÜT SIĞIRCILIĞI ÜREME SÜREÇ YÖNETİMİ

Oğuzhan SÖNMEZ

Mekatronik Mühendisliği Ana Bilim Dalı

Tez Danışmanı: Kenan ZENGİN

Haziran 2023, xii + 69 Sayfa

Yüksek ekonomik değere sahip süt sığırlarının buzağılama esnasında olumsuz senaryolar yaşanabilmektedir. Buzağuların sıkışması, yaralanma, buzağılama sonrasında yetersiz beslenmeden dolayı kayıplar ve gözetimsiz buzağılama gibi birçok olumsuz senaryo gerçekleşebilmektedir. Bu olumsuzlukları azaltmak ve hayvan refahını artırmak için buzağılama zamanını doğru tahmin etmek büyük öneme sahiptir. Bu çalışmada, Kalman filtreli bir Bi-LSTM sınıflandırıcı kullanarak buzağılama zamanı tahmini için yeni bir yöntem öneriyoruz. Bi-LSTM sınıflandırıcı, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenebilen bir derin öğrenme modelidir. Kalman filtresi, gürültülü verileri yumuşatmak ve bir sistemin zaman içindeki durumunu tahmin etmek için kullanılabilen istatistiksel bir filtredir. Yapılan deneyler sonucunda, önerilen modelin, geliştirilen diğer alternatif modellere ve literatürdeki diğer tahmin yöntemlerine göre daha iyi performans gösterdiği tespit edilmiştir. Özellikle, kalman filtresi sayesinde modellerde ortalama %20 daha iyi performans sağlanırken, modelin %93 hassasiyet ve % 95 doğruluk değeri ile yüksek bir başarı elde ettiği görülmüştür. Ayrıca, çapraz doğrulama yöntemi ile veri seti büyüklüğü etkisi azaltılarak ve aşırı uyum önlenerek, modelin daha doğru sonuçlar vermesi sağlanmıştır. Yöntemimiz süt çiftçileri için değerli bir araç olabilir. Çiftçilerin sürü yönetimi hakkında daha bilinçli kararlar almasına yardımcı olabilir, bu da hayvan refahının ve süt üretiminin artmasına yol açabilir. Bu tez çalışması, yapay zeka yöntemlerinin hayvan yetiştiriciliği alanında da önemli bir uygulama potansiyeli olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Buzağılama Tahmini, Bi-LSTM, Derin Öğrenme, Kalman Filtresi.

ABSTRACT

DOCTORATE THESIS

MULTIVARIATE TIME SERIES ANALYSIS WITH RECURRENT NEURAL NETWORKS FOR DAIRY CATTLE BREEDING MANAGEMENT

Oğuzhan SÖNMEZ

Department of Mechatronics Engineering

Advisor: Assist. Prof. Dr. Kenan ZENGİN

June 2023, xii + 69 pages

Negative scenarios can occur during calving of dairy cattle with high economic value. Many negative scenarios such as calf entrapment, injury, losses due to malnutrition after calving and unattended calving can occur. In order to reduce these adverse scenarios and improve animal welfare, accurate prediction of calving time is of great importance. In this study, we propose a new method for calving time estimation using a Bi-LSTM classifier with Kalman filter. The Bi-LSTM classifier is a deep learning model that can learn long-term dependencies in time series data. The Kalman filter is a statistical filter that can be used to smooth noisy data and estimate the state of a system over time. As a result of the experiments, it is found that the proposed model outperforms other alternative models and other forecasting methods in the literature. In particular, the Kalman filter provides an average of 20% better performance in the models, while the model achieves a high success with 93% precision and 95% accuracy. In addition, the cross-validation method reduced the effect of data set size and prevented overfitting, resulting in more accurate model results. Our method can be a valuable tool for dairy farmers. It can help farmers make more informed decisions about herd management, which can lead to increased animal welfare and milk production. This thesis demonstrates that artificial intelligence methods have a significant potential for application in the field of animal farming.

Keywords: Calving Prediction, Bi-LSTM, Deep Learning, Kalman Filter.

İÇİNDEKİLER

ETİK SÖZLEŞME SAYFASI	i
JÜRİ KABUL VE ONAY	ii
ÖNSÖZ/TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ÇİZELGELER LİSTESİ.....	viii
ŞEKİLLER LİSTESİ	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETLERİ/KURAMSAL TEMELLER/GENEL BİLGİLER	4
2.1. Literatür Taraması	4
2.2. Kuramsal Temeller ve Genel Bilgiler	9
2.2.1. Zaman Serileri.....	9
2.2.2. Derin Öğrenme (DL)	10
3. MATERYAL YÖNTEM.....	13
3.1. Çalışmada Kullanılan Bilgisayar Özellikleri	13
3.2. Çalışma Ortamı MATLAB	13
3.3. Veri Hazırlama	14
3.3.1. Veri Toplama Süreci	14
3.3.2. Veri Setinin Özellikleri	15
3.3.3. Veri Setinin Temizlenmesi	17
3.3.4. Veri Dönüştürme.....	18
3.3.5. Veri Normalizasyonu	18
3.3.6. Veri Setinin Bölünmesi ve Eğitim-Test Kümelerinin Oluşturulması	19
3.4. Çalışmada Kullanılan Yöntemler	21
3.4.1. Kalman Filtresi	21
3.4.2. Tekrarlayan Sinir Ağları (RNN)	23
3.4.3. Tam Bağlantılı Katmanı (Fully Connected Layer)	28
3.4.4. ReLu Aktivasyon Fonksiyonu	28
3.4.5. Sınıflandırma (Softmax) Katmanı	29

3.5. Önerilen Model	30
4. BULGULAR ve TARTIŞMA	37
4.1. Kalman + Bi-LSTM Model Sonuçları	44
4.2. KALMAN + GRU Model Sonuçları.....	45
4.3. KALMAN + LSTM Model Sonuçları.....	47
4.4. Tek Katmanlı RNN Tabanlı Derin Yapı Model Sonuçları	48
4.5. Bi-LSTM Model Sonuçları	50
4.6. LSTM+GRU Model Sonuçları.....	51
4.7. LSTM Model Sonuçları	53
4.8. Bi-LSTM + GRU Model Sonuçları.....	54
4.9. GRU Model Sonuçları.....	56
5. SONUÇ VE ÖNERİLER.....	62
6. KAYNAKLAR	64
7. ÖZGEÇMİŞ	69

ÇİZELGELER LİSTESİ

Çizelge 3.1. Çalışmada Kullanılan Bilgisayarın Teknik Özellikleri	13
Çizelge 3.2. Verilere Z-skor normalizasyonu uygulanmış hali	18
Çizelge 3.3. Buzağılamadan önceki son 24 Saatlik Verilere Z-score Normalize uygulanmış.....	33
Çizelge 3.4. Buzağılamadan önceki son 24 Saatlik Verilerin Normalizasyon Uygulanmamış Hali	33
Çizelge 4.1. Önerilen modelin detaylı başarı metrikleri	37
Çizelge 4.2. Önerilen Modelin Karışıklık Matrisi	39
Çizelge 4.3. Diğer Modellerin Önerilen Modele Göre Başarı Durumu.....	41
Çizelge 4.4. Modellerin Performans Karşılaştırması.....	42
Çizelge 4.5. Modellerin Detaylı Performansları	43
Çizelge 4.6. Kalman + Bi-LSTM Modelinin Karışıklık Matrisi	44
Çizelge 4.7. Kalman + Bi-LSTM Modelinin Başarı Değerlendirilmesi.....	44
Çizelge 4.8. Kalman + GRU Modelinin Karışıklık Matrisi.....	46
Çizelge 4.9. Kalman + GRU Modelinin Başarı Değerlendirilmesi	46
Çizelge 4.10. Kalman + LSTM Modelinin Karışıklık Matrisi	47
Çizelge 4.11. Kalman + LSTM Modelinin Başarı Değerlendirilmesi	47
Çizelge 4.12. Tek Katmanlı RNN Modelinin Karışıklık Matrisi	49
Çizelge 4.13. Tek Katmanlı RNN Tabanlı Modelin Başarı Değerlendirilmesi.....	49
Çizelge 4.14. Bi-LSTM Modelinin Karışıklık Matrisi	50
Çizelge 4.15. Bi-LSTM Modelinin Başarı Değerlendirilmesi.....	50
Çizelge 4.16. LSTM + GRU Modelinin Karışıklık Matrisi.....	52
Çizelge 4.17. LSTM + GRU Modelinin Başarı Değerlendirilmesi	52
Çizelge 4.18. LSTM Modelinin Karışıklık Matrisi	53
Çizelge 4.19. LSTM Modelinin Başarı Değerlendirilmesi	53
Çizelge 4.20. Bi-LSTM + GRU Modelinin Karışıklık Matrisi.....	55
Çizelge 4.21. Bi-LSTM+GRU Modelinin Başarı Değerlendirilmesi	55
Çizelge 4.22. GRU Modelinin Karışıklık Matrisi.....	56
Çizelge 4.23. GRU Modelinin Başarı Değerlendirilmesi	56
Çizelge 4.24. Literatürdeki Çalışmaların Karşılaştırılması	59

ŞEKİLLER LİSTESİ

Şekil 2.1 Yapay zekâ, makine öğrenmesi ve derin öğrenmenin konumu.....	12
Şekil 3.1. Süt Sığırının Buzağılamadan önceki 3 gün içindeki Toplam Hareketleri.....	15
Şekil 3.2. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Ayakta Kalma Süresi	16
Şekil 3.3. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Yatma Süresi.....	16
Şekil 3.4. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Adım Sayısı.....	17
Şekil 3.5. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Yatma Sıklığı	17
Şekil 3.6. K-kat çapraz doğrulama.....	19
Şekil 3.7. Karışıklık Matrisi (Confusion Matrix)	20
Şekil 3.8. Kalman Filtresinin Çalışma Modeli	23
Şekil 3.9. Tekrarlayan Sinir Ağları (RNN) Mimari Yapısı	24
Şekil 3.10 Uzun Kısa Süreli Bellek (LSTM) Ağı Mimari Yapısı	25
Şekil 3.11. Çift Yönlü Uzun- Kısa Süreli Bellek (Bi-LSTM) Ağı Mimari Yapısı.....	26
Şekil 3.12. Kapılı Tekrarlayan Birim (GRU) Ağı Mimari Yapısı	27
Şekil 3.13. Tam Bağlantılı Katman Yapısı	28
Şekil 3.14. ReLu Fonksiyonu	29
Şekil 3.15. Sınıflandırma Katmanı	29
Şekil 3.16. Softmax Fonksiyonu.....	30
Şekil 3.17. Saatlik Tahmin İçin Akış Şeması	31
Şekil 3.18. Kalman Katsayısı 0.01	32
Şekil 3.19. Kalman Katsayısı 0.001	32
Şekil 3.20. Önerilen Model Mimarileri	34
Şekil 3.21. Modelin GRU katmanı çıkarılmış hali	35
Şekil 3.22. Tek Katmanlı RNN Tabanlı Model	35
Şekil 3.23. GRU Kullanılarak Oluşturulan Model	36
Şekil 3.24. Üç RNN Yapısı Oluşturulmuş Model	36
Şekil 4.1. Buzağılama Tahmin Grafiği	38
Şekil 4.2. Önerilen Modelin Ortalama Başarı-Hata Grafiği	38
Şekil 4.3. Önerilen Modelin ROC Eğrisi	40
Şekil 4.4. Kalman+ Bi-LSTM Modelinin ROC Eğrisi	45

Şekil 4.5. Kalman + GRU Modelinin ROC Eğrisi	46
Şekil 4.6. Kalman + LSTM Modelinin ROC eğrisi	48
Şekil 4.7. Tek Katmanlı RNN Tabanlı Modelin ROC Eğrisi	49
Şekil 4.8. Bi-LSTM Modelinin ROC eğrisi.....	51
Şekil 4.9. LSTM + GRU Modelinin ROC eğrisi	52
Şekil 4.10. LSTM Modelinin ROC eğrisi.....	54
Şekil 4.11. Bi-LSTM + GRU Modelinin ROC eğrisi.....	55
Şekil 4.12. GRU Modelinin ROC eğrisi	57
Şekil 4.13. Modellerin Hassaslık Performansları	57
Şekil 4.14. Modellerin Duyarlılık Performansları	58
Şekil 4.15. Modellerin Doğruluk Performansları	58
Şekil 4.16. Modellerin F ₁ -Skor Performansları	59

SİMGELER VE KISALTMALAR

AG: Hızlandırılmış Gradyan
AR: Otoregresif
ARMA: Otoregresif Hareketli Ortalama
ARIMA: Bütünleşik Otoregresif Hareketli Ortalama
AUC: ROC Eğrisi Altında Kalan Alan
Bi-LSTM: Çift Yönlü Uzun-Kısa Süreli Bellek Sinir Ağı
CPU: Merkezi İşlem Birimi
CNN: Evrişimli Sinir Ağı
DT: Karar Ağacı
FP: Yanlış Pozitif (False Positive)
FN: Yanlış Negatif (False Negative)
GAN: Çekişmeli Üretken Ağlar
GB: Gradyan Artırma
GPU: Grafik İşleme Birimi
GRU: Kapılı Tekrarlayan Birim
kNN: K En Yakın Komşu
LDA: Doğrusal Diskriminant Analizi
LSTM: Uzun-Kısa Süreli Bellek Sinir Ağı
MA: Hareketli Ortalama
MAE: Ortalama Mutlak Hata
MATLAB: Matris Laboratuvarı
MCC: Matthew's korelasyon katsayısı
MLP: Çok Katmanlı Algılayıcı
MSE: Karesel Hata Ortalaması
NB: Naïve bayes
NPV: Negatif Tahmin Değeri
PPV: Pozitif Tahmin Değeri
ReLu: Düzleştirilmiş Doğrusal Birim Katmanı
RF: Rastgele Orman
RMSE: Ortalama Hata Kare Kökü
RNN: Tekrarlayan Sinir Ağı

ROC: İşlem Karakteristik Eğrisi

RT: Rusboosted

SVM: Destek Vektör Makinesi

TP: Doğru Pozitif (True Positive)

TN: Doğru Negatif (True Negative)

YSA: Yapay Sinir Ağları



1. GİRİŞ

Süt, dünya genelinde temel bir gıda maddesi olarak kabul edilmekte ve son yıllarda küresel olarak tüketimi artmaktadır. Bu artışta nüfus artışı, şehirleşme, sütün sağlık faydaları hakkındaki bilinçlenmenin artması ve süt bazlı yeni ürünlerin geliştirilmesi gibi etkenler rol oynamaktadır. Süt tüketiminin artması, süt ineklerinin bakımı ve doğum süreçlerinin önemini arttırmaktadır. Sürdürülebilir bir süt verimi elde etmek için, üreme süreçleri doğru bir şekilde yönetilmelidir.

