



BÜYÜKBAŞ HAYVANLARDA KIZGINLIĞIN (ÖSTRUS)  
HAREKETLİLİK VE ÇEVRE VERİLERİNDEN YARARLANARAK  
YAPAY SİNİR AĞLARI İLE BELİRLENMESİ

**ADİL KORAY YILDIZ**

**DOKTORA TEZİ**

**BİYOSİSTEM MÜHENDİSLİĞİ ANA BİLİM DALI**

**DANIŞMAN:**

**YRD. DOÇ. DR. MEHMET METİN ÖZGÜVEN**

**Haziran - 2016**

**Her hakkı saklıdır**

**T.C.  
GAZIOSMANPAŞA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİYOSİSTEM MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**BÜYÜKBAŞ HAYVANLARDA KIZGINLIĞIN (ÖSTRUS)  
HAREKETLİLİK VE ÇEVRE VERİLERİNDEN YARARLANARAK  
YAPAY SİNİR AĞLARI İLE BELİRLENMESİ**

**ADİL KORAY YILDIZ**

**TOKAT  
Haziran - 2016**

**Her hakkı saklıdır**



**Bu tez çalışması;**

**TÜBİTAK tarafından “MAG 113 R 039” No.lu proje ile desteklenmiştir.**

**Adil Koray YILDIZ** tarafından hazırlanan “**BÜYÜKBAŞ HAYVANLARDA KIZGINLIĞIN (ÖSTRUS) HAREKETLİLİK VE ÇEVRE VERİLERİNDEN YARARLANARAK YAPAY SİNİR AĞLARI İLE BELİRLENMESİ**” adlı tez çalışmasının savunma sınavı 01.06.2016 tarihinde yapılmış olup aşağıda verilen Jüri tarafından oy birliği ile Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü, Biyosistem Mühendisliği Ana Bilim Dalı olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Yrd. Doç. Dr. Mehmet Metin ÖZGÜVEN

.....

Üye

Prof. Dr. Sefa TARHAN

.....

Üye

Doç. Dr. Ufuk TÜRKER

.....

Üye

Yrd. Doç. Dr. Alper TANER


.....

Üye

Yrd. Doç. Dr. Kenan ZENGİN

.....

Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 05.05.2016 tarih ve 17 sayılı kararıyla onaylanmıştır.



Prof. Dr. Mehmet Ali SAKİN

Fen Bilimleri Enstitüsü Müdürü

29.06/20.16

## TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

Adil Koray YILDIZ

1 Haziran 2016

## ÖZET

### DOKTORA TEZİ

# BÜYÜKBAŞ HAYVANLARDA KIZGINLIĞIN (ÖSTRUS) HAREKETLİLİK VE ÇEVRE VERİLERİNDEN YARARLANARAK YAPAY SİNİR AĞLARI İLE BELİRLENMESİ

ADİL KORAY YILDIZ

GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

BİYOSİSTEM MÜHENDİSLİĞİ ANA BİLİM DALI

(TEZ DANIŞMANI: YRD. DOÇ. DR. MEHMET METİN ÖZGÜVEN)

Gıda sanayinin en temel ham maddeleri olan et ve süt üretimi büyük ölçüde büyükbaş hayvancılık ile sağlanmaktadır. Hayvancılıkta karlılığı arttırmak için otomasyonlar gibi iyileştirmeler yapılmaktadır. Hassas sürü yönetim sistemleri bu otomasyonların önemli bir parçasıdır. Bu sistemlerde aranan en önemli özelliklerden birisi etkin üreme yönetiminin sağlanabilmesidir. Bunun için ineklerin kızgınlık (östrus) denilen dönemlerinin belirlenmesi gerekmektedir. Kızgınlıktaki hayvanlar diğer hayvanlara göre daha hareketlidir. Bu hareketlilik “pedometre” denen cihazlarla ölçülebilmektedir. Algılanan hareket değişimleri ile Yapay Sinir Ağları (YSA) modelleri kullanılarak kızgınlık tahmin edileceği düşünülmektedir. Bu çalışmada, hareket ve çevresel veriler kullanılarak büyükbaş hayvanlarda kızgınlığı tahmin edecek bir YSA modelinin oluşturulması ve etkililiğinin incelenmesi amaçlanmıştır. Özel bir tarım işletmesinde dört ay süresince toplamda 186 kızgınlık gösteren 78 sığırın hareket verileri iklimsel verilerle beraber kaydedilmiştir. İneklerin yaşları, laktasyon sayıları, kızgınlıktan sonra geçen gün sayısı verileri de değerlendirmeye alınmıştır. Mekanistik model ve YSA modelleri karşılaştırılmıştır. Bunun için doğruluk, kesinlik, bu ikisinin ortak etkisini belirten F skoru ve ROC analizinden faydalanılmıştır. YSA modeli olarak bir ve iki katmanlı ileri beslemeli sınıflandırma ağları denenmiştir. YSA modeline en uygun girişler hareket verisi, bir önceki zaman dilimine ait hareket verisi, bir önceki kızgınlıktan sonra geçen gün sayısı, sıcaklık ve nem olarak bulunmuştur. Tek katmanlı YSA için en iyi sonuç 0.9654 AUC ile 91 nöronlu ağdan elde edilirken birinci katmanında 37 ikinci katmanında 40 nöronu bulunan çift katmanlı ağ 0.9733 ROC puanıyla en başarılı model olmuştur. Mekanistik model 0.5006 ROC puanı ile en düşük başarıyı göstermiştir. Çalışmada iklim verilerinin hareket verileriyle beraber değerlendirilmesi ile doğru kızgınlık tahmininin arttığı görülmüştür.

2016, 98 SAYFA

**ANAHTAR KELİMELEER:** Kızgınlık Tahmini, Yapay Sinir Ağları, Sınıflandırma, Mekanistik Model

## **ABSTRACT**

### **DOCTORATE THESIS**

**DETERMINATION OF ESTRUS IN CATTLE WITH NEURAL NETWORKS USING  
MOBILITY AND ENVIRONMENTAL DATA  
ADİL KORAY YILDIZ**

**GAZIOSMANPASA UNIVERSITY INSTITUTE OF SCIENCE**

**DEPARTMENT OF BIOSYSTEMS ENGINEERING**

**(SUPERVISOR:) ASST. PROF. DR. MEHMET METİN ÖZGÜVEN**

The most basic raw materials for the food industry, meat and milk production, are provided largely through cattle. Improvements such as automation have been increasing profitability in livestock production. Precision herd management systems are an important part of this automation process. A key feature of such systems is effective reproduction management. To achieve this, one needs to determine cows' heat period (Estrus). Animals in Estrous are more active than others. This mobility can be measured by a testing device called "pedometer". Estrus is expected to be estimated by using detected movement changes with Artificial Neural Networks (ANN) models. The aim of this study is to create and assess the effectiveness of a neural network model to estimate estrus in cattle by using movement and environmental data. Movement data of 78 cattle which showed a total of 186 estruses has been captured along with climatic data during a four-month period at a private agricultural organization. Data such as cow age, lactation number and number of days elapsed from estrus were also taken into account and evaluated. Mechanistic models and ANN models were compared. Accuracy, precision, F scores indicating their impact, and ROC analysis were used for this comparison. For feed-forward neural network model, one and two layers classification networks were tested. Optimal inputs to the neural network model were found to be motion data, motion data of previous time period, number of days after the previous estrus, temperature and humidity. The best result for single-layer ANN, 0.9654 AUC, has been obtained with 91 neurons. Dual-layer network with 40 neurons in the second layer and 37 for the first layer has been the most successful model with 0.9733 ROC points. Mechanistic models have shown the lowest success with an ROC score of 0.5006. The study has shown that the accuracy of estrus prediction is increased by evaluating movement data movement along with climate data.

2016, 98 PAGES

**KEYWORDS: Estrus Prediction, Artificial Neural Networks, Classification, Mechanistic Model**

## ÖNSÖZ

Tez çalışmamda benden maddi manevi desteğini esirgemeyen başta, danışmanım Yrd. Doç. Dr. Mehmet Metin ÖZGÜVEN'e, tez izleme komitesi ve tez jürimde olan Prof. Dr. Sefa TARHAN'a, Doç. Dr. Ufuk TÜRKER'e, Yrd. Doç. Dr. Kenan ZENGİN'e ve Yrd. Doç. Dr. Alper TANER'e tezime olan katkılarından dolayı çok teşekkür ederim.

Gözlemlenen hayvanlarla çalışma süresince ilgilenen ve verileri elde etmemde bana yardımcı olan Veteriner Hekim Mustafa POLAT ve çalışma arkadaşlarına, bilgi ve tecrübelerini benle paylaşan tüm hocalarıma yardımlarından dolayı teşekkürü bir borç bilirim.

Ayrıca bu süreçte yanımda olan ve beni destekleyen eşime ve aileme çok teşekkür ederim.

**Adil Koray YILDIZ**

**1 Haziran 2016**



## İÇİNDEKİLER

	<b><u>Sayfa</u></b>
ÖZET .....	i
ABSTRACT.....	ii
ÖNSÖZ .....	iii
İÇİNDEKİLER .....	iv
SİMGELER VE KISALTMALAR .....	vi
ŞEKİL LİSTESİ.....	vii
ÇİZELGE LİSTESİ .....	ix
1. GİRİŞ .....	1
2. KURAMSAL TEMELLER .....	7
2.1. Kızgınlık Belirleme Çalışmaları .....	7
2.1.1. Pedometre kullanımı .....	7
2.1.2. Yapay zekâ yöntemleri ile kızgınlık belirleme .....	7
2.2 Tahmin Modelleri .....	9
2.2.1 Mekanistik model .....	9
2.2.2 YSA modeli .....	10
2.3 Sınıflandırma modellerinin başarılarının değerlendirilmesi .....	23
2.3.1 Duyarlılık .....	24
2.3.2 Kesinlik .....	24
2.3.3 F Skoru.....	25
2.3.4 ROC ( Receiver Operating Characteristic) Analizi .....	26
3. MATERYAL VE YÖNTEM .....	28
3.1 Denemelerin Gerçekleştirildiği Tarım İşletmesi ve Gözlem Hayvanları .....	28
3.2 İklim Verilerinin Toplanması .....	34
3.3 Hareket ve Kızgınlık Verilerinin Toplanması .....	37
3.4 Tahmin Modellerinin Denenmesi .....	41
3.4.1 Mekanistik modelin denenmesi .....	43
3.4.2 YSA modellerinin denenmesi .....	43
4. BULGULAR VE TARTIŞMA .....	50
4.1 Deneme Verilerinin Genel Değerlendirilmesi .....	53
4.1.1 İklim verilerinin değerlendirilmesi .....	53

4.1.2 Hareket verilerinin deęerlendirilmesi .....	55
4.1.3 İklımsel veriler ile hareketlilik iliřkisi .....	57
4.2 Model Performansları .....	59
4.2.1 Mekanistik model .....	59
4.2.2 YSA modeli .....	60
4.2.3 Modellerin karřılařtırılması .....	71
5. SONUÇ .....	74
6. KAYNAKLAR .....	76
7. EKLER .....	80
8. ÖZGEÇMİŐ .....	98