Süt sığırcılığı, hayvan refahının ve verimliliğin artmasına rağmen, buzağılama öncesi veya buzağılama sırasındaki (perinatal dönem) ölüm oranlarının birçok işletme için kabul edilemez seviyelerde olduğu görülmektedir (Mee, 2008). Araştırmalar, buzağı kayıplarının İtalya'da %25 (De Amicis ve ark., 2018), ABD'de %6,4, İngiltere'de ise %2,47 ile %7,42 arasında değiştiğini göstermiştir (Gates, 2013). Türkiye'de ise bu oranın %10 - %15 aralığında olduğu tespit edilmiştir. Kaybedilen buzağının % 90' ı başlangıçta sağlıklı bir şekilde doğmuştur ve bu kayıpların yüksek bir kısmının önlenabilir olduğu düşünülmektedir (Mee, 2004). Buzağının canlı doğumu ve sorunsuz bir şekilde büyümesi, süt ineklerinde başarılı bir buzağılama dönemi olarak kabul edilir.

Buzağılama, süt ineklerinin hayatında kritik bir dönüm noktasıdır ve inek için oldukça stresli bir süreçtir. Bu nedenle, bu sürecin sorunsuz geçmesi için gerekli önlemlerin alınması büyük önem taşır. Buzağılamayı iyileştirmenin yolu ise, ineğin ne zaman doğum yapacağını önceden tahmin etmektir. Böylece çiftçiler, ineğin rahat edebileceği bir ortam hazırlayabilir, ayrıca bir veteriner hekimin de hazır bulunmasını sağlayarak doğum sürecine en iyi şekilde hazırlanabilirler.

Buzağılama zamanını tahmin etmek için birçok yöntem kullanılabilir. Bunlardan biri, ineğin davranışlarını izlemektir. Örneğin, doğuma yakın olan inekler genellikle daha fazla yatarak ve daha az ayakta durarak vakit geçirirler (Titler ve ark., 2015). Ayrıca huzursuz

ve tedirgin olabilirler. İneklerin bu davranışları göstermesi, doğumun yaklaştığını gösteren işaretlerden biridir.

Bir diğer yöntem ise, ineğin vücut durumunu izlemektir. Buzağılamak üzere olan inekler genellikle kilo kaybeder ve memeleri şişebilir (Berglund ve ark., 1987). Bunun yanı sıra, doğum öncesi kasık bölgesinde şişlik de görülebilir (Saint-Dizier & Chastant-Maillard, 2015). Tüm bu işaretler, doğumun yakın olduğuna dair önemli ipuçları sağlar. Bunların yanı sıra bazı cihazlar da kullanılarak buzağılama zamanı tahmini yapılabilir.

Bu çalışmada, kalman filtresi ve çift yönlü uzun-kısa süreli bellek (Bi-LSTM) sınıflandırıcı kullanarak buzağılama zamanını tahmin etmek için yeni bir yöntem öneriyoruz. Kalman filtresi, durum tahminini güncellemek için en son bilgileri kullanan özyinelemeli bir filtredir. Filtre, en son ölçümlere ve önceki durum tahminine dayanarak durum tahminini güncellemek için bir dizi denklem kullanır. Kalman filtresi, adım sayısı, yatma süresi, ayakta geçirilen süre ve yatma sıklığı gibi verilerden ineğin durumunu tahmin etmek için kullanılabilir. Örneğin, bir inek normalden daha fazla adım atıyorsa ve uzanıyorsa, bu davranışların altında pek çok olası neden yatabilir (Titler ve ark., 2015). Bu davranışlar, hayvanın huzursuzlanması, stres yaşaması veya yaklaşan doğum gibi fizyolojik değişimlerin belirtileri olabilir. Benzer şekilde, bir inek her zamankinden daha fazla ayakta duruyorsa, bu da rahatlamaya çalışması veya doğum sancısı gibi faktörlerden kaynaklanabilir.

Kalman filtresi, adım sayısı, yatma süresi, ayakta geçirilen süre ve yatma sıklığı gibi verilerden ineğin durumunu yüksek doğrulukla tahmin etmek için kullanılabilir. Bunun nedeni, Kalman filtresinin durum tahminini güncellemek için en son bilgileri kullanabilmesidir. Kalman filtresi ayrıca ölçümlerdeki belirsizliği de hesaba katabilir ve bu da tahminlerin doğruluğunu artırmaya yardımcı olur.

Bi-LSTM sınıflandırıcı, uzun vadeli bağımlılıkları öğrenebilen bir derin öğrenme modelidir. Buzağılama birkaç gün sürebilen bir süreç olduğundan, bu Bi-LSTM sınıflandırıcıyı buzağılama zamanını tahmin etmek için çok uygun hale getirir. Bi-LSTM

sınıflandırıcı, ineğin davranışı, vücut durumu ve buzağılama zamanı hakkında bilgiler içeren geçmiş verilerden oluşan bir veri kümesi üzerinde eğitilmiştir.

Önerilen yöntem 28 inekten oluşan bir veri kümesi üzerinde değerlendirilmiştir. Sonuçlar, önerilen yöntemin buzağılama zamanını %93 doğrulukla tahmin edebildiğini göstermiştir.

Bu tez çalışmasının amacı;

1. Süt sığırcılığında buzağılama zamanını tahmin edilmesinde kalman filtresi ve tekrarlayan sinir ağlarını birlikte kullanarak, birden fazla yöntemin kombinasyonu ile daha yüksek doğruluk oranı elde etmek.
2. Süt sığırlarında buzağılama zamanını tahmini gibi birçok tarımsal verilere dayalı problemlerde derin öğrenme yöntemlerinin etkili bir şekilde sonuç verebileceğini göstermek.
3. Uygulanan kalman filtresi ve tekrarlayan sinir ağlarından elde edilen sonuçların performans karşılaştırmasını yaparak önerilen yöntemin etkinliğini ortaya koymak.
4. Ayrıca sektöre hayvan refahının korunması, verimli işletme yönetimi, karar verme süreçlerinin iyileştirilmesi, sağlıklı büyüme ve inovasyon gibi alanlarda literatüre önemli katkılar sağlamaktır.

Buzağılama zamanının doğru tahmini sayesinde çiftçiler, ineğin ne zaman buzağılayacağı konusunda önceden uyarılarak gerekli hazırlıkları yapabilirler. Bu da ineğin güvenli bir şekilde buzağılamasını sağlayarak hem yavru buzağının hem de annenin sağlığını korur. Ayrıca, önerilen yöntem ineğin ne zaman satılacağı veya yetiştirileceği konusunda da çiftçilere önemli bir karar verme aracı sunar. Bu sayede çiftçiler, süt üretimindeki dönemsel dalgalanmaları daha iyi yönetebilir ve daha verimli bir işletme yönetimi sağlayabilirler. Önerilen yöntem, diğer yöntemlere göre daha doğru, verimli, esnek ve ölçeklenebilir olmasıyla birlikte, hayvancılık sektöründe önemli bir potansiyele sahiptir. Bu yöntemin kullanımı, süt çiftliklerinin verimliliğini artırarak daha karlı bir işletme yönetimi sağlayabilir.

Sunulan tez çalışmasında, 1. bölümde tezin amacı ve önemi hakkında bilgi verilmiştir. Bu bölümde, süt sığırcılığındaki buzağılama zamanının tahmin edilmesinin neden önemli olduğu ve çalışmanın amacı vurgulanmıştır. 2. Bölümde konuyla ilgili literatür taraması yapılarak süt sığırcılığında buzağılama zaman tahmini yapan çalışmalar incelenmiştir. Önceki çalışmalardaki yaklaşımlar, kullanılan yöntemler ve elde edilen sonuçlar üzerinde durulmuştur. 3. Bölümde tezde kullanılan metaryal ve yöntem hakkında bilgi verilmiştir. Tezde kullanılan veri setinin analiz öncesi işleme süreci ayrıntılı bir şekilde açıklanmıştır. Ayrıca, tekrarlayan sinir ağıları (RNN) tabanlı derin öğrenme modelleri ve kalman filtresi gibi kullanılan yöntemler hakkında detaylı bilgi verilmiştir. Bu bölüm, çalışmanın metodolojik temelini oluşturan bilgileri içermektedir. 4. Bölümde önerilen model kapsamında elde edilen bulgular ile önerilen alternatif yöntemlerin bulgularına yer verilmiştir. Ayrıca önerilen model ve alternatif modellerin başarı metrikleri incelenmiştir. Bulgulara dayalı olarak, buzağılama zamanı tahmini konusunda önerilen modelin etkinliği ve avantajları tartışılmıştır. Ayrıca bu bölümde önerilen model ile literatürdeki çalışmalar karşılaştırılarak gerekli tartışmalar gerçekleştirilmiştir. Son bölümde, çalışmanın sonuçları özetlenmiş ve elde edilen bulguların önemi vurgulanmıştır. Ayrıca, önerilen modelin kısıtlamaları, başarısı ve geliştirilme potansiyeli üzerine detaylı bir değerlendirilme yapılmıştır.

2. LİTERATÜR ÖZETLERİ/KURAMSAL TEMELLER/GENEL BİLGİLER

Tez çalışmasının bu bölümünde literatür taranarak ilgili çalışmalara yer verilmiştir. Ayrıca zaman serileri ve derin öğrenme hakkında genel bilgilere yer verilerek çalışmanın temeli oluşturulmuştur.

2.1. Literatür Taraması

Tez çalışması kapsamında literatür incelendiğinde buzağılama zamanını tahmini çeşitli yöntemlerle tespit edilmeye çalışıldığı görülmektedir. İlgili çalışmalar aşağıda özetlenmiştir.

Wright ve ark., (1988), ineklerin ultrasonik görüntülerinden faydalanarak buzağılama zamanını tahmin etmeye çalışmışlardır. Yöntemin pratik olmaması ve maliyetli olmasından dolayı yeni çalışma arayışlarına yol açmıştır.

Cangar ve ark., (2008), kurdukları video sistemi sayesinde gebe ineklerin buzağılamadan önceki 24 saatini yatma, ayakta durma, yeme ve içme gibi davranışlarını sınıflandırmışlardır. 8 gebe hayvanın davranışsal hareketlerini ortalama %86 doğrulukla sınıflandırmışlardır. İleride gebelik davranışı analiz etmede kullanmak için umut verici bir çalışma olmuştur.

Saint-Dizier ve Chastant-Maillard (2015), çalışmalarında çiftliklerde kullanılan cihazları incelemişler ve buzağılama zamanını tahmin eden ürünleri tespit etmişlerdir. Kuyruk kaldırma ve aşırı aktiviteyi tespit eden eğim ve ivme ölçerler, kasılmaları tespit eden kemerler, vajinal sıcaklıktaki düşüşü tespit eden probalar ve buzağının atılmasını tespit eden cihazlar olmak üzere 4 farklı cihaz olduğunu ifade etmişlerdir.

Titler ve ark., (2015), 132 gebe inek ve düvenin buzağılamadan önceki davranışsal aktiviteleri olan yatma süresi, adımlar, ayakta durma süresi ve yatma nöbetlerini kayıt altına alarak incelemişlerdir. Son 24 saatte diğer günlere istinaden daha fazla adım atma, daha fazla ayakta durma ve daha az yatma süreleri gözlemlenmiştir. Buzağılamadan ortalama 6 saat önce gözlemlenebilen farklı ancak bir davranış modeli gösterdiği tespit edilmiştir.

Xu ve Zhang (2015), borsa verileri üzerinde yaptıkları çalışmada, Changbaishan hisse senedinin 27 günlük kapanış fiyatlarını kalman filtresi kullanarak tahmin etmişlerdir. Kurdukları matematik model sayesinde, kısıtlı verisetine rağmen 27 günlük tahminin %95' ni maksimum %5 yaklaşık hata ile tahmin etmişlerdir.

Ouellet ve ark., (2016), 42 Holstein sığırından 3 otomatik cihaz sayesinde elde ettikleri yatma nöbetleri, yatma süresi, geviş getirme ve vajinal sıcaklık verilerini 1 dakika ve 1 saat aralıklarla kayıt altına alınmıştır. Kurdukları modelde buzağılamanın 24-12-6 saat içinde gerçekleşeceğini tahmin etmeye çalışmışlardır. Lojistik regresyon (LR) modelini

kullanarak yaptıkları çalışmada buzağılamadan önceki son 24-12-6 saati tahmin etmede sırasıyla %77, %70, %68 duyarlılık değerine ve %56, %30 , %15 Pozitif Tahmin Değeri (PPV) değerlerine ulaşmışlardır. En iyi tahmini buzağılamadan önceki son 24 saat dilimi için yapmışlardır. Buzağılama zamanını %77 doğruluk oranıyla tahmin etmişlerdir.

Borchers ve ark., (2017), çalışmalarında 53 holstein süt sığına yerleştirilen ivmeölçer ve sensörlerden elde edilen toplam hareket sayısı, yatma sıklığı, yatma süresi, ayakta kalma süresi, geviş getirme süresi ve toplam adım sayısı verilerinden yararlanarak model geliştirmişlerdir. Buzağılamadan önceki 14 günü kapsayan ve 2 saatlik peryotlar halinde tutulan veriler geliştirilen model için giriş değişkenlerini oluşturmuştur. Çalışmada makine öğrenme yöntemlerinden Rastgele Orman (RF), Doğrusal Diskriminant Analizi (LDA) ve yapay sinir ağları (YSA) modelleri kullanılmıştır. Modelin doğruluğunu değerlendirmek için PPV başarısını ise özgüllük ile ifade etmişlerdir. Buzağılama günü ve buzağılamadan önceki son 8 saat olmak üzere iki farklı değerlendirme yapmışlardır. Buzağılama günü tahmin etmede sinir ağları yöntemiyle %100 duyarlılık ve % 40 olurken PPV değerine sahiptir. Buzağılamadan önceki son 8 saati tahmin etmede ise YSA algoritmasının duyarlılık değeri %82.8 olurken PPV ise %68.6 olarak bulmuşlardır.

Rutten ve ark., (2017), Hollanda’ da bir süt çiftliğinde yaptıkları çalışmalarında 400 inekten sensörler yardımıyla toplanan aktivite, sıcaklık, geviş getirme ve yemleme verileri kayıt altına alınmıştır. 365 gün içerisinde 417 buzağılama gerçekleşmiş ve buzağılamayı alan görüntülerle kayıt altına alınmıştır. Buzağılamadan önceki sırasıyla son 12-6-3-1 saati tahmin etmek için elde edilen verileri LR yöntemiyle tahmin etmişlerdir. Buzağılamadan önceki son 12 saatte % 51.5 duyarlılık değerini ve Doğru Pozitif (True-Pozitif (TP)) sayısını 17 bulmuşlardır. Buzağılama zamanını sadece 17 hayvan için doğru olarak tahmin etmişlerdir.

Fadul ve ark., (2017), cinsleri Friesian ve Holstein 33 inek üzerinde yaptıkları çalışmalarında, hayvanlara taktıkları burun bandı ve ivmeölçer sayesinde geviş getirme ve aktivite değerlerini elde etmişlerdir. Buzağılamadan en az 10 gün öncesinde taktıkları cihazlar sayesinde buzağılamadan önceki son 3 saati tahmin etmeye çalışmışlardır. Makine öğrenmesi yöntemlerinden LR kullanarak tahmin ve İşlem karakteristik Eğrisi

(ROC) analiziyle ise modelin performansını değerlendirmişlerdir. ROC eğrisi altında kalan alan (AUC)=0.94, duyarlılık = %87, özgüllük = %83.65 değerleri modelin başarısını göstermektedir.

Zehner ve ark., (2019), çalışmalarında 35 süt ineğinin yutma davranışlarını taktıkları burun bandı sayesinde kayıt altına almışlardır. 3 farklı çiftlik, 35 hayvandan elde ettikleri 168 saatlik verisetini kullanarak buzağılamadan önceki son 1 saati tahmin etmeye çalışmışlardır. Naïve bayes (NB) sınıflandırıcısını kullandıkları modelde duyarlılık=%69, özgüllük=%89 ve PPV=%3 tahmin etmişlerdir. PPV değerinin çok düşük olması buzağılama zamanını çok düşük doğru olarak tahmin ettiğini ifade etmektedir. özgüllük değerinin yüksek, PPV'nin düşük çıkması daha çok 0 ların yani buzağılama olmayan zaman dilimini doğru tahmin ettiğini göstermektedir. Bunun sebebi ise 0 olarak etiketlenen veri miktarının 1'lerden çok daha fazla olmasından kaynaklanabilir.

Miller ve ark., (2019), çalışmalarında 254 süt ve besi ineğine taktıkları ivmeölçer ve sensör sayesinde yeme, geviş getirme, aktivite seviyeleri ve kuyruk kaldırma davranışlarının verilerini kayıt altına almışlardır. Buzağılamadan önceki son 2 saati tahmin etmek için RF makine öğrenme modelini tercih etmişler ve başarı ölçütü olarak ise Matthew's korelasyon katsayısını (MCC) kullanmışlardır. Bütün parametreleri kullanarak buldukları MCC=0.3 iken sadece kuyruk sensörünü kullanarak yaptıkları tahminde ise MCC=0.29 bulmuşlardır. Çalışmaları için kuyruk sensörü dışındaki verilerin önem arz etmediğini tespit etmişlerdir.

Keceli ve ark., (2020), 53 süt sığırının davranışsal hareketleri olan yeme, geviş getirme, ayakta durma, yatma, uyuma nöbet sıklığı gibi verilerinden faydalananarak buzağılama zamanını tahmin için model geliştirmişlerdir. Geliştirilen modelde buzağılama günü ve buzağılamadan önceki son 8 saati tahmin etmeye çalışmışlardır. Buzağılamadan önceki son 8 saati tahmin için Rusboosted (RT) algoritmasını kullanarak Duyarlılık=%66 ve PPV= %89 oranla tahmin etmişlerdir. Buzağılama günü tahmin için ise Destek Vektör Makinaları (SVM), Uzun-kısa süreli bellek (LSTM), K-en yakın komşu (kNN), Bi-LSTM, RF, LDA, algoritmalarını kullanmışlar ve en iyi sonuca olan derin öğrenme

modeli olan Bi-LSTM ile ulaşmışlardır. Duyarlılık= %82 ve PPV= %83 model başarılı bir tahmin yapmışlardır.

Peng ve ark., (2020), çalışmalarında 4 ineğin buzağılamadan önceki son 3 gün içindeki ayakta durma, yatma, geviş getirme gibi verilerini ve kurduğu kamera sistemini kullanarak buzağılama zamanını tahmin etmeye çalışmışlardır. Makine öğrenme modellerinden LSTM ile RNN kullanarak yeni bir model önermişlerdir. LSTM-RNN modelinin başarı kriteri olarak kullandığı kesinlik değeri %81.1 ve duyarlılık değeri %79.9 olarak tespit edilmiştir. Sonuçlar gelecek için umut vericidir.

Higaki ve ark., (2020), çalışmalarında 138 süt sığırının buzağılamadan önceki son 24 tahmin etmek için kuyruklarına sıcak sensörü yerleştirerek veri toplamışlardır. Bu verileri Destek Vektör Makinaları (SVM) algoritmasına giriş parametresi olarak kullanıp buzağılama zamanı tahmini yapmışlardır. Testlerini $<15^{\circ}\text{C}$, $>15^{\circ}\text{C}$ ile $<25^{\circ}\text{C}$ ve $>25^{\circ}\text{C}$ 3 farklı sıcaklık ortamına sahip 2 farklı çiftlikte ve 108 gebe sığırdan aldığı verilerden gerçekleştirmiştir. Buzağılamanın 24 saat içinde gerçekleşeceğine dair %70 kesinlik değeri başarı kriteri olarak belirlenmiştir.

Liseune ve ark., (2021), 8 farklı çiftlikten 2363 Süt sığırlarının bacaklarına ve boyunlarına takılan sensörler sayesinde geviş getirme, yürüme, yatma, ayağa kalkma verilerini dakikalık peryotlarla kayıt etmişlerdir. Buzağılamadan önceki farklı saat dilimlerini tahmin etmek için makine öğrenme yöntemlerini kullanmışlardır. Buzağılamadan önceki sırasıyla son 24, 12, 6 ve 1 saati tahmin için RF, LR, LSTM, Evrimsel Sinir Ağları (CNN) ve kurdukları yeni model olan C-LSTM'i kullanmışlardır. Buzağılamanın 24 saat içerisinde gerçekleşeceğin %77 son 3 saatte %49 kesinlik değeriyle gerçekleşeceğini tespit etmişlerdir.

Sumi ve ark., (2021), Japonya'da bir çiftlikte ahırlara yerleştirdikleri kameralarla 10 süt sığırını izlemişlerdir. Hayvanların davranışsal hareketleri olan ayakta durma, yatma, kalkma, kuyruk kaldırma ve pozisyon değiştirmelerini video görüntülerinden işleyerek Saklı markov modeline giriş değişkeni olarak vermişlerdir. Buzağılamadan önceki 3 günü tahmin ettikleri bu modelde başarılı sonu elde etmişlerdir. Önerdikleri modelde başarı

kriteri olarak kullandıkları kesinlik değerini %93.28 olarak gerçekleştirmiştir. Hayvanlara takılacak sensörler sayesinde elde edilen geviş getirme ve hareket sayıları gibi verilerle başarı oranının daha artacağı öngörülmektedir.

Deepika ve Bhat (2021), Yahoo ve Twitterdan aldıkları verilerle 10 hisse senedi üzerine çalışmalarıdır. Çalışmalarında kNN, SVM, LSTM ve Hızlandırılmış Gradyan (AG) ve LSTM derin öğrenme modeliyle birlikte kalman filtresi kullanarak fiyat tahmini yapmışlardır. Elde ettikleri sonuçlar önerilen yöntemin hisse senedi tahmininde mevcut yönteme kıyasla daha performanslı olduğunu göstermiştir. Kalman filtresi ve AG-LSTM modeliyle %84.1 başarı elde ederken, Kalman filtresi kullanmadan AG-LSTM modelini uyguladıklarında başarı oranını %58.4 olarak tespit etmişlerdir. Kalman filtresi kullanarak yapılan tahminde apple hisse için Karesel ortalama (MSE) 0.0514 iken, Kalman filtresi kullanılmadan yapılan tahminde 0.2451 olarak tespit etmişlerdir. Kalman filtresi kullanılmasının performansı artırdığını göstermektedir.

Weleszczuk ve ark., (2022), Polonya’da 2000 holstein cinsi düve ve inekten elde ettikleri verileri kullanarak buzağılama gününü tahmin etmeye çalışmışlardır. Kullandıkları 27 parametrelerden bazıları vücut ve meme genetik değeri, sütteki yağ ve proteindir. Polonya’da farklı 16 farklı bölgeden toplanan veriler makine öğrenme modelleriyle eğitilerek test edilmiştir. Karar ağacı (DT), kNN, Gradyan artırma (GB), YSA, LR, RF modellerini kullanmışlardır ve en iyi sonucu Kök Ortalama Kare Hatası (RMSE) değeri 1.27 olan GB ile elde etmişlerdir. Modelin performansını Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) ile ölçülmüşlerdir.

2.2. Kuramsal Temeller ve Genel Bilgiler

2.2.1. Zaman Serileri

Zaman serileri belirli aralıklarla elde edilen (genel olarak aralarında eşit mesafe bulunan) gözlemlenen ve ölçülebilen değişkenin zaman içerisinde nasıl değişiklik gösterdiğini ifade eden istatistiksel bir modellemedir. Farklı alanlarda çeşitli verilerin toplandığı gözlemler yapılmaktadır. İş dünyasında finansal veriler, meteorolojide hava durumu

verileri, tarımsal alanda üretim rakamları ve biyolojik bilimlerde biyolojik süreçler incelenerek veriler kaydedilir. Zaman serisi olan bu verilerin toplanması ve analizi sayesinde geçmiş dönemlerin veya bugünün trendleri belirlenerek gelecekteki olası sonuçlar tahmin edilebilir (Jonathan & Kung-Sik, 2008). Böylece, karar vericiler daha bilinçli ve verilere dayalı kararlar alabilirler. Tahminler kısa, orta ve uzun vadeli olarak sınıflandırdığımızda; saat, gün ve haftalık tahmini kısa vadeli, 1 ile 2 yıl aralığında tahminler orta vadeli ve daha uzun yılları kapsayan tahminler ise uzun vadeli tahmin olarak değerlendirilmektedir.

Zaman serisi tahminleri gerçekleştirirken kullanılan yöntemler geleneksel ve geleneksel olmayan yöntemler olarak ikiye ayrılır. Geleneksel yöntemlerde geçmiş veri setinden yararlanarak model kurulur. Geleneksel yöntem olarak kullanılan modeller genel olarak; Otoregresif model (AR), Hareketli Ortalama modeli (MA), Otoregresif Hareketli Ortalama modeli (ARMA), Bütünleşik Otoregresif Hareketli Ortalama modeli (ARIMA) olarak karşımıza çıkmaktadır. Geleneksel olmayan yöntemlerde ise karmaşık ve büyük veri setleri ile çalışırken geçmiş veri setinden yararlanarak makine öğrenmesi yöntemleri ile tahmin ve modelleme yapılmaktadır. Geleneksel olmayan yöntemler, Yapay sinir ağları, Destek Vektör Makineleri, Evrimsel Sinir Ağları, Tekrarlayan Sinir Ağları, Doğrusal Regresyon, Karar Ağaçları ve Rasgele Orman algoritmaları gibi birçok farklı modelden oluşmaktadır. Qian (2017), çalışmasında zaman serisi tahmininde kullanılan geleneksel yöntemler ve makine öğrenme modellerini ele almıştır. Bu yöntemler özellikle karmaşık ve büyük veri setleri ile çalışırken geleneksel yöntemlerin kısıtlarını aşmak için kullanılır. Literatür incelediğinde bu modellerle geleneksel yöntemlere kıyasla daha başarılı tahminler yapıldığı gözlemlenmiştir.

Bu çalışma kapsamında süt sığırcılığına ilişkin buzağılama zaman tahmini gerçekleştirilirken makine öğrenme yöntemlerinden olan derin öğrenme modellerinden faydalanılmıştır. Bu kapsamda bir sonraki bölümde uygulamada kullanılan yöntemlere yer verilmiştir.


2.2.2. Derin Öğrenme (DL)

Derin öğrenme, yapay sinir ağlarının karmaşık ve çok katmanlı yapılarını kullanarak veri özelliklerini keşfetmek ve öğrenmek için kullanılan bir makine öğrenme modelidir. Bir

başka ifadeyle bilgisayarların tecrübelerden yararlanarak öğrenmesini sağlayan makine öğrenme biçimine derin öğrenme denir (Goodfellow ve ark., 2016). Derin öğrenme modellerinde, karar verme ve özellik çıkarımı için sinir hücreleri ardışık olarak kullanılmaktadır bundan dolayı sığ makine öğrenme algoritmalarından daha performanslı olabilirler (Cil ve ark., 2021) . McCulloch-Pitts yapay sinir ağlarında kilometre taşı olarak kabul edilen beyin fonksiyonlarını işlevini hesaplayan temel matematiksel bir model sunmuşlardır (McCulloch & Pitts, 1943). Makinelerin insanların yaptıkları işleri yapma fikrini 1956 yılında John Mccarthy tarafından ortaya atılmıştır (Andresen, 2002). Yapay sinir ağları, 1970’li yıllarda finansal kaynakların azalması ve yaşanan zorluklar nedeniyle “Yapay Zekâ Kış Uykusu” olarak isimlendirilen dönem geçirmiştir ama 2000’li yıllarda donanım alanındaki gelişmelerle tekrar kullanılmaya başlanmıştır (Schmidhuber, 2015). Ayrıca derin öğrenme modellerinin büyük veri setleriyle eğitilmesi tercih edilir (İnik & Turan, 2018). Donanımsal kaynaklara fazla miktarda ihtiyaç duyulmasının sebebi büyük veri seti kullanılmasından ve derin öğrenme modellerindeki sinir ağı katman sayısındaki artıştan kaynaklanmaktadır. Standart işlemciler basit problemleri kısa sürede çözerken karmaşık ve büyük veri setleri için yetersiz kaldığı gözlemlenmektedir. Bu nedenle derin öğrenme modellerinin eğitilip ve işlemesi için paralel hesaplama yapabilen, birçok çekirdeğe sahip ve işlemciye göre daha yüksek işlem gücüne sahip Grafik işleme birimi (GPU) kullanılır. Hinton ve ark., (2012), tarafından modellenen Alexnet mimarisi derin öğrenmede GPU’ ların kullanıldığı ilk çalışmalardan biridir.

Derin öğrenme modelleri, CNN, RNN, LSTM, Bi-LSTM gibi birçok sinir ağı modelini kullanır. Bu modeller hem sınıflandırma hem de tahmin problemlerinde kullanılırlar.

Zaman serisi tahmininde, derin öğrenme modellerinden CNN, RNN, LSTM, Bi-LSTM gibi modellerin başarılarının yüksek olduğunu çalışmalar göstermiştir. Zaman serisindeki uzun süreli bağımlılıkları LSTM ve Bi-LSTM modelleri yakalayabilmektedir.