## SİMGELER VE KISALTMALAR

### Simgeler

$\sigma$

$\mu$

### Açıklama

Eğitim algoritması ağırlık değişim katsayısı

Eğitim algoritması belirsizlik parametresi

### Kısaltmalar

### Açıklama

ADALINE

DNS

DPY

SNİ

SOM

T

YNS

YPS

YSA

Adaptif Linear Neuron

Doğru negatif sayısı

Doğru pozitif sayısı

Sıcaklık nem indeksi

Self Organizing Maps

Tahmin toplamı

Yanlış negatif sayısı

Yanlış pozitif sayısı

Yapay Sinir Ağı

## ŞEKİL LİSTESİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 1.1. 2007-2015 Yılları arasında büyükbaş hayvan sayıları ve süt üretimi .....	1
Şekil 1.2. 2007-2015 Yılları arasında büyükbaş hayvan sayılarındaki birikimli değişim...	2
Şekil 1.3. İneklerde laktasyon süresince süt verimi.....	4
Şekil 2.1. Mekanistik model için günlük zaman pencerelenmesi.....	9
Şekil 2.2. Mekanistik modelin kızgınlık karar algoritması.....	10
Şekil 2.3. Gerçek sinir hücresi yapısı .....	11
Şekil 2.4. YSA nöron modeli.....	11
Şekil 2.5. Danışmalı öğrenme için YSA sınıflandırması.....	14
Şekil 2.6. Çok katmanlı ileri beslemeli hiyerarşik ağ ve matematiksel gösterimi.....	15
Şekil 2.7. Geri yayılım ile ağın eğitimi.....	17
Şekil 2.8. hardlim(n) transfer fonksiyonunun grafiksel gösterimi.....	19
Şekil 2.9. hardlims(n) transfer fonksiyonunun grafiksel gösterimi .....	19
Şekil 2.10. purelin(n) transfer fonksiyonunun grafiksel gösterimi .....	20
Şekil 2.11. logsig(n) transfer fonksiyonunun grafiksel gösterimi .....	20
Şekil 2.12. tansig(n) transfer fonksiyonunun grafiksel gösterimi.....	20
Şekil 2.13. Eğri uydurma için öğrenememe, tam öğrenme ve ezber durumları .....	21
Şekil 2.14. Eğitim süresince doğrulama ve eğitim hatalarındaki değişim.....	22
Şekil 2.15. Hata matrisinde değerlerin yerleşimi.....	23
Şekil 2.16. Kesinlik ve duyarlılık arasındaki ödünleşim .....	25
Şekil 2.17. ROC eğrisi örneği .....	26
Şekil 3.1. Tarım işletmesinde bulunan 1 No'lu ahır .....	28
Şekil 3.2. Ahırlarda açık gezi alanı .....	29
Şekil 3.3. Tohumlanan hayvanların alındığı 2 No'lu ahır .....	29
Şekil 3.4. Ahıra monte edilen kameralardan biri .....	30
Şekil 3.5. Gözlem-kayıt merkezi .....	31
Şekil 3.6. Tarım işletmesine kurulan iklim istasyonu.....	34
Şekil 3.7. İklim verilerine ulaşılmasını sağlayan WEB arayüzü .....	35
Şekil 3.8. İklim veri tabanından ölçümleri otomatik indiren yazılım.....	36
Şekil 3.9. Hayvanın bileğine takılan pedometre .....	37
Şekil 3.10. Hareket ölçümünde kullanılan pedometre .....	37
Şekil 3.11. Hareket takip sistemi ara istasyonu .....	38
Şekil 3.12. Hareket takip sisteminde hareket, yatma verisiyle kızgınlığın belirlenmesi ...	40
Şekil 3.13. Alınan verilerin zaman çizelgesinde gösterimi .....	41
Şekil 3.14. YSA eğitimleri için iki saatlik pencereleme şekli .....	43
Şekil 4.1. Her bir hayvan için gözlemlenen kızgınlık sayısı grafiği.....	52
Şekil 4.2. Kızgınlıklar arasında geçen gün sayısına göre kızgınlık sayıları .....	53
Şekil 4.3. Gözlem sürecinde aylık sıcaklık değişimi .....	54
Şekil 4.4. Gözlem süresince ölçülen aylık bağıl nem değerleri.....	54
Şekil 4.5. Hesaplanan SNİ'lerin aylık gösterimi .....	55
Şekil 4.6. Tüm hayvanların ortalama hareket verileri .....	56
Şekil 4.7. Günün saatleri için hareket ortalamaları.....	57
Şekil 4.8. Sıcaklık ile ortalama hareketlilik dağılımı.....	58
Şekil 4.9. Nem ve ortalama hareket dağılımı.....	58
Şekil 4.10. SNİ ve ortalama hareket dağılımı .....	59

Şekil 4.11. Mekanistik modelin hata matrisi .....	60
Şekil 4.12. En başarılı girişin hata eğrisi ve doğrulama hataları .....	64
Şekil 4.13. En iyi giriş kümesinin eğitim hata grafiği .....	64
Şekil 4.14. En iyi giriş kümesi hata matrisi ve ROC eğrisi .....	65
Şekil 4.15. Tek katmanlı en başarılı ağıın eğitim süreci.....	66
Şekil 4.16. Tek katmanlı en başarılı ağıın doğrulama hata grafiği .....	67
Şekil 4.17. Tek katmanlı en başarılı ağıın hata matrisi, ROC eğrisi.....	67
Şekil 4.18. İki katmanlı YSA'da nöron sayılarına göre F skor değişimi.....	69
Şekil 4.19. En başarılı iki katmanlı ağıın eğitim süreci grafikleri .....	69
Şekil 4.20. İki katmanlı en başarılı ağıın hata matrisi.....	70
Şekil 4.21. İki katmanlı en başarılı ağıın ROC eğrisi .....	70
Şekil 4.22. İki saatlik verilerle eğitilen ağıın karşılaştırma matrisi .....	72
Şekil 4.23. İki saatlik verilerle eğitilen ağıın ROC eğrisi .....	72
Şekil 4.24. Çakışmayan iki saatlik verilerle eğitilmiş ağıın karşılaştırma matrisi.....	73
Şekil 4.25. Çakışmayan iki saatlik verilerle eğitilmiş ağıın ROC eğrisi .....	73