Şekil 2.1 Yapay zekâ, makine öğrenmesi ve derin öğrenmenin konumu

Derin öğrenme yöntemleri, verilerin üst düzey soyutlamalarını modellemeye çalışarak daha yüksek düzeyde özelliklerin öğrenilmesini sağlar (Goodfellow ve ark., 2016). Bu sayede veriler arasındaki karmaşık ilişkiler daha iyi anlaşılabilir hale ve daha doğru tahminler yapılabilir. Derin öğrenmede önceden tanımlanmış öznitelikler yerine, veriler doğrudan sisteme verilir ve sistemin, verilerdeki ilişkileri kendisi öğrenerek önemli noktaları modellemesi beklenir. Öznitelik mühendisliğini ortadan kaldırarak doğrudan veriye dayalı öğrenme ile ilişkileri belirleyici noktaları modelleyebilir.

3. MATERYAL YÖNTEM

Bu tez çalışmasında, tarımın önemli bir parçası olan süt sığırcılığında buzağılama zamanı tahmini derin öğrenme modellerinden LSTM, Bi-LSTM ve Kapılı Tekrarlayan Birim (GRU) yöntemleriyle incelenecektir. Zaman serilerinde kullanılan Kalman filtresi ile eksik gözlemler ve gürültülü verilerden dolayı oluşabilecek tahmin başarısızlığını en aza indirilecektir. Modelin performansını değerlendirmek için Hassaslık (Precision), Duyarlılık (Re-call), Doğruluk (Accuracy), F₁-Skor (F₁-Score), Cohen's kappa başarı metrikleri kullanılacaktır. Bu tez çalışması kapsamında süt sığırlarının buzağılama zamanı tahmini saatlik olmak üzere ele alınmıştır. Deneysel çalışmalarda 37 süt sığırından elde edilen veriler kullanılarak modeller eğitilmiş ve test edilmiştir. Sonraki bölümde veri seti ile çalışmada kullanılan yöntemler hakkında bilgi verilmiştir.

3.1. Çalışmada Kullanılan Bilgisayar Özellikleri

Çizelge 3.1. Çalışmada Kullanılan Bilgisayarın Teknik Özellikleri

Donanım	Teknik Özellikler
Üretici	HP
İşlemci (Cpu)	Intel Core i5
Ekran Kartı (Gpu)	Intel Iris Xe – 4 GB
Çekirdek Sayısı (Core)	4
İşlemci Hızı	2.4 Ghz
Ön Bellek	8 MB
Ram	8 GB
Ssd	256 GB

3.2. Çalışma Ortamı MATLAB

Matlab, sayısal hesaplama, veri analizi ve görselleştirme gibi alanlarda kullanılan bir programlama dili ve ortamıdır. Matlab'ın temel amacı matris hesaplamalarını kolaylaştırmak ve hızlandırmaktır.

Matlab, matematiksel işlemler, mühendislik hesaplamaları, veri analizi, görüntü işleme, sinyal işleme, yapay zekâ ve makine öğrenmesi gibi birçok alanda kullanılır. Matlab, görselleştirme araçları ile verilerinizi grafikler, tablolar ve çizimler şeklinde analiz etmenize yardımcı olur.

Deep Learning araç kutusu sayesinde derin öğrenme ağlarını tasarlama, eğitme ve uygulama gibi işlemlerin gerçekleştirilmesine olanak tanımaktadır. Ayrıca CNN, LSTM, Çekişmeli üretken ağlar (GAN), Otomatik kodlayıcı gibi popüler derin öğrenme modellerinin uygulanması için de gerekli fonksiyonları içermektedir. Neural Network araç kutusu ile düzgün yayılım katmanlı ağlar (Feedforward Neural Networks), RNN ağlar (Recurrent Neural Networks) ve ardışık veri akışı ağları (Time series networks) gibi farklı yapay sinir ağı türlerinin tasarlanmasına, eğitimine ve simülasyonuna imkân tanımaktadır. Reinforcement Learning Toolbox araç kutusu sayesinde, pek çok problemde kullanılabilen takviyeli öğrenme algoritmalarının tasarımını ve eğitimini sağlamaktadır. Bu araçların yanı sıra, Matlab, açık kaynaklı frameworkler olan PyTorch ve TensorFlow ile de entegre edilebilir. Bu şekilde, bu frameworkleri kullanarak oluşturulan modelleri Matlab üzerinde eğitmek ve test etmek mümkündür.

3.3. Veri Hazırlama

Bu bölümde verilerin toplanma yöntemleri, veri setinin özellikler ve veri ön işleme hakkında bilgi verilmiştir. Veri ön işleme yapıldıktan sonra derin öğrenme modellerinin kullanılmasıyla modellerin sınıflandırma başarısının arttığı gözlemlenmiştir (Adem ve ark., 2023)

3.3.1. Veri Toplama Süreci

Veriler, Kentucky üniversitesi Coldstream süt ürünleri tesisinde 2011-2013 yılları arasında 20 ilk buzağılama 33 birden fazla buzağılama yapmış toplamda 53 süt sığırları kullanılarak toplanmıştır. Tahminen buzağılamadan 28 gün önce ineklere 3 boyutlu ivmeölçer ile içerisinde bir mikro işlemci barındıran boyun hareketlerini ve geviş getirme verilerini otomatik olarak toplayan sensör yerleştirilmiştir. Ayağa takılan ivmeölçer


sayesinde adım sayısı, ayakta geçirilen süre, yatarak geçirilen süre, ayakta durmaktan yatmaya geçiş sayısı (yatma nöbetleri) ve toplam hareket değişkeni 15 dakikalık zaman dilimleriyle otomatik olarak toplanmıştır.

3.3.2. Veri Setinin Özellikleri


Veri seti elektronik ortamda günlük ve saatlik veriler olmak üzere CSV formatında tutulmuştur. Veri seti, her bir inek için bir numara verilmiş olup ve bu inekler için toplam adım sayısını, ayakta geçirilen süreyi, yatarak geçirilen süreyi, yatma nöbetlerini, geviş getirme sayısı ve boyun hareket süreleri içerir. Özniteliklerin farklılaşması arttıkça buzağılama tahmini hakkında daha fazla bilgi alınabilir (Çam & Özdağ, 2021). Saatlik veri seti, buzağılamadan önceki son 72 saatlik verileri içerir ve 2 saatlik periyotlar halinde bulunan verilerin saatlik ortalamaları da mevcuttur. Günlük veri setinde, buzağılamadan önceki son 14 günlük veriler günlük periyotlarla verilmiştir. Şekil 3.1 ile Şekil 3.5 arasındaki şekiller süt sığırının buzağılamadan önceki son 3 güne ait toplam hareket sayısı, ortalama ayakta kalma süresi, ortalama yatma süresi, ortalama adım sayısı ve yatma sıklığı verilerini göstermektedir.




Şekil 3.1. Süt Sığırının Buzağılamadan önceki 3 gün içindeki Toplam Hareketleri




Şekil 3.2. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Ayakta Kalma Süresi



Şekil 3.3. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Yatma Süresi



Şekil 3.4. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Adım Sayısı



Şekil 3.5. Süt Sığırının Buzağılamadan Önceki Son 3 Gün Ortalama Yatma Sıklığı

3.3.3. Veri Setinin Temizlenmesi

Deneysel çalışmamızda toplanan veri setinde bazı hayvanların verilerinin eksik olduğu gözlemlenmiştir. Yapılacak tahminler bütün veri üzerinden değil de her bir hayvanın kendi süreci üzerinden değerlendirileceği için etiketlenmeye engel hayvanlar işlem dışı bırakılmıştır.

3.3.4. Veri Dönüştürme

İneklerin davranışsal farklılıklarını gösteren saatlik veriler 2 saatlik periyotlar şeklinde ve buzağılamadan önceki son 24 saati içerecek şekilde düzenlenmiştir. Verileri buzağılamanın başladığı saatleri 1 buzağılamanın olmadığı saatleri 0 olmak üzere etiketlenmiştir. Buzağılamanın başladığı 2 periyot olan 4 saatlik zaman dilimi olarak alınmıştır. İneklerin durumlarını 0 ve 1 şeklinde binarizasyon işlemine (sınıflandırma için ikili formata dönüştürme) tabi tutulmuştur. Böylece 0 olan yerlerde buzağılama gerçekleşmedi 1 olan durumlarda ise buzağılama başladı veya gerçekleşti olarak etiketlenmiştir.

3.3.5. Veri Normalizasyonu

Normalizasyon veriler arasındaki ölçek farklılıklarından kaynaklanan hataları gidererek, makine öğrenimi modellerinin daha doğru ve güvenilir tahminler yapmasına yardımcı olan bir veri ön işleme yöntemidir. Verileri belirli bir aralığa veya dağılıma göre yeniden ölçeklendirerek veri dağılımını standartlaştırır böylece modele daha uyarlanabilir hale getirir. Z-score matematiksel formülü denklem (3.1) gösterilmektedir.

$$Z_{norm} = \frac{(X - \text{mean}_x)}{(Sd_x)} \quad 3.1$$

Z_{norm} = Normalize edilmiş özellik değeri

X = Normalize edilmek istenen değer

mean_x = Özelliklerin ortalaması

Sd_x = Özelliklerin standart sapması

Çizelge 3.2. Verilere Z-skor normalizasyonu uygulanmış hali


0.146449	0.20526	-0.54526	0.545264	-0.67472
0.438855	0.479759	-0.70774	0.707741	-0.2439
0.647774	0.676606	-0.42606	0.426057	0.079395
0.853224	0.875318	0.227062	-0.22706	0.438281
0.694465	0.686877	0.501805	-0.50181	0.716513
0.654506	0.62871	0.866864	-0.86686	0.943808
0.59847	0.560737	1.148179	-1.14818	1.089534
0.632387	0.597841	1.470406	-1.47041	1.183016
0.405422	0.341102	1.488153	-1.48815	1.242997

3.3.6. Veri Setinin Bölünmesi ve Eğitim-Test Kümelerinin Oluşturulması

Veri setinin, eğitim ve test olarak ikiye ayırmak yerine k-kat çapraz doğrulama yöntemi kullanılarak 4 eşit parçaya bölünerek bütün veri seti üzerinde eğitilmesi ve test edilmesi sağlanmıştır. Bu yöntemle veri setinin %75' i eğitim %25' i test için kullanılmıştır.

3.3.6.1. K-Kat Çapraz Doğrulama

Makine öğrenmesi modellerinin, tüm veri seti üzerinden eğitilip ve test edilmesine olanak sağlayan K-kat çapraz doğrulama yöntemidir. Bu yöntem ile modelin performansını daha objektif değerlendirirken, modelin aşırı öğrenmesinin de önüne geçmektedir. Yöntemin çalışma prensibi, veri seti k eşit parçaya bölünür ve k adet alt kümeden biri test için kullanılırken veri setinin kalan kısmı eğitim için kullanılır. Her iterasyonda elde edilen başarı metriklerinin ortalaması alınarak modelin başarısı ortaya çıkmaktadır (Yadav & Shukla, 2016). Şekil 3.6' da K-kat çapraz doğrulama örnek bir uygulama gösterilmiştir.



Şekil 3.6. K-kat çapraz doğrulama

3.3.6.2. Performans Ölçütleri

Modelin performansını değerlendirmek için Binary Karışıklık Matrisi (Confusion matrix) kullanılır (Ruuska ve ark., 2018). Karışıklık matrisi, modelin tahmin ettiği sınıf etiketleri ile gerçek sınıf etiketleri arasındaki ilişkiyi gösterir. Karışıklık matrisi doğru sınıflandırılan pozitiflere doğru pozitif (TP), doğru sınıflandırılan negatiflere doğru negatif (TN), yanlış sınıflandırılan pozitifler (FP) ve yanlış sınıflandırılan negatifler (FN) olarak sınıflandırılır. Karışıklık matrisinin tablosu şekil 3.7' de gösterildiği gibidir. Karışıklık matrisinden yararlanarak modelin başarısını ölçmek için İnik ve Ülker'in önerdiği, Hassaslık, Duyarlılık, Doğruluk, F₁-Skor, Cohen's kappa denklemleri kullanılacaktır (İnik & Ülker, 2022).

Hassaslık, sınıflandırma modelinin ne kadar doğru pozitif tahmin yaptığını göstermektedir (TP, FP). Doğruluk, bir sınıflandırma modelinde doğru olarak sınıflandırılmış verilerin oranını ifade etmektedir. (TP, TN). Duyarlılık, modelin pozitif örnekleri doğru şekilde sınıflandırma yeteneğini ölçmektedir. Cohen's Kappa statistic, dengesiz sınıf problemlerinde başarıyı ölçmek için kullanılmaktadır (Hussain, ve ark., 2019).

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Sınıf	Pozitif	Doğru Pozitif (TP)	Yanlış Pozitif (FP)
	Negatif	Yanlış Negatif (FN)	Doğru Negatif (TN)

Şekil 3.7. Karışıklık Matrisi (Confusion Matrix)

Doğruluk, sınıflandırma modelinin doğru sonuç verme oranını gösterir. Denklem (3.2) gösterilmektedir.

Hassasiyet, modelin pozitif olarak tahmin ettiği örneklerin gerçekte pozitif olma oranını ifade eder. Denklem (3.3) gösterilmektedir.

Duyarlılık, modelin pozitif örnekleri doğru şekilde sınıflandırma yeteneğini ölçer. Denklem (3.4) gösterilmektedir.

F1-Skor, sınıflandırma modelinin doğruluğunu ölçer. Denklem (3.5) gösterilmektedir.

Cohen Kappa, dengesiz sınıf problemlerinde başarıyı ölçmek için gösterilmektedir. Denklem (3.6) gösterilmektedir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad 3.2$$

$$\text{Hassasiyet} = \frac{TP}{TP + FP} \quad 3.3$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad 3.4$$

$$F1_{\text{skor}} = \frac{2 * \text{Hassasiyet} * \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} = \frac{2TP}{2TP + FP + FN} \quad 3.5$$

$$\text{Cohen Kappa} = \frac{P_o - P_e}{1 - P_e} \quad 3.6$$

$$P_o = \frac{TP + TN}{TP + FP + TN + FN} \quad 3.7$$

$$P_e = \frac{(TP + FP) * (TP + FN)}{(TP + FP + TN + FN)^2} + \frac{(TP + FP) * (TN + FN)}{(TP + FP + TN + FN)^2} \quad 3.8$$

3.4. Çalışmada Kullanılan Yöntemler

Bu bölümde çalışmada kullanılan Kalman filtresi, RNN, LSTM, Bi-LSTM ve GRU modellerinden bahsedilecektir.

3.4.1. Kalman Filtresi

Kalman filtresi, bir sistemdeki bilinmeyen durumları MSE değerini en aza indirecek şekilde tahmin etmek için özyinelemeli bir denklemdir (G. F. Welch, 2020). Böylece

sistemin belirsizliğini en aza indirir ve daha iyi tahminler elde etmeyi sağlar. Kalman filtresi, sistem hakkında önceki bilgileri kullanarak hedefin gerçek durumunu tahmin eder ve tahminlerin ne kadar doğru olduğunu ölçer. Kalman filtresi tahmin ve güncelleme aşaması olarak iki bölümden oluşur.

Tahmin aşaması: sistemin son durumunun tahmini yapılır. Bu tahmin, sistemdeki önceki durum ve sisteme uygulanan girdilerin bir fonksiyonu olarak hesaplanır. Tahmin gerçek durumdan farklı olabilir, ancak sistemin önceden bilinen özelliklerini kullanarak, tahminin hata miktarını da tahmin eder.

Güncelleme aşaması: Tahmin edilen durum gerçek durumla karşılaştırılır, bunun sebebi tahmin edilen durumun doğruluğunu ölçmek için kullanılır. Tahmin edilen durum, gerçek ölçümlerle ve matematik modellerle uyumlu hale getirilir. Bu sayede sistemin gerçek durumunun daha doğru bir tahminine yol açar (G. Welch & Bishop, 1995).

P_k^- = Tahmin edilen hata kovaryansı

R_k = Ölçülen hata kovaryansı

Q_k = Gürültü matrisi

K_k = Kalman Kazancı

Kalman Filtresi Tahmin Adımı

$$\hat{x}_{k+1} = A_k \hat{x}_k + B u_k \quad (3.17)$$


$$P_{k+1}^- = A_k P_k A_k^T + Q_k \quad (3.18)$$

Kalman Filtresi Düzeltme Adımı

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (3.20)$$

$$\hat{x}_k = \hat{x}_k^- + K(z_k - H_k \hat{x}_k^-) \quad (3.21)$$

$$P_k = (I - K H_k) P_k^- \quad (3.22)$$




Şekil 3.8. Kalman Filtresinin Çalışma Modeli

3.4.2. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağları, derin öğrenme yöntemleri arasında yer alan bir yapay sinir ağı türüdür ve giriş parametreleri zaman serisi olan problemler için tercih edilir. Bu sinir ağları geçmiş zaman adımlarında elde edilen verileri mevcut ya da gelecek zaman dilimlerindeki tahminleri hesaplamak için kullanır (Goodfellow ve ark., 2016). RNN' ler geleneksel yapay sinir ağı modellerinde olduğu gibi, bir dizi katmandan oluşur. Bu mimarinin özelliği, birbiriyle bağlantılı katmanların döngüsel bir şekilde bağlanmasıdır. Diğer sinir ağlarında tüm girdiler birbirinden bağımsızdır fakat RNN' de girdiler birbiriyle ilintilidir. Bağlantılar sayesinde önceki durumları bir sonraki duruma aktarır ve ağıın önceki durumları belleğinde tutmasına izin verir. Geçmişteki durumları belleğinde tutması sebebiyle zaman serisi modellemesinde kullanılabilir. RNN sıralı verileri (metin gibi) modellemek için yaygın olarak kullanılmaktadır. Ancak verilerin uzunluğu arttıkça

modelin performansı azalabilir. Hafızada uzun süreli bağımlılık sorununu çözmek için farklı RNN modelleri önerilmiştir. Şekil 3.9’ da RNN mimarisinin yapısı gösterilmiştir. RNN’ lerin eğitilmesi diğer yapay sinir ağı modellerine göre zor olması ve çok sayıda parametre içermesine rağmen paralel hesaplama, ağ mimarileri ve optimizasyon tekniklerindeki gelişmeler büyük oranda başarılı sonuçlar almasının önünü açmıştır (Lipton ve ark., 2015).




Şekil 3.9. Tekrarlayan Sinir Ağları (RNN) Mimari Yapısı

3.4.2.1. Uzun Kısa Süreli Bellek (LSTM)

Uzun- Kısa Süreli Bellek ağları (LSTM) uzun dönemli bağımlılıkları öğrenebilen bir tekrarlayan sinir ağı türüdür. Hochreiter ve Schmidhuber, (1997), hafıza yeteneği sayesinde LSTM mimarisini zaman serilerinde kullanımını önermiştir. LSTM’ ler RNN’ lerin hafızasını genişleterek geçmişteki verilerden elde edilen kalıplar sayesinde uzun vadeli bağımlılıkları öğrenebilirler. Bu bellek uzantısı, bilgileri daha uzun süre hatırlama yeteneğine sahiptir ve böylece kapılar sayesinde belleklerinden bilgi okuma, yazma ve silmeye olanak tanır (Namini ve ark., 2019). Zaman serisi ve doğal dil işleme gibi uzun vadeli bağımlılıkların önemli olduğu problemlerde başarılı sonuçlar verirler. LSTM Şekil 3.10’ da görüldüğü üzere giriş kapısı x_t , hafıza kapısı C_t ve çıkış H_t kapısı olmak üzere

üç kapıya sahiptir. Kapılar sayesinde girdi önemliyse bir sonraki adıma aktarılır önemsiz ise unutulur. Bir önceki katmandan hafıza kapısına gelen bilgiler (h_{t-1} ve x_t) sigmoid fonksiyonundan geçerek 1'e yakınlık derecesine göre hatırlanmaktadır. Girdi kapısında sigmoid fonksiyonu sayesinde hangi bilginin iletileceğine, *Tanh* fonksiyonu ile (-1,1) arasına indirgenmektedir. *Sigmoid* ve *Tanh* fonksiyon çıktıları çarpılarak hangi bilginin güncelleneceğine karar vermektedir. Çıkış kapsında ise sonraki hücreye girecek olan bilgiyi belirlemektedir. Bunu yaparken, mevcut değer ile bir önceki değer *sigmoid* fonksiyonundan geçer, taşımakla görevli olan Cell-State hücresinden gelen değer ise *Tanh* fonksiyonundan geçerek bu değerler çarpılarak bir sonraki katmana girdi olarak iletilir (Olah, 2015).



Şekil 3.10 Uzun Kısa Süreli Bellek (LSTM) Ağı Mimari Yapısı

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.9)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.10)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.11)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3.12)$$


$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.13)$$

$$h_t = o_t * \tanh(C_t) \quad (3.14)$$

Denklemlerde hafıza kapısını f_t , giriş kapısını i_t , çıkış kapısını o_t , giriş vektörünü x_t , giriş değerlerinin ağırlıklarını W , bias değerini b hücre bilgilerini C_t , çıktı vektörünü h_t , sigmoid aktivasyon fonksiyonunu σ , hiperbolik tanjant fonksiyonunu ise $\tanh$ olarak gösterilmektedir.

3.4.2.2. Çift Yönlü Uzun Kısa Süreli Bellek (Bi-LSTM)


Girdilerin her iki yönde de işlenebildiği LSTM modelinin türüdür. Bu sayede önceki zaman adımlarındaki bilgilerin hem ileri yönlü hem de geri yönde aktarılmasını sağlar. LSTM' in ileri ve geri yönde olarak iki kez uygulanması, uzun vadeli bağımlılıkların öğrenilmesini artırır ve modelin doğruluğuna pozitif yönde katkı sağlar (Namini ve ark., 2019). Bi-LSTM mimari yapısı Şekil 3.11' de verilmiştir. Yapılan çalışmalar incelendiğinde birçok dil modeli ve doğal dil işleme uygulamalarında başarılı sonuçlar verdiği gözlemlenmiştir. Bi-LSTM özellikle uzun metinlerdeki ilişkileri yakalama konusunda başarılıdır ve bu alanlarda sıkça kullanılır.



Şekil 3.11. Çift Yönlü Uzun- Kısa Süreli Bellek (Bi-LSTM) Ağı Mimari Yapısı

3.4.2.3. Kapalı Tekrarlayan Birim (GRU)


Chung ve ark., (2014), tarafında geliştirilen ve RNN türü olan GRU mimarisi LSTM mimarisine benzer yapıya sahiptir. Kapılar sayesinde bilgi akışını kontrol ederken LSTM' den basit mimarisi sebebiyle eğitimi daha hızlı gerçekleştirir. GRU eğitilirken, giriş veriler ile ağ beslenir ve ağın çıktısı ile gerçek değer arasındaki fark azaltmak için ağırlıklar güncellenir. Bu işlem belirli bir doğruluk seviyesine kadar devam eder. Güncellemenin yapıldığı güncelleme kapısı ve sıfırlama (reset) kapısı olmak üzere GRU mimarisinde iki kapı mevcuttur. Güncelleme kapısı, hangi bilgilerin saklanmayacağına ve hangi yeni bilgilerin eklenip güncelleneceğine karar verir. Sıfırlama kapısı hafıza hücresinin hangi bilgini korunacağına karar verir, kapı açık olduğunda hafıza hücresi geçmiş bilgiyi unuttur ve sadece mevcut girdiye dayalı olarak yeni bir hafıza hücresi oluşturur. Reset kapısı kapalı olduğunda ise geçmiş bilgiyi korur ve yeni bilgiyi ekler. GRU' nun basit bir mimarisi vardır dolayısıyla daha az donanım kaynağı tüketmektedir. GRU, LSTM' e göre daha hızlıdır ancak hangi yöntemin daha iyi sonuç göstereceği hem uygulamanın amacına hem de veri setine bağlıdır.



Şekil 3.12. Kapalı Tekrarlayan Birim (GRU) Ağı Mimari Yapısı

3.4.3. Tam Bağlantılı Katmanı (Fully Connected Layer)

Tam bağlantılı katman genellikle son katman olarak kullanılırlar. Girdiler, RNN modellerinde RNN katmanlarından geçtikten sonra tam bağlantılı katmana verilirler. Her bir girdi kendine bağlı çıktı nöronlarıyla tamamen bağlıdır. Tam bağlantılı katmanın matematiksel işlevi, girdileri almak ve her bir girdiyi önceden belirlenmiş ağırlıklarla çarpmak, ardından bias eklemek ve son olarak aktivasyon fonksiyonunu uygulamaktır (Nielsen, 2015). Tam bağlantı katmanının amacı, sınıflandırma ve regresyon gibi sonuç üretmektir. Şekil 3.13’ te tam bağlantılı katmanın mimari yapısı gösterilmektedir.




Şekil 3.13. Tam Bağlantılı Katman Yapısı

3.4.4. ReLu Aktivasyon Fonksiyonu

Derin öğrenme mimarilerinde sıkça kullanılan bir aktivasyon fonksiyonudur. Girdi olarak aldığı değerin 0’ dan küçük olması durumunda çıkış olarak 0 verir. Eğer girdi 0’ dan büyük olması durumunda ise girdiyi doğrudan çıkış olarak verir. Çizelge 3.14’ te ReLu fonksiyonunun grafiği gösterilmiştir.

$$f(x) = \max(0, x)$$




Şekil 3.14. ReLu Fonksiyonu

3.4.5. Sınıflandırma (Softmax) Katmanı

Softmax katmanı sınıflandırma problemlerinde kullanılan bir aktivasyon fonksiyonudur. Temel amacı girdi olarak aldığı değerleri normalleştirerek, her bir sınıf için $[0,1]$ arasında olasılık değeri hesaplamaktır. Bu sayede bir girdinin hangi sınıfa ait olma olasılığını gösteren çıktılar elde edilir. Genellikle son katman olarak kullanılır. Şekil 3.15’ te softmax katmanının örnek olasılık değerleri gösterilmiştir.

$$\sigma(\vec{Z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.15)$$



Şekil 3.15. Sınıflandırma Katmanı

$\vec{Z}$ = Softmax fonksiyonunun girdi vektörü


Z_i = Girdi vektörünün girdi değerleri

e^{Z_i} = Girdi vektörünün her öğesine uygulanan eksponansiyel fonksiyon

K = Çoklu sınıflayıcılardaki sınıf sayısı

$$\sum_{j=1}^K e^{Z_j} = \text{Normalizasyon}$$

3.16



Şekil 3.16. Softmax Fonksiyonu

3.5. Önerilen Model

Önerdiğimiz model, buzağılama gününü ve buzağılamadan önceki son 4 saati tahmin için kullanılan bir yapıdır. Önerilen modelin temelinde, zaman serilerinde sıklıkla kullanılan kalman filtresi ve RNN mimarilerinden LSTM, Bi-LSTM ve GRU modelleri birlikte kullanılmıştır. Saatlik tahmin için önerilen iş akışı Şekil 3.17’de gösterilmektedir.


1.Adım	a) Saatlik Gözlem b) Verinin İkili Sistem Çevrimi
2.Adım	c) Kalman Filtresi Uygulanması d) Normalizasyon
3.Adım	e) K-Fold Cross Validation (Eğitim ve Test olarak 2'ye ayrılması)
4.Adım	f) Bi-LSTM Sınıflandırıcının Eğitilmesi
5.Adım	g) Buzağılamadan Önceki Son 4 Saati Tahmini

Şekil 3.17. Saatlik Tahmin İçin Akış Şeması


1.Adım: 53 süt sığırı verilerinden parametrelerin seçimi yapıp veriler uygun forma dönüştürülerek ön işlem gerçekleştirilmiştir. Saatlik veri setinde verilerin ortalama saatteki adım sayıları, ayakta geçirilen süre, yatarak geçirilen süre, yatma nöbet sayıları, toplam hareket değişkeni olmak üzere 5 farklı değişken girdi parametresi olarak kullanılmıştır. Hayvanların buzağılamadan önceki son 24 saatlik verileri 13 peryot olacak şekilde 2 saatlik dilimler halinde organize edilmiştir. Buzağılama kısa süren bir durum olmadığı için buzağılama başlangıcı ve bitişi ortalama 4 saat olarak hesaplanmıştır. Buradan hareketle 13 saat diliminin 2'sini 1 olarak diğer 11 saat dilimini 0 olarak etiketliyoruz. Dolayısıyla 1 olarak etiketlenen zaman dilimlerini “buzağılama başladı” ve 0 olarak etiketlenen zaman dilimleri ise “buzağılama başlamadı” şeklinde ifade edilmiştir.