## ÇİZELGE LİSTESİ

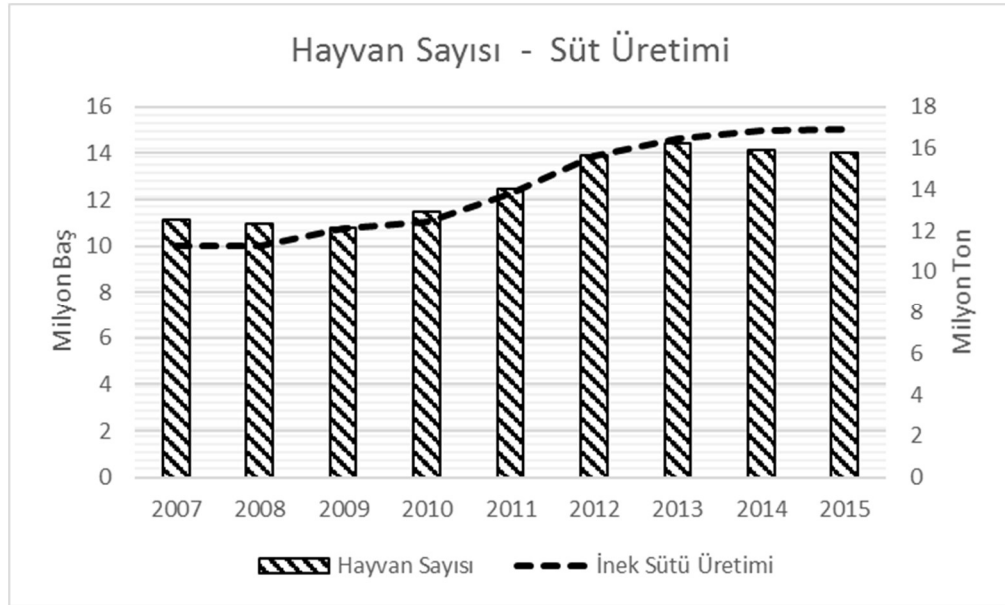
<b><u>Çizelge</u></b>	<b><u>Sayfa</u></b>
Çizelge 3.1. Gözlemlenen hayvanlar .....	31
Çizelge 3.2. Araştırılan giriş kümeleri.....	45
Çizelge 3.3. Önceki çalışmalarda gizli nöron sayısı hesapları .....	48
Çizelge 4.1. Gözlemlenen kızgınlıklar .....	50
Çizelge 4.2. Giriş kümelerinin deneme sonuçları.....	61
Çizelge 4.3. Tek katmanda birinci aşama deneme sonuçları .....	65
Çizelge 4.4. Tek katmanda ikinci aşama deneme sonuçları .....	66
Çizelge 4.5. Önceki çalışmalardaki formüllerden elde edilen sonuçlar .....	68
Çizelge 4.6. Modellerin karşılaştırılması.....	71



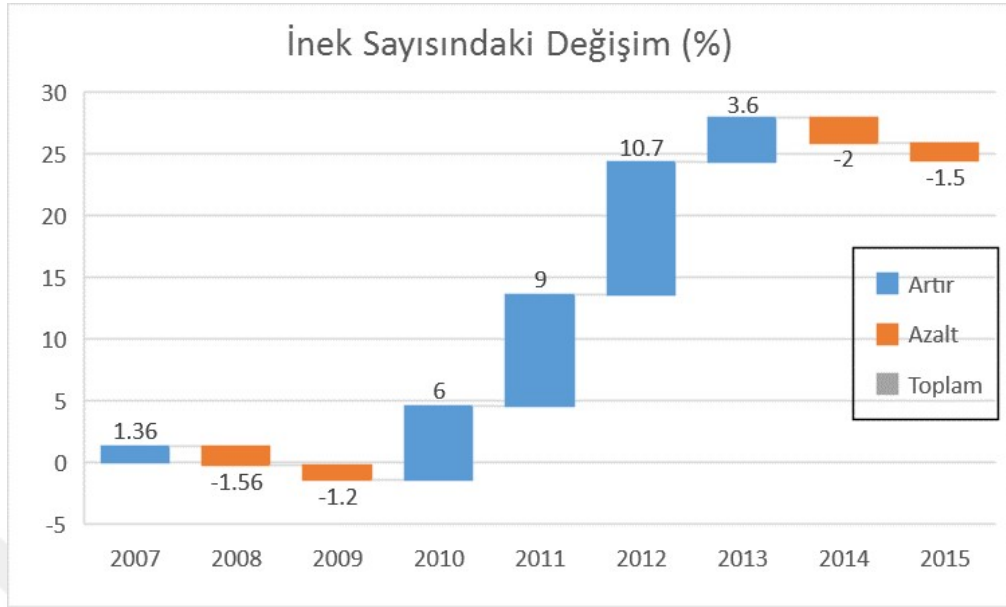
## 1. GİRİŞ

Hayvancılık, gıda ihtiyacımızın büyük kısmını karşılayan önemli bir zirai faaliyettir. Ülkemizde gıda sanayinin en temel ham maddeleri olan et ve süt üretimi büyük ölçüde büyükbaş hayvancılık ile sağlanmaktadır. Ülkemizde 2014 yılında üretilen toplam sütün %92'si ve toplam etin %88'i büyükbaş hayvancılıktan sağlanmıştır (Anonim, 2014a). Ülke ekonomisinde büyük önem taşıyan bu üretim kolunun geliştirilmesi öncelikli üretim hedeflerinden biri haline gelmiştir (Anonim, 2014b). Dünyada ve ülkemizde bu gelişimin sağlanması için çeşitli çalışmalar yapılmaktadır. Modern tesislerde üretimin kontrollü ve sağlıklı gerçekleştirilmesinin yanında verimin artırılması en önemli hedefler arasında sayılmaktadır (Aras, 2015).