2.Adım: Sensör ve ivmeölçerlerden toplanan verilerin hata ve gürültüleri minimuma indirmek için kalman filtresini kullandık. Kalman filtresinin çalışma prensibinde önceki adımlardan yararlandığı verilerden tahmin yapar ve ölçülen değerle kıyaslar ve hata değerini kullanarak güncelleme yapar. Kalman katsayısı 1' e ne kadar yakın olursa düzeltme o kadar az olur. Çalışmada kalman filtresi kullanarak, ani tepelerin yarattığı gürültüyü azaltmak veya alakasız özellik değerleriyle eğitilmesini engellemiş oluruz

(Deepika ve Bhat, 2021). Şekil 3.18 ve 3.19’ da buzağılamadan önceki son 72 saati içeren ham verilere kalman filtresinin farklı kalman katsayılarıyla uygulanmış karşılaştırılması mevcuttur. Kalman filtresi sayesinde veriler daha istikrarlı hale gelmiştir.



Şekil 3.18. Kalman Katsayısı 0.01



Şekil 3.19. Kalman Katsayısı 0.001

Kalman filtresini uyguladıktan sonra verileri Z-score normalizasyonu yaparak farklı ölçütlerdeki veriler tek tip veriye dönüştürdük. Çizelge 3.4’ te verilerimizin normalize edilmemiş hali, Çizelge 3.3’ te verilerin normalize edilmiş hali görülmektedir.

Çizelge 3.3. Buzağılamadan önceki son 24 Saatlik Verilere Z-score Normalize uygulanmış


Buz. Kalan Zaman	Toplam Hareket	Adım Sayısı	Ayakta Durma Süresi	Yatma Süresi	Yatma sıklığı
24	1.534	1.582	-0.015	0.015	-0.678
22	1.441	1.508	-0.117	0.117	-0.571
20	1.212	1.276	-0.183	0.183	-0.503
18	0.639	0.755	-0.569	0.569	-0.269
16	0.397	0.519	-0.387	0.387	-0.119
14	0.03	0.139	-0.657	0.657	0.166
12	-0.13	-0.083	-0.658	0.658	0.717
10	-0.532	-0.518	-1.089	1.089	1.26
8	-0.744	-0.791	-1.236	1.236	1.697
6	-0.752	-0.836	-1.073	1.073	2.067
4	-0.794	-0.924	-1.312	1.312	2.583
2	-0.168	-0.381	-1.38	1.38	2.914
0	1.692	2.102	-3.615	3.615	2.112

Çizelge 3.4. Buzağılamadan önceki son 24 Saatlik Verilerin Normalizasyon Uygulanmamış Hali

Buz. Kalan Zaman	Toplam Hareket	Adım Sayısı	Ayakta Durma Süresi	Yatma Süresi	Yatma sıklığı
24	355.17	88	1.51	0.49	0.58
22	338.58	83.17	1.51	0.49	0.58
20	296.83	73.42	1.43	0.57	0.75
18	309.17	76	1.53	0.47	0.75
16	288.42	70	1.44	0.56	0.92
14	295.83	70.58	1.48	0.52	1.25
12	266.5	62.92	1.38	0.62	1.42
10	271.08	63.08	1.41	0.59	1.5
8	283.5	66.5	1.47	0.53	1.58
6	280	64.92	1.39	0.61	1.83
4	343.92	80.67	1.41	0.59	1.83
2	486.75	136.58	0.9	1.1	0.92
0	451.67	123.75	0.9	1.1	0.92

3.Adım: Veri setinin daha iyi bir şekilde kullanılması için K-kat çapraz doğrulama yöntemi kullanılmıştır. Veri setindeki hayvan sayımız 4 eşit parçaya bölünerek her bir döngüde 3 birim eğitim 1 birim test seti olarak kullanılmıştır. K-kat çapraz doğrulama sayesinde, ezberleme ve aşırı genelleştirmelerinde önüne geçmiş oluruz. Veri seti dolaylı olarak %75 eğitim %25 test seti olarak 2' ye ayrılmıştır.


4.Adım: Şekil 3.20' de önerilen modele göre giriş verilerinin ön işleme tamamlandıktan sonra 128 hücreli bir GRU katmanı içeren bir yapı oluşturulmuştur. Bu katmandan elde edilen çıktı, özellik çıkarımı için 256 hücreli bir Bi-LSTM katmanını beslemek için kullanılmıştır. Daha sonra, negatif değerleri sıfıra dönüştürmek ve pozitif değerleri değiştirmeden bırakmak için ReLu aktivasyon fonksiyonunun uygulandığı sınıflandırma için tam bağlı bir katman kullanılmıştır. Yapı, önceki katmanlarda keşfedilmeyen farklı özellikleri öğrenmek için yeniden oluşturulmuş, böylece daha karmaşık bir model elde edilmiş ve daha yüksek doğruluk elde edilmiştir. Aşırı uyumu azaltmak için, eğitim sırasında dropout (%20) kullanılmış ve modelin çeşitli özellikleri öğrenmesini sağlamak için her adımda rastgele seçilen %20'lik bir nöron alt kümesi devre dışı bırakılmıştır. Eğitim sürecinde kullanılmak üzere Learningrate = 0.02 başlangıç öğrenme oranı, iterasyon başına 64 örneklik minibatch boyutu, 1 eşik değeri ve 600 epok belirlenmiştir. Softmax katmanı, tahmin edilen sınıf için olasılık değerleri üretmiş ve bunlardan en yüksek olasılığa sahip olan sınıf, girdi örneğinin sınıfını tahmin etmek için seçilmiştir.



Şekil 3.20. Önerilen Model Mimarileri


En ideal modeli kurarken alternatif yöntemler denenmiş ve test değerleri kayıt altına alınmıştır. Şekil 3.21. - 3.24 'te alternatif modellerin mimarileri gösterilmiştir.

Şekil 3.21' de önerilen modelin GRU katmanı çıkarılarak farklı bir modele geçilmiştir ve bu yeni modele ait performans ölçümleri yapılmıştır.




Şekil 3.21. Modelin GRU katmanı çıkarılmış hali

Alternatif yöntemlerden bir diğeri olan Şekil 3.22' de ise sadece tek RNN katmanlarından oluşan tekrarsız bir model önerilmiş ve ölçümler yapılmıştır.



Şekil 3.22. Tek Katmanlı RNN Tabanlı Model

Önerilen alternatif model, Şekil 3.23’ te gösterildiği gibi sadece GRU katmanının kullanıldığı bir RNN modelidir.



Şekil 3.23. GRU Kullanılarak Oluşturulan Model

Şekil 3.24. te gösterilen alternatif model, daha fazla özellik çıkarmak için GRU ve Bi-LSTM mimarilerini kullandığımız bir yapıdır.



Şekil 3.24. Üç RNN Yapısı Oluşturulmuş Model

Çalışmada Şekil 3.20. – Şekil 3.24’ te gösterilen ve birçok model test edilmiş olup sonuçları kayıt altına alınmıştır.

4. BULGULAR ve TARTIŞMA


Bu çalışmada, kalman filtresi ve derin öğrenme yöntemleri kullanılarak, tarım ekonomisi için önem taşıyan süt sığırlarının buzağılama zamanı tahmin edilmiştir. Önerdiğimiz modelin başarı metrikleri Çizelge 4.1’ de gösterilmiştir. Buzağılamadan önceki son 24 saat 2 saatlik zaman dilimleri halinde 0 (buzağılama gerçekleşmiyor) ve 1 (buzağılama gerçekleşiyor) olarak etiketlenmiştir. Test veri setinde her bir hayvan için 0 sınıfına ait 11 üye ve 1 sınıfına ait 2 üye bulunmaktadır. Üyeler 2 saatlik zaman dilimlerini ifade etmektedir. Çizelge 4.1’ de hassaslık değeri bizim buzağılama zamanını ne kadar doğrulukla tahmin ettiğimizi gösterir. Doğruluk değeri ise 0 ve 1 olarak sınıflandırılan zaman dilimlerinin tamamının ne kadar doğrulukla tahmin edildiğini ifade etmektedir. Çizelge 4.1’ de tablodaki 0 sütunu buzağılamanın olmadığı 1 sütunu ise buzağılamanın gerçekleştiği zaman dilimlerinin doğruluk tahmin performansını göstermektedir. Test setinde 0 sınıfının üyeleri çoğunlukta olduğu için modelin 1 sınıfını yüksek doğrulukla tahmin etme gücü bizim için daha fazla önem arz etmektedir. Çizelge 4.1’ de 1 sınıfını tahmin etme veya hassaslık metriğinin performansına bakmak daha doğru olacaktır. Önerilen modelin ortalama doğruluk oranı %95’ tir. 1 sınıfını bir başka deyişle “buzağılama zamanı” olarak etiketlediğimiz zaman dilimini doğru tahmin etme başarısı ise %93 olarak tespit edilmiştir.

Buna göre modelde süt sığırlarının ortalama % 95 doğruluk oranıyla buzağılamadan önceki son 4 saati başarıyla tahmin edilmiştir.

Çizelge 4.1. Önerilen modelin detaylı başarı metrikleri


	Hassaslık (Precision)	Doğruluk (Accuracy)	Kappa Uyumu	Duyarlılık (Recall)	F Ölçüsü (F ₁ -score)	0	1
1.KAT	0.93	0.97	0.88	0.87	0.96	0.94	0.93
2.KAT	0.86	0.95	0.72	0.80	0.91	0.96	0.86
3.KAT	1.00	0.93	0.78	0.70	1.00	0.92	1.00
4.KAT	0.93	0.96	0.84	0.81	0.96	0.96	0.92
ORTALAMA	0.93	0.95	0.81	0.79	0.96	0.94	0.93

Şekil 4.1’ de 1.kat çapraz doğrulamada elde edilen sonuçlar grafiğe aktarılmıştır. 1. Kat da 1 olarak etiketlenen 14 değerden sadece birini bilemediği gösterilmiştir. Doğru tahmin edemediği hayvanın numarası 6 olarak gözlemlenmektedir.



Şekil 4.1. Buzağılama Tahmin Grafiği


Önerilen modelin eğitim sırasındaki başarı ve hata grafiği Şekil 4.2’ de verilmiştir.




Şekil 4.2. Önerilen Modelin Ortalama Başarı-Hata Grafiği

Karışıklık matrisi modelin doğru ve yanlış tahminleri hakkında bilgi verir. Çizelge 4.2’ de önerilen modelin karışıklık matrisi gösterilmiştir. Buzağılama kavramını pozitif olarak nitelendirdiğimiz için TP kavramı, buzağılamanın doğru bir şekilde tahmin edildiği TN kavramı ise buzağılama olmayacağını doğru bir şekilde tahmin ettiği durumu ifade eder. Önerilen modelde Çizelge 4.2’ de gösterildiği gibi 28 süt sığırının buzağılama zamanını sadece 1 hayvan için doğru olarak tahmin edilememiştir. TP olarak ifade edilen, buzağılama zamanını doğru tahmini %92.9 doğruluk oranına sahiptir. TN olarak ifade edilen buzağılamanın gerçekleşmediği durum tahmini ise %94.8 doğruluk oranına sahiptir. Veri setinde kategorik olarak ifade edilen zaman kavramları homojen olarak dağılmadığı için başarı metriklerini detaylı olarak incelenmiş olup modelimiz için en doğru kavramın hassaslık başarı metriği olduğu tespit edilmiştir. Modelin toplam başarısından daha çok buzağılama zamanı olarak etiketlenen zaman diliminin doğru tahmin edilmesi daha önemlidir. Dolayısıyla modelin başarısını doğru olarak ifade etmek için hassaslık başarı metriği daha öne çıkmaktadır.

Çizelge 4.2. Önerilen Modelin Karışıklık Matrisi



Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.3’ te verilmiştir. ROC eğrisi altında kalan alanlar incelendiğinde, önerilen modelin buzağılama zamanını doğru tahmin etme oranının diğer alternatif modellere göre daha yüksek olduğu gözlemlenmektedir.



Şekil 4.3. Önerilen Modelin ROC Eğrisi


Şekil 3.20. - 3.24. 'de göstermiş olduğumuz modeller ve diğer test ettiğimiz modellerin performansının karşılaştırılması gerçekleştirilmiştir ve önerilen modelin alternatif modellere göre daha başarılı performans gösterdiği anlaşılmıştır. Alternatif modellerden elde edilen bulgular incelendiğinde Şekil 3.21' de GRU katmanı çıkarılarak yaptığımız testlerde başarı oranının önerilen modele göre yaklaşık %3 düştüğü gözlemlenmiştir. Şekil 3.22' de RNN tabanlı mimarileri tek katman olarak kullandığımız modelde daha az özellik çıkarımı yapabildiği için modelin başarısı önerilen modele göre yaklaşık %16 oranında düşmüştür. Şekil 3.23. 'te RNN mimarilerinden sadece GRU katmanı kullanılarak yapılan modelin başarısı önerilen modele göre % 33 daha düşüktür. Şekil 3.24' te RNN mimarilerini artırarak daha fazla özellik çıkarımı yapılabilir mi diye yaptığımız testlerde başarı metriklerinde herhangi bir gelişme olmadığı gözlemlenmiştir. Dolayısıyla RNN yapıları arttıkça başarının artmayacağı önerilen modelin ideal bir yapı olduğu gözlemlenmiştir. Çizelge 4.3' te diğer alternatif modellerin, önerilen modele kıyasla başarı performansları gösterilmiştir.

Çizelge 4.3. Diğer Modellerin Önerilen Modele Göre Başarı Durumu

MODEL	BAŞARI
KALMAN+Bi-LSTM+GRU (Önerilen Model)	
KALMAN+Bi-LSTM	% -3
KALMAN+GRU	% -7
KALMAN+LSTM	% -11
TEK KATMANLI RNN TABANLI DERİN YAPI	% -16
BiLSTM	% -22
LSTM+GRU	% -24
LSTM	% -28
GRU	% -33
Bi-LSTM+GRU	% -34

Çizelge 4.4’ te testi yapılan bütün modellerin hassaslık grafiği gösterilmiştir. Kalman filtresinin, modeller üzerinde ortalama % 23 pozitif etkisi görülmüştür. Kalman filtresi, buzağılama zamanını tahmin etmede, RNN tabanlı derin öğrenme modellerine katkı sağlamıştır. Buzağılamadan önceki son 4 saati tahmin etmek en yüksek doğruluk payına sahip önerilen model, kalman filtresi, GRU ve Bi-LSTM modellerinin birlikte kullanılmasıyla elde edilmiştir. Kalman filtresinin zaman serileri üzerindeki etkisi Çizelge 4.4’ te gösterilmiştir. Kalman filtresi sayesinde test edilen modellerin tamamında doğruluk bakımından iyileşme olmuştur. Aynı zamanda kalman filtresi çalışma zamanı bakımından da modellere pozitif bir etki yapmıştır. GRU katmanı, yapısından dolayı LSTM ve Bi-LSTM modeline göre daha hızlı olmasının yanı sıra bu modellerle birlikte kullanıldığında performans bakımından yukarı yönlü etkisi gözlemlenmiştir. RNN modellerin tek kullanılmasından daha çok birlikte kullanılmasıyla performans açısından pozitif yönlü bir iyileşme olmuştur.