Türkiye İstatistik Kurumundan alınan verilere göre ülkemizde son yıllardaki büyükbaş hayvan sayıları ile toplam süt üretimi grafiği Şekil 1.1'de ve büyükbaş hayvan sayısındaki değişimin birikimli gösterimi Şekil 1.2'de verilmiştir (Anonim, 2016).



Şekil 1.1. 2007-2015 Yılları arasında büyükbaş hayvan sayıları ve süt üretimi



Şekil 1.2. 2007-2015 Yılları arasında büyükbaş hayvan sayısındaki birikimli değişim

Ülkemizde büyükbaş hayvan sayısı 2013 yılında 14 milyon 415 bin iken, iki yıl üst üste azalarak 2015 yılı sonu itibariyle 13 milyon 994 bin olmuştur (Anonim, 2013; Anonim, 2015). Bu düşüşün, çeşitli ekonomik sebeplerin yanında, uygun üretim ve ıslah çalışmalarının etkili bir şekilde uygulanamamasından kaynaklandığı düşünülmektedir. Düşüşe rağmen süt üretimi azalmamıştır. Devlet ve Avrupa Birliği desteklerinin de etkisi ile son yıllarda daha teknik ve modern tesislerin kurulması, kültür ve melez ırkların yaygınlaştırılması, bu sayede üretim veriminin artırılması ülkemizdeki süt üretimini arttırmıştır (Ataseven ve Gülaç, 2014). Geleneksel hayvancılığın çok fazla iş gücü isteyen bir üretim dalı olması karlı bir üretim için iyileştirmeleri zorunlu kılmaktadır.

Hayvansal üretimde yapılan en önemli iyileştirmelerden biri otomasyonlardır. Otomasyonların kontrolü bilgisayar teknolojisine dayalı sistemler yardımıyla yapılmaktadır. Böylece iş gücünden tasarruf sağlanarak yakın bir geçmişe kadar zor ve zaman alıcı olarak görülen birçok işlem, basit ve daha az zaman alan birer uygulama niteliği kazanmıştır (Çakıcı, 2006). Bunun en güzel örneklerinden biri hassas sürü yönetim sistemleridir. Süt sığırcılığında hassas sürü yönetiminin temel amaçları, hayvanların bireysel potansiyelinden en yüksek düzeyde yararlanmak, hastalıkları daha erken teşhis etmek ve koruyucu sağlık önlemleri yoluyla ilaç kullanımını en aza indirmektir. Sürü yönetim yazılımlarıyla işletmede bulunan hayvanların sağım, yemleme, kızgınlık, tohumlama, buzağılama, verim bilgilerinin düzenli toplanması sağlanmaktadır.

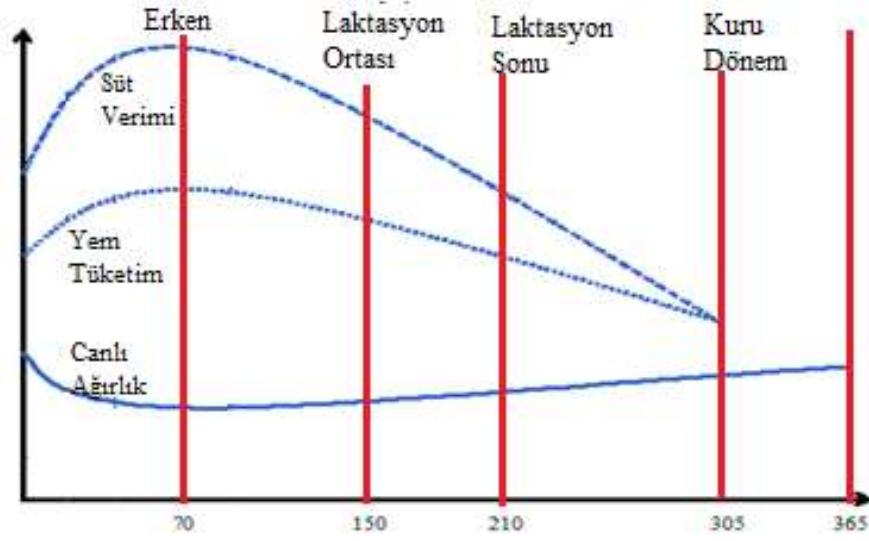


Tutulan bu bilgilerin analiziyle sürünün performansı ve sağlık durumu izlenmekte, raporlama sayesinde ise gerekli müdahaleler zamanında uygulanabilmektedir (Tarhan ve ark., 2015). Hassas sürü yönetim uygulamaları kapsamında birçok ileri teknoloji unsuru olduğu belirtilmektedir (Uzmay ve ark., 2010).

Modern ve büyük ölçekli süt çiftliklerinde işletmenin kârlılığını arttırmak ve kayıpları en aza indirmek için hassas sürü yönetim sisteminin işletme ihtiyaçlarına uygun olması gerekmektedir. Bu amaçla bilgisayar kontrollü elektronik araçlar içeren modern sürü yönetim sistemleri işletmeler tarafından yoğun olarak kullanılmaya başlanmıştır (Tömek, 2007). Üreticiler kalıcı kayıplar oluşmadan tedbirlerini almakta ve gerekli iş planlarını zamanında oluşturabilmektedirler.

Sürü yönetim sistemlerinde aranan en önemli özelliklerden birisi etkin üreme yönetiminin sağlanabilmesidir. Etkin üreme yönetiminin amacı her bir inek için biyolojik olarak mümkün olan en erken zaman aralığında gebeliğin sağlanması olarak tarif edilmektedir. Bu doğru zamanlamanın yapılabilmesi için ineklerin kızgınlık (östrus) denilen dönemlerinin belirlenmesi gerekmektedir (Demirci, 2007). Kızgınlık ovulasyondan (yumurtlamadan) hemen önce fizyolojik ve davranışsal değişikliklerle karakterize bir durum olup süresi 4 ile 24 saat arasında değişmektedir.

Yüksek doğruluk ile kızgınlığın tespit edilmesi ineklerin gebe kalmasının sağlanmasına doğrudan etki etmektedir. İneklerin üreme kabiliyetlerinin yüksek oranlarda gerçekleştirilmesi, öncelikle buzağı üretimini artırmaktadır. Ayrıca süt üretimini doğrudan etkiler. Şekil 1.3'de verilen süt ineğine ait genel laktasyon eğrisinden de anlaşılacağı gibi ineklerde en çok süt verilen dönem, buzağılamadan hemen sonraki erken laktasyon dönemidir. Bu dönemden sonra süt verimi yem tüketimine göre daha hızlı azalmaktadır. Birim süt için tüketilen yem miktarı artmaya başlar. Bu nedenle üremenin kontrol altında tutulması daha uzun süre ve daha yüksek oranlarda süt üretimine imkân sağlamaktadır (Daniel, 2006).



Doğumdan Sonra geçen gün sayısı

Şekil 1.3. İneklerde laktasyon dönemi süresince süt verimi

Kızgınlığın belirlenmesinde birçok yöntem kullanılmaktadır (Firk ve ark, 2002; Demirci, 2007). Bu yöntemler:

- İnspeksiyonla (gözlem ile) araştırma
- Arama boğasıyla belirleme
- Sacrum (kuyruk sokumu) bölgesine boyalı araçlar yerleştirme
- Vagina mukozasının elektrik direncinin ölçümü
- Kanda ve sütte hormon (progesteron, östrojen) tayini
- Rektal muayene
- Pedometre ile belirleme

şeklinde sıralanabilir.

Ayrıca video kamera ile gözlem, sıçrama detektörleri, sıcaklık algılayıcıları ve hormonal koku algılayıcıları gibi elektronik cihazlarla da kızgınlık belirleme yapılabilmektedir (Williamson ve ark., 2006).

Hayvanlarda kızgınlık dönemi yaygın olarak çeşitli davranışsal tepkilerin gözlenmesiyle belirlenmektedir. En belirgin tepki hareketlilikteki artıştır. Kızgınlıktaki hayvanlar diğer hayvanlara göre daha hareketlidir. Bu hareketlilik ineklerin bileklerine takılan “pedometre” denen ve atılan adımı sayan cihazlarla ölçülmektedir. Böylece pedometre

kullanılarak kızgınlık uygun şartlarda %80 ile %90 oranında doğru olarak tahmin edilebilmektedir. Ancak barınak şartları, iklim şartları ve hayvan yoğunluğu başarı oranını düşürebilmektedir. Başarı oranındaki düşüşün en önemli nedeninin çevresel şartların hayvan hareketliliğine olan etkileri olduğu düşünülmektedir. Ayrıca kızgınlık periyodunun kısa ve değişken olmasından dolayı ineklerde kızgınlığın belirlenmesi diğer türlere göre daha zor olduğu belirtilmektedir (Demirci, 2007).

Belirlenemeyen veya yanlış belirlenen kızgınlıklar suni tohumlamanın zamanında ve başarılı bir şekilde yapılmasını olumsuz yönde etkilemekte ve işletmelerin süt ve buzağı üretim potansiyellerini azaltmaktadır. Kaçırılan bir kızgınlık dönemi hayvan başına ortalama 21 günlük süt kaybına neden olmaktadır. Bunun yanında, buzağılama aralığının artmasından dolayı gereken sayıda düve sağlanamayacağından sürü yaşlanacak ve küçülecektir. Uygulanan seleksiyonun başarısı olumsuz yönde etkilenecektir. Dolayısıyla gerçekleşen kızgınlıkların yüksek oranda doğru saptanabilmesi ve kızgın olmayan hayvanların kızgınlık gösteriyormuş gibi algılanmaması gerekmektedir. En yaygın kızgınlık belirleme bakıcı gözlemiyle yapılmaktadır. Bu yöntemde uzmanlaşmış elemanlara ihtiyaç duyulmaktadır (Sarıbay ve Erdem, 2008). Buna rağmen bakıcılar tarafından gözlemlenen kızgınlık takibinde birçok işletmenin kızgınlık belirleme başarısı %50'nin altındadır. Bazı işletmelerde hayvanların %5 ila %30 kadarı kızgın olmadığı halde tohumlanabilmektedir (Tömek, 2007). Bu yanlış tohumlama hem tohumlama materyalinin boşa gitmesine hem de iş kaybına sebep olabilmektedir.