Çizelge 4.4. Modellerin Performans Karşılaştırması



Çizelge 4.5’ te önerdiğimiz modele alternatif oluşturduğumuz modellerin başarı metrikleri detaylı gösterilmiştir. Önerilen modelin sonuçlarını inceleyecek olursak; çalışma zamanı olarak en uzun süreye sahip olsa da başarı performansı açısından en iyi değerlere sahiptir. Bütün sınıfların performansına bakarken hassaslık başarı metriği sadece buzağılama zamanının doğru olarak tahmin edildiği sınıfı hesaplamada yardımcı olmaktadır. Çizelgede 4.5’ te 0 ve 1 değerlerine göre 1 sınıfını % 93, 0 sınıfını %94 doğrulukla tahmin edildiği gösterilmiştir. Test sütunundaki değer ise 0 ve 1 değerlerin toplam doğru tahmin edilme oranını ifade etmektedir. TP ve FP değerleri 1 olarak etiketlediğimiz zaman dilimlerindeki doğru ve yanlış tahmin sayılarını göstermektedir. Test veri setimiz 14 tane 1 sınıfından oluşmaktadır, model 13 tanesini doğru tahmin etmiş 1 tanesini ise 0 olarak yanlış tahmin etmiştir. Veri seti test sınıfı 77 tane 0’dan oluşmaktadır, önerdiğimiz model ortalama olarak aldığımız için 73.50 zaman dilimi olan 0 sınıfını doğru tahmin etmektedir. Ortalama 3.50 tane 0 sınıfını bilememiştir.

Çizelge 4.5. Modellerin Detaylı Performansları


Modeller	Precision	Accuracy	Kappa	Recall	Fscore	0	1	Train	Test	TP	FP	TN	FN	Süre(sn)
KALMAN+Bi-LSTM+GRU (Önerilen Model)	0.93	0.95	0.81	0.79	0.96	0.94	0.93	0.97	0.94	13.00	1.00	73.50	3.50	220
KALMAN+Bi-LSTM	0.91	0.94	0.81	0.78	0.94	0.95	0.91	0.98	0.94	12.75	1.25	73.50	3.50	188
KALMAN+GRU	0.87	0.94	0.80	0.80	0.92	0.96	0.87	0.98	0.94	12.25	1.75	74.00	3.00	54.50
KALMAN+LSTM	0.83	0.90	0.69	0.67	0.89	0.92	0.83	0.99	0.90	11.67	2.33	71.33	5.67	67.70
TEK KATMANLI RNN TABANLI DERİN YAPI	0.78	0.93	0.75	0.79	0.86	0.96	0.62	0.99	0.93	11.00	3.00	74.00	3.00	195.25
BİLSTM	0.73	0.90	0.65	0.67	0.82	0.93	0.73	0.96	0.90	10.25	3.75	72.00	5.00	211
LSTM+GRU	0.71	0.90	0.63	0.68	0.80	0.93	0.71	0.94	0.90	10.00	4.00	72.33	4.67	176
LSTM	0.68	0.89	0.59	0.64	0.78	0.93	0.68	0.97	0.89	9.50	4.50	71.75	5.25	112.50
Bi-LSTM+GRU	0.62	0.90	0.58	0.66	0.73	0.95	0.62	0.97	0.90	8.75	5.25	73.25	4.50	235
SADECE GRU	0.62	0.89	0.57	0.65	0.74	0.94	0.62	0.95	0.89	8.75	5.25	72.25	4.75	63

4.1. Kalman + Bi-LSTM Model Sonuçları

Çizelge 4.6’ da Kalman filtresiyle birlikte Bi-LSTM modelini kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 51 tanesini doğru, "0" sınıfındaki üyelerin ise 294 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı için başarı performansı Çizelge 4.7.’ de gösterilmiş olup %91 doğrulukla tahmin etmiştir.

Yapılan testler sonucunda, Çizelge 4.7’ de oluşturulan modelin tahmin performansı gösterilmektedir.

Çizelge 4.6. Kalman + Bi-LSTM Modelinin Karışıklık Matrisi




Çizelge 4.7’ de alternatif modelin başarı değerlendirilmesinde kullanılan hassaslık(kesinlik), doğruluk, duyarlılık ve F1 skor verilmiştir.

Çizelge 4.7. Kalman + Bi-LSTM Modelinin Başarı Değerlendirilmesi

Model	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
KALMAN+ Bi-LSTM	0.91	0.94	0.78	0.94

Modelin daha iyi deęerlendirilmesi iin ROC eęrisi ekil 4.4’ te verilmiřtir.




ekil 4.4. Kalman+ Bi-LSTM Modelinin ROC Eęrisi

4.2. Kalman + GRU Model Sonuları

izelge 4.8’ de Kalman filtresiyle birlikte RNN tabanlı GRU modelini kullanarak oluřturduęumuz modelin karıřıklık matrisi verilmiřtir. Karıřıklık matrisi incelendięinde, toplam 364 zaman dilimi zerinde test yapılmıřtır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki yelerin 49 tanesini doęru, "0" sınıfındaki yelerin ise 296 tanesini doęru ekilde tahmin edilmiřtir. Buna gre, "1" olarak etiketlenen buzaęılama zamanı iin bařarı performansı izelge 4.9’ da gsterilmiř olup %87.5 doęrulukla tahmin edilmiřtir.

Yapılan testler sonucunda, izelge 4.9’ da oluřturulan modelin tahmin performansı gsterilmektedir.

Çizelge 4.8. Kalman + GRU Modelinin Karışıklık Matrisi




Çizelge 4.9’ da alternatif modelin başarı değerlendirilmesinde kullanılan hassaslık(kesinlik), doğruluk, duyarlılık ve F1 skor verilmiştir.

Çizelge 4.9. Kalman + GRU Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
KALMAN+GRU	0.87	0.94	0.80	0.92

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.5’ te verilmiştir




Şekil 4.5. Kalman + GRU Modelinin ROC Eğrisi

4.3. Kalman + LSTM Model Sonuçları

Çizelge 4.10’ da Kalman filtresiyle birlikte RNN tabanlı LSTM modelini kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 47 tanesini doğru, "0" sınıfındaki üyelerin ise 286 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı için başarı performansı Çizelge 4.11’ de gösterilmiş olup %83.9 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.11’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.10. Kalman + LSTM Modelinin Karışıklık Matrisi



Çizelge 4.11. Kalman + LSTM Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
KALMAN+LSTM	0.83	0.90	0.67	0.89

Modelin daha iyi deęerlendirilmesi için ROC eęrisi Şekil 4.6’ da verilmiştir.




Şekil 4.6. Kalman + LSTM Modelinin ROC eğrisi

4.4. Tek Katmanlı RNN Tabanlı Derin Yapı Model Sonuçları

Önerdiğimiz modelde daha fazla özellik çıkarsın diye RNN tabanlı modeller 2 kez kullanılmıştır. Çizelge 4.12’ de önerilen modele alternatifi olan ve bir kez kullanılan RNN tabanlı modellerin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 44 tanesini doğru, "0" sınıfındaki üyelerin ise 296 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı örnekleri için başarı performansı Çizelge 4.13’ de gösterilmiş olup %78.6 doğrulukla olarak tahmin edilmiştir. Derin öğrenme modellerinde, aktivasyon fonksiyonları değiştirilerek ve daha fazla gizli katman kullanılarak uygulamanın başarısını arttırmak mümkündür (Çevik ve Zengin, 2019). Yapılan testler sonucunda, Çizelge 4.13’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.12. Tek Katmanlı RNN Modelinin Karışıklık Matrisi



Çizelge 4.13. Tek Katmanlı RNN Tabanlı Modelin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
TEK KATMANLI RNN TABANLI DERİN YAPI	0.78	0.93	0.79	0.86

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.7’ de verilmiştir.




Şekil 4.7. Tek Katmanlı RNN Tabanlı Modelin ROC Eğrisi

4.5. Bi-LSTM Model Sonuçları

Çizelge 4.14’ te sadece Bi-LSTM derin öğrenme modelini kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 41 tanesini doğru, "0" sınıfındaki üyelerin ise 288 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı dilimleri için başarı performansı Çizelge 4.15’ de gösterilmiş olup %73.2 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.15’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.14. Bi-LSTM Modelinin Karışıklık Matrisi



Çizelge 4.15. Bi-LSTM Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
Bi-LSTM	0.73	0.90	0.67	0.82

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.8’ de verilmiştir.




Şekil 4.8. Bi-LSTM Modelinin ROC eğrisi

4.6. LSTM+GRU Model Sonuçları

Çizelge 4.16’ da LSTM + GRU derin öğrenme modellerini birlikte kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 40 tanesini doğru, "0" sınıfındaki üyelerin ise 288 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı dilimleri için başarı performansı Çizelge 4.17’ de gösterilmiş olup %71.4 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.17’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.16. LSTM + GRU Modelinin Karışıklık Matrisi



Çizelge 4.17. LSTM + GRU Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
LSTM+GRU	0.71	0.90	0.68	0.80

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.9’ da verilmiştir.




Şekil 4.9. LSTM + GRU Modelinin ROC eğrisi

4.7. LSTM Model Sonuçları

Çizelge 4.18’ de LSTM derin öğrenme modelini kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 38 tanesini doğru, "0" sınıfındaki üyelerin ise 287 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı dilimleri için başarı performansı Çizelge 4.19’ da gösterilmiş olup %67.9 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.19’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.18. LSTM Modelinin Karışıklık Matrisi



Çizelge 4.19. LSTM Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
LSTM	0.68	0.89	0.64	0.78

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.10’ da verilmiştir.




Şekil 4.10. LSTM Modelinin ROC eğrisi

4.8. Bi-LSTM + GRU Model Sonuçları

Çizelge 4.20' de Bi-LSTM ve GRU derin öğrenme modellerini birlikte kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 35 tanesini doğru, "0" sınıfındaki örneklerin ise 293 tanesini doğru şekilde tahmin etmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı dilimleri için başarı performansı Çizelge 4.21' de gösterilmiş olup %62.5 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.21' de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.20. Bi-LSTM + GRU Modelinin Karışıklık Matrisi



Çizelge 4.21. Bi-LSTM+GRU Modelinin Başarı Değerlendirilmesi

Modeller	Hassaslık	Doğruluk	Duyarlılık	F1 Skor
Bi-LSTM+GRU	0.62	0.90	0.66	0.73

Modelin daha iyi değerlendirilmesi için ROC eğrisi Şekil 4.11' de verilmiştir.




Şekil 4.11. Bi-LSTM + GRU Modelinin ROC eğrisi

4.9. GRU Model Sonuçları

Çizelge 4.22’ de GRU derin öğrenme modelini kullanarak oluşturduğumuz modelin karışıklık matrisi verilmiştir. Karışıklık matrisi incelendiğinde, toplam 364 zaman dilimi üzerinde test yapılmıştır. Bu zaman dilimlerinden 56 tanesi "1" sınıfına, 308 tanesi ise "0" sınıfına aittir. Model, "1" sınıfındaki üyelerin 35 tanesini doğru, "0" sınıfındaki üyelerin ise 289 tanesini doğru şekilde tahmin edilmiştir. Buna göre, "1" olarak etiketlenen buzağılama zamanı dilimleri için başarı performansı Çizelge 4.23’ de gösterilmiş olup %62.5 doğrulukla tahmin edilmiştir.

Yapılan testler sonucunda, Çizelge 4.23’ de oluşturulan modelin tahmin performansı gösterilmektedir.


Çizelge 4.22. GRU Modelinin Karışıklık Matrisi



Çizelge 4.23. GRU Modelinin Başarı Değerlendirilmesi


Modeller	Hassashk	Doğruluk	Duyarlılık	F1 Skor
GRU	0.62	0.89	0.65	0.74

Modelin daha iyi deęerlendirilmesi iin ROC eęrisi Őekil 4.12’ de verilmiřtir. Őekil 4.12’ de ROC eęrisi altında kalan alan incelendięinde, modelin en kk AUC deęerine sahip olduęu dolayısıyla bařarı performansının dřk olduęu gzlemlenmiřtir.




Őekil 4.12. GRU Modelinin ROC eęrisi

alıřmada nerilen model ve alternatif modellerin Hassaslık performanslarının karřılařtırılması Őekil 4.13’ te gsterilmiřtir




Őekil 4.13. Modellerin Hassaslık Performansları

Çalışmada önerilen model ve alternatif modellerin Duyarlılık performanslarının karşılaştırılması Şekil 4.14’ te gösterilmiştir




Şekil 4.14. Modellerin Duyarlılık Performansları

Çalışmada önerilen model ve alternatif modellerin Doğruluk performanslarının karşılaştırılması Şekil 4.15’ te gösterilmiştir



Şekil 4.15. Modellerin Doğruluk Performansları

Çalışmada önerilen model ve alternatif modellerin F₁-Skor performanslarının karşılaştırılması Şekil 4.16’ da gösterilmiştir



Şekil 4.16. Modellerin F₁-Skor Performansları

Önerilen modelin sonuçları incelendiğinde, süt sığırlarının davranışsal farklılıklarının, buzağılamadan önceki son 4 saati tespit etme de önemli rol oynadığını göstermektedir. Önerilen modelin, buzağılamadan önceki son 4 saati % 93 doğrulukla tahmin edebildiğini göstermiştir. Önerilen model çalışma esnasında geliştirilen alternatif modellere kıyasla daha yüksek performans gösterdiği gözlemlenmiştir. Önerilen modelin, literatürdeki çalışmalarla karşılaştırıldığında geliştirilen yöntemlere göre bir gelişmedir. Önerilen modelin %95 doğruluk oranına sahip %93 hassaslık değerine sahip olduğu göz önüne alınırsa buzağılama zamanının yüksek doğrulukla tahmin edildiği gözlemlenmiştir.

Çizelge 4.24. Literatürdeki Çalışmaların Karşılaştırılması

Saat	Yazar	Sınıflandırıcı	Duyarlılık(Se)	Özgüllük(Sp)	PPV	NPV	Hassaslık(Pr)
<4	Önerilen Model	Kalman+BiLstm	79%	99%	93%	95%	93%
<3	Liseune ve ark. (2021)	Cnn-lstm	57%	85%	85%		49%
<8	Keceli ve ark. (2020)	Rusboosted Tree	66%	95%	89%	82%	

<8	Borchers ve ark. (2017)	Neural Network	82%	80%	69%	90%
<8	Borchers ve ark. (2017)	Linear discriminant analysis	76%	75%	61%	85%
<8	Borchers ve ark. (2017)	Random Forest	72%	82%	68%	85%
<3	Rutten ve ark. (2017)	Logistic Regression	42%	99%		
<24	Ouellet ve ark. (2016)	Logistic Regression	71%	71%	16%	97%

Önerilen model, diğer yöntemlere göre çeşitli avantajlar sunmaktadır. İlk olarak, daha doğru sonuçlar üretmektedir. Bu doğruluk, kalman filtresi gibi özyinelemeli bir filtrenin kullanılması sayesinde sağlanmaktadır. Kalman filtresi, en son bilgileri kullanarak durum tahminini güncelleyen bir filtredir ve diğer yöntemlerden daha doğru sonuçlar vermektedir.