Kızgınlık belirleme konusunda oluşabilecek hataların önüne geçilmesi için yapay zekâ yöntemlerinden faydalanılabilmektedir. Günümüzde karmaşık ve zaman alan problemler için yapay zekâ yöntemleri etkili bir çözüm aracıdır. Yapay zekâ, insanların karar verme süreçlerindeki zihinsel fonksiyonlarının bilgisayar modelleri yardımıyla formül haline getirilerek çeşitli alanlarda bunların kullanımını inceleyen bir araştırma alanıdır. Yapay zekâ, teorik olarak elektronik ve bilgisayar teknolojilerinden daha önce geliştirilmesine rağmen ağır işlem yüklerinden dolayı 80li yıllara kadar pratikte çözümler sağlayamamıştır. Bu yıllarda ve sonrasında mikroişlemci teknolojilerindeki gelişmeler, bilgisayarların ağır işlemlerin üstesinden gelebilmelerini sağlamış ve bu sayede uygulanabilirliklerini artırmıştır. Yapay zekâ araştırmalarıyla geliştirilen sistemler ticari uygulamalarda kullanılmaya başlanmıştır. Yapay zekâ yöntemleri birçok alanda olduğu

gibi tarım ve hayvancılıkta da etkili çözümler üreterek kullanıcılara yarar sağlayabilmektedir (Akkaya, 2007).

Yapay Sinir Ağları (YSA), yapay zekâ içerisinde araştırılan ve kullanılan önemli bir yöntemdir (Elmas, 2011). YSA modellerinin hayvan davranışlarındaki değişimleri algılayarak kızgınlık durumuna karar verilebileceği düşünülmektedir. Bu nedenle çalışmada, hareket ve çevresel veriler kullanılarak büyükbaş hayvanlarda kızgınlık dönemini belirleyecek bir YSA modelinin oluşturulması ve etkililiğinin incelenmesi amaçlanmıştır. Pedometreler ile elde edilen hareket bilgileri ile beraber iklim verileri ve hayvanlara ait veriler de çalışmaya dâhil edilmiştir. Farklı girdi kümeleri farklı YSA modelleri ile değerlendirilmiş böylece en uygun model ve veri türlerinin belirlenmesi amaçlanmıştır.

## **2. KURAMSAL TEMELLER**

### **2.1 Kızgınlık Belirleme Çalışmaları**

#### **2.1.1 Pedometre kullanımı**

Hayvanlar, belirlenmiş genel davranışları olsa da çoğu durumda farklı tepkiler gösterebilmektedirler (Hulsen, 2012). Bu farklılıklardan dolayı kızgınlığı gösterecek kesin bir adım sayısı belirlemek imkânsızdır. Yine de kızgınlığa gelen hayvanlardaki hareket artışı pedometreler yardımıyla kızgınlığın belirlenmesinde fayda sağlamaktadır. Roelofs ve ark. (2005), pedometre verilerine dayalı kızgınlık tahmininde farklı matematiksel algoritmalar kullanarak %51 ila %81 arasında başarı oranları elde etmişlerdir. Başarı oranlarındaki bu değişikliğin çevresel faktörler ve kızgınlıktaki hayvanların birbirine olan etkilerinin değerlendirilmemesi sebebiyle meydana geldiği yorumunu yapmışlardır.

#### **2.1.2 Yapay zekâ yöntemleri ile kızgınlık belirleme**

Tarımsal üretimin birçok alanında yapay zekâ yöntemlerinden faydalanılmaktadır (Yıldız ve ark., 2013). Tahmin ve modelleme problemlerine etkili çözümler getiren yapay zekâ yöntemleri kızgınlık verilerinin değerlendirilmesinde de kullanılmaktadır. Mitchell ve ark. (1996) topladıkları süt verilerini bazı makine öğrenmesi algoritmalarıyla değerlendirerek kızgınlık tahmini için bu algoritmaların işlevselliğini karşılaştırmışlardır. En iyi sonucu C4.5 sınıflandırma ağacı algoritması %96,5'lik doğrulukla vermiştir. Fakat çok büyük veri setlerine ihtiyaç duyulması ve gerçek zamanlı bir uygulama olmamasından dolayı pratikte bu kadar yüksek doğruluk elde etmenin zor olacağını belirtmişlerdir. Yoğun olarak kullanılan diğer yapay zekâ yöntemleri Bulanık Mantık ve Kalman Filtresi'dir (Firk ve ark., 2002). Kalman Filtresi, zaman serilerinin kestirimi ve tahmini problemlerinde kullanılan iki aşamalı özyinelemeli bir yöntemdir. İneklerden

alınan zamansal verilerin bu yöntemle değerlendirilmesiyle kızgınlık tespiti yapılabilmektedir (De Mol ve ark., 1999).

Bulanık Mantık modeli ile kızgınlık durumu, “kızgınlıkta”, “kızgınlıkta değil” ve “kızgınlıkta olabilir” şeklinde üç kümede sınıflandırılmakta ve sistem, üyelik derecesine göre hayvanların kümesini tahmin etmektedir (De Mol ve Woldt, 2001). Önceki çoğu çalışmada girdi verileri süt miktarı, süt sıcaklığı, sütün elektriksel geçirgenliği gibi süttten alınan veriler iken Brunassi ve ark. (2010) çevresel sıcaklık, hareketlilik sapmaları, progesteron salınımı ve kızgınlık takvimini veri olarak Bulanık Mantık modelinde kullanıp süt ineklerinde kızgınlık tahmin etmişler ve %84,2’lik doğruluk elde edebilmişlerdir. Memmedova ve Keskin (2011) önce inekleri hareket durumlarına göre “az hareketli”, “orta hareketli” ve “çok hareketli” olarak sınıflandırmışlar sonra Bulanık Mantık modelini oluşturmuşlar ve %98’lik bir tespit oranı bildirmişlerdir.