İkinci olarak, önerilen model daha verimlidir. Bu verimlilik, Bi-LSTM derin öğrenme modelinin kullanılmasıyla elde edilmektedir. Bi-LSTM derin öğrenme modeli, uzun vadeli bağımlılıkları öğrenebilmesi sayesinde diğer derin öğrenme modellerinden daha verimlidir.

Üçüncü avantajı ise esnekliktir. Önerilen model, farklı tiplerde verilerle çalışabilen ve farklı özellikler eklenerek iyileştirilebilen bir yapıdadır. Bu sayede, değişen ihtiyaçlara uygun şekilde adapte olabilmektedir.

Son olarak, önerilen model büyük veri kümeleriyle kullanılabildiği için daha ölçeklenebilirdir. Hem Kalman filtresi hem de Bi-LSTM derin öğrenme modeli, büyük veri kümeleriyle kullanılabilecek ölçeklenebilir modellerdir. Bu sayede, önerilen model büyük veri kümeleriyle çalışmakta zorluk çeken diğer modellere göre daha avantajlı hale gelmektedir.

Önerilen model, süt çiftliklerinde verimliliği artırmak amacıyla kullanılabilecektir. Buzağılama zamanının tahmin edilmesiyle birlikte, çiftçiler ineğin ne zaman

buzagılayacağına dair önceden uyarılmış olacaklar. Bu durum, çiftçilerin ineğin güvenli ve sağlıklı bir şekilde doğmasını sağlamak için gerekli adımları atabilmelerine olanak tanıyacaktır.

Ayrıca, önerilen model sayesinde çiftçiler süt çiftliklerinin karlılığını artıracaklardır. Buzagılama zamanının tahmin edilmesi ile birlikte çiftçiler, ineğin ne zaman doğuracağı hakkında bilgi sahibi olacaklar ve buna göre satış ya da üreme planlarını yapabileceklerdir.

Önerilen model, buzagılama zamanı tahmini için önceki yöntemlere göre önemli bir gelişmedir. Önerilen model diğer yöntemlere göre daha doğru, daha verimli, daha esnek ve daha ölçeklenebilirdir.

5. SONUÇ VE ÖNERİLER

Son zamanlarda yapay zeka alanında yaşanan gelişmeler, insanlar kadar diğer canlılarında hayatlarına da önemli derecede katkı sağlamaktadır. Yapay zeka yöntemleriyle tahmin ve sınıflandırma üzerine yapılan çalışmalarında elde edilen başarılar umut verici niteliktedir.

Süt sığırcılığında buzağılama zamanı tahminini gerçekleştirdiğimiz bu tez çalışmasında, önerdiğimiz model geliştirilen alternatif modellere ve literatürde ki diğer tahmin yöntemlerine göre daha başarılı performans gösterdiği tespit edilmiştir. Buzağılama zamanı tahmini için önerdiğimiz modelin yüksek başarıya ulaşmasında Bi-LSTM derin öğrenme yöntemlerinin kullanılmasının yanı sıra kalman filtresinin önemli bir yere sahip olduğu gözlemlenmiştir. Önerilen yöntemde değerlendirme kriteri olarak kullandığımız hassaslık değeri %93 gibi bir değerle azımsanamayacak kadar yüksek bir başarıya ulaşmıştır. Çalışma kapsamında veri setinin büyüklüğünün etkisini azaltmak için çapraz doğrulama yöntemiyle modelde aşırı uyumun önüne geçilmiştir. Böylece modelin daha doğru sonuçlar vermesine olanak sağlanmıştır.

Sınırlamalar

Çalışmada 24 saatlik zaman dilimini 2 saatlik periyotlara ayrılmıştır. Buzağılamanın olmadığı zamanı 0 buzağılamanın gerçekleşeceği zaman dilimini 1 olarak etiketlendiğinde dengesiz 0 ve 1 dağılımı gerçekleşmektedir. 1 olarak etiketlenen zaman dilimlerini artırırsak buzağılama tahmin zaman aralığı artacağından tercih edilmemiştir. Alternatif olarak sentetik veri üretme yöntemi göz önüne alındığında 1 olarak etiketlenen zaman dilimlerini çoğaltmak zaman serisinin akışını bozacağından teknik olarak uygun bulunmamıştır.

Gelecek Çalışmalar

Önerilen modelin geliştirilmesi çeşitli yollarla mümkündür. İlk olarak, daha geniş bir veri kümesinde eğitim yapılabilir. Bu, modelin doğruluğunu artırabilir. İkinci olarak, daha fazla inek üzerinde test edilerek sonuçların genelleştirilebilirliği artırılabilir. Üçüncü olarak, gerçek dünya ortamında test edilerek sonuçların uygulanabilirliği artırılabilir.

Bu önerilen model, süt çiftliklerinin verimliliği ve karlılığı için umut verici bir yöntem olarak değerlendirilebilir. Buzağılama zamanının tahmin edilmesi sayesinde, çiftçiler ineğin ne zaman buzağılayacağı konusunda önceden uyarılabilir. Bu da, çiftçilerin ineğin güvenli ve sağlıklı bir şekilde buzağılamasını sağlamak için gerekli önlemleri almasına yardımcı olabilir. Ayrıca, bu önerilen model, ineklerin satılması veya yetiştirilmesi ile ilgili kararlar için de kullanılabilir.

Bu yöntem, diğer yöntemlere göre daha doğru, verimli, esnek ve ölçeklenebilirdir. Dolayısıyla, süt çiftliklerinde kullanılması, çiftliklerin daha verimli ve karlı hale gelmesine katkıda bulunabilir.

Bu yöntem, süt sığırları yetiştiricilerine, doğum öncesinde sağlık durumlarını izlemeleri ve gerekli tedbirleri almaları için önemli bir araç olabilir. Sonuç olarak, bu çalışmada sunulan yöntem, süt sığırlarının buzağılama zamanı tahmininde oldukça başarılı sonuçlar vermiştir. Bu çalışma, süt sığırları yetiştiricilerine, doğum öncesinde daha iyi bir izleme ve tedavi stratejisi geliştirmelerini sağlayacak önemli bir araç sunmaktadır.

6. KAYNAKLAR

- Adem, K., Özgüven, M., & Altaş, Z. (2023). A sugar beet leaf disease classification method based on image processing and deep learning. *Multimedia Tools and Applications*, 12577-12594.
- Andresen, S. (2002). John McCarthy: father of AI. *IEEE Intelligent Systems*, 17(5), 84-85.
- Berglund, B., Philipsson, J., & Danell, ö. (1987). External signs of preparation for calving and course of parturition in Swedish dairy cattle breeds. *Animal Reproduction Science*, 61-79.
- Borchers, M., Chang, Y., Proudfoot, K., Wadsworth, B., Stone, A., & Bewley, J. (2017). Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. *Journal of Dairy Science*, 5664-5674.
- Buzağı Kayıpları. (21-22 Aralık 2017). *Buzağı Kayıpları Sempozyumu*, (s. 3). Kırıkkale.
- Cangar, Ö., Leroy, T., Guarino, M., Vranken, E., Fallon, R., Lenehan, J., . . . 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*, 53-60.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *Computer Science*(1412.3555). <https://doi.org/Doi.org/10.48550/arXiv.1412.3555>
- Cil, A., Yıldız, K., & Buldu, A. (2021). Detection of DDoS attacks with feed forward based deep neural network model . *Expert Systems with Applications*, 169(114520). <https://doi.org/doi:10.1016/j.eswa.2020.114520>
- Çam, E., & Özdağ, M. (2021). Discovery of Course Success Using Unsupervised Machine Learning Algorithms. *Malaysian Online Journal of Educational Technology*, 9(1), 26-47.
- Çevik, E., & Zengin, K. (2019). Classification of Skin Lesions in Dermatoscopic Images with Deep. *European Journal of Science and Technology*(Special Issue), 309-318.
- De Amicis, I., Veronesi, M. C., Robbe, D., Gloria, A., & Carluccio, A. (2018). Prevalence, causes, resolution and consequences of bovine dystocia in Italy. *Theriogenology*, 107, 104-108.

- Deepika, N., & Bhat, M. (2021). An Efficient Stock Market Prediction Method Based on Kalman Filter. *Journal of The Institution of Engineers (India): Series B* , 629-644.
- Fadul, M., Bogdahn, C., Alsaad, M., Hüsler, J., Starke, A., Steiner, A., & Hirsbrunner, G. (2017). Prediction of calving time in dairy cattle. *Animal Reproduction Science*(187), 37-46.
- Gates, M. C. (2013). Evaluating the reproductive performance of British beef and dairy herds using national cattle movement records. *Veterinary Record*, 173(20), 499.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MA: The MIT Press.
- Higaki, S., Koyama, K., Sasaki, Y., Abe, K., Honkawa, K., Minamino, Y., . . . 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*(103), 8535-8540.
- Hinton, G., Srivastava, N., Krizhevsky, A., Sutskever , I., & Salakhutdinov, R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *Computer Science*, 1-18.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 1735-1780.
- Hussain, S., Muhsin, Z., Salal, Y., Theodorou, P., Kurtoğlu, F., & Hazaria, G. (2019). Prediction Model on Student Performance based on Internal Assessment using Deep Learning. *International Journal Of Emerging Technologies In Learning*, 4-22.
- İnik, Ö., & Turan, B. (2018). Classification of Different Age Groups of People by Using Deep. *Journal Of New Results in Science*, 9-16.
- İnik, Ö., & Ülker, E. (2022). Optimization of deep learning based segmentation method. *Soft Computing*, 3329-3344.
- Jonathan, D., & Kung-Sik, C. (2008). *Time series analysis with applications in R*. Springer.
- Keceli, A., Catal, C., Kaya, A., & Tekinerdoğan, B. (2020). Development of a recurrent neural networks-based calving prediction model using activity and behavioral data. *Computers and Electronics in Agriculture*(170), 1-9.
- Lipton, Z., Berkowitz, J., & Elkan, C. (2015). A Critical Review of Recurrent Neural Networks for Sequence Learning. *Computer Science* (1506.00019).

- Liseune, A., Poel, V., Hut, P., Eerdenburg, F., & 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*(191).
- McCulloch, W., & Pitts, W. (1943). McCulloch-Pitts. *Bulletin of Mathematical Biology*, 52(1-2), 99-115. [https://doi.org/doi:10.1016/s0092-8240\(05\)80006-0](https://doi.org/doi:10.1016/s0092-8240(05)80006-0)
- Mee, J. F. (2004). Managing the dairy cow at calving time. *Veterinary Clinics. Food Animal Practice*, 20(3), 521-546.
- Mee, J. F. (2008). Newborn Dairy Calf Management. *Veterinary Clinics of North America: Food Animal Practice*, 1-17.
- Miller, G., Mitchell, M., Barker, Z., Giebel, K., Codling, E., Amory, J., . . . Duthie, C. (2019). Using animal-mounted sensor technology and machine learning to predict time-to-calving in beef and dairy cows. *Animal*, 1-9.
- Namini, S., Tavakoli, N., & Namin, A. (2019). The Performance of LSTM and BiLSTM in Forecasting Time Series. *2019 IEEE International Conference on Big. Los Angeles: IEEE*. <https://doi.org/10.1109/BigData47090.2019.9005997>
- Nielsen, M. (2015). *Neural Networks and Deep Learning*. San Francisco: USA: Determination press.
- Olah, C. (2015, 8 27). <http://colah.github.io/>. github.io: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> adresinden alındı
- Ouellet, V., Vasseur, E., Heuwieser, W., Burfeind, O., Maldague, X., & 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*, 99(2), 1539-1548.
- Peng, Y., Kondo, N., Fujiura, T., Suzuki, T., Ouma, S., Wulandari, . . . Itoyama, E. (2020). Dam behavior patterns in Japanese black beef cattle prior to calving:. *Computers and Electronics in Agriculture*, 169, 1-7.
- Qian, X. (2017). Financial Series Prediction: Comparison Between Precision of Time. *arXiv:1706.00948*, 1-9.
- Rutten, C., Kamphuis, C., Hogeveen, H., Huijps, K., Nielen, M., & 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*(132), 108-118.
- Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P., & Mononen, J. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural Processes*, 56-62.
- Saint-Dizier, M., & Chastant-Maillard, S. (2015). Methods and on-farm devices to predict calving time in cattle. *The Veterinary Journal*, 349-356.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61(2015), 85-117. <https://doi.org/doi:10.1016/j.neunet.2014.09.003>
- Sumi, K., Maw, S., Zin, T., Tin, P., Kobayashi, I., & Horii, Y. (2021). Activity-Integrated Hidden Markov Model to Predict Calving Time. *Animals*, 11.
- Sumi, K., Zin, T., Kobayashi, I., & Hori, Y. (2017). A study on cow monitoring system for calving process. *2017 IEEE 6th Global Conference on Consumer Electronics (GCCE)*. Nagoya, Japan.
- Titler, M., Maquivar, M., Bas, S., Rajala-Schul, P., Gordon, E., McCullough, K., & Schuenemann, G. (2015). Prediction of parturition in Holstein dairy cattle using electronic data loggers. *Journal of Dairy Science*, 98:1–9.
- Węleszczuk, J., Kosinska-Selbi, B., & Cholewińska, P. (2022). Prediction of Polish Holstein's economical index and calving interval using . *Livestock Science* .
- Wright, I., White, I., Russel, A., Whyte, T., & McBean . (1988). Prediction of calving date in beef cows by real-time ultrasonic scanning. *The Veterinary Record*, 228-229.
- Xu, Y., & Zhang, G. (2015). Application of Kalman Filter in the Prediction of Stock Price. *International Symposium on Knowledge Acquisition and Modeling* (s. 197-198). Atlantis Press.
- Yadav, S., & Shukla, S. (2016). Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification. *2016 IEEE 6th International Conference on Advanced Computing*, (s. 78-83).
- Zaremba, W., Sutskever, I., & Vinyals, O. (2014). Recurrent Neural Network Regularization. *Computer Science*.

Zehner, N., Niederhauser, J., Schick, M., & 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*(161), 62-71.



7. ÖZGEÇMİŞ