Hayvan ve sürü davranışlarının sınıflandırılmasında Yapay Sinir Ağı (YSA) modelleri kullanılabilir (Nadimi ve ark., 2012). Dolayısıyla hayvan davranışlarına belirgin etkileri olan kızgınlığın YSA kullanılarak tahmini mümkün görülmektedir. Krieter ve ark. (2005), 373 süt ineği üzerinde yaptıkları çalışmada, kontrol grafiği ve YSA kullanarak %99.6 doğrulukla kızgınlığı tespit etmişlerdir. Bu çalışmada girdi verisi olarak kızgınlıktan sonra geçen gün sayısı ve sağımdan önce pedometrelerden okunan adım sayıları kullanılmıştır. Araştırmacılar, çevre verileri ve diğer veriler (örn. süt verileri) ile daha etkin ve uygulama anında sonuç verebilecek sistemler gerçekleştirilebileceğini vurgulamaktadır.

## 2.2 Tahmin Modelleri

Çalışmada temel iki tahmin modeli üzerinde durulmuştur. İlki Roelofs ve ark. (2005) tarafından başarılı olduğu belirtilen “Mekanistik Model”dir. Araştırılan diğer tahmin modeli de YSA sınıflandırmasıdır.

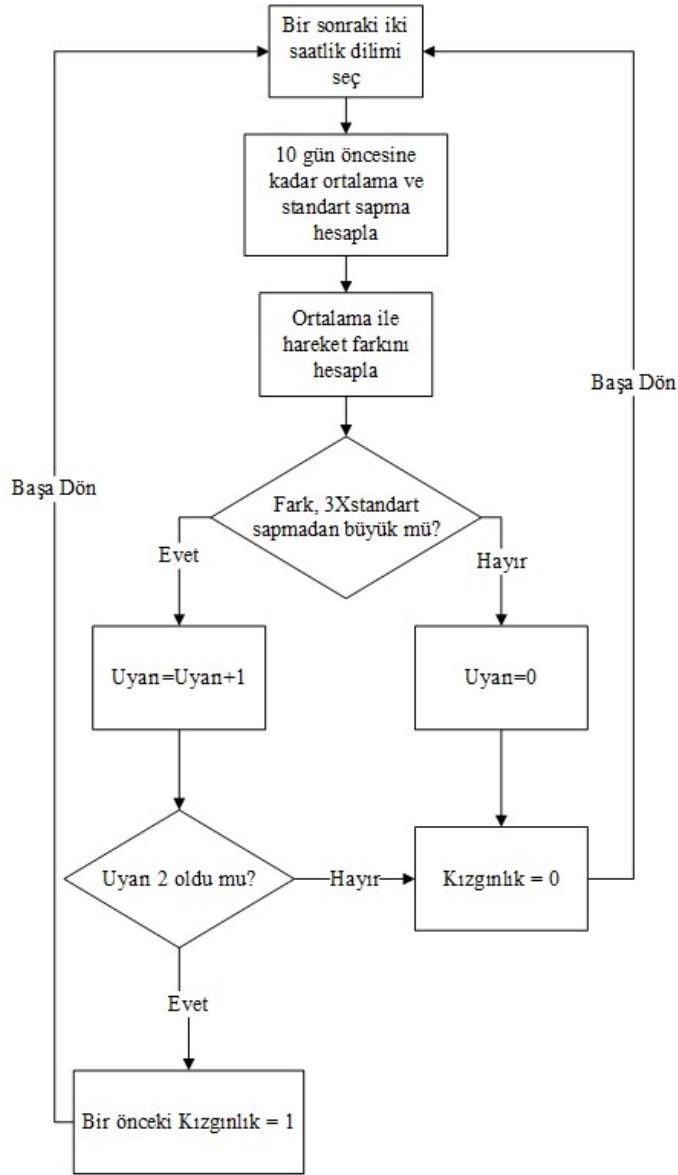
### 2.2.1 Mekanistik model

Mekanistik modelde hareket verileri ikişer saatliktir. Bu nedenle hareket verilerinin ikişer saatlik pencerelemeye ayrılması gerekmektedir. Şekil 2.1’de bir gün için bu pencerelemenin yapılışı gösterilmektedir.



Şekil 2.1. Mekanistik model için günlük zaman pencerelemesi

Her bir gün içinde 0-2, 2-4, 4-6, 6-8, 8-10, 10-12, 12-14, 14-16, 16-18, 18-20, 20-22, 22-00 olacak şekilde 12 adet ikişer saatlik zaman dilimleri elde edilmektedir. Mekanistik modelin çalışma algoritması Şekil 2.2’de görülmektedir. Bu modele göre her bir zaman dilimine ait ortalama ve standart sapma o zaman diliminden on gün öncesine kadar olan veriler değerlendirilerek hesaplanmaktadır. O anki değer ile hesaplanan ortalama arasındaki fark üst üste iki defa standart sapmanın 3 katından büyük olduğunda ilk aşmanın olduğu zaman dilimi için kızgınlık kaydedilmektedir.




Şekil 2.2. Mekanistik modelin kızgınlık karar algoritması

### 2.2.2 YSA modeli

YSA, beynin karar alma işlemine benzer şekilde çalışan matematiksel modellerdir. Sınır hücrelerin birbiriyle yaptığı bağlantı ve iletişimden esinlenerek geliştirildikleri için YSA olarak adlandırılmışlardır. Ağı oluşturan işlem düğümleri fonksiyon bakımından sınır hücrelerine benzediği için “nöron” olarak adlandırılmıştır. Şekil 2.3’de gerçek bir nöron hücresinin çizimi görülmektedir. Nöronlar, gövde ve gövdeden dışa doğru çıkmış “akson” ve “dendrit” denilen bağlantı elemanlarından meydana gelmişlerdir. Çıkış olan aksonlar diğer hücrelerin girişlerine yani dendritlerine bağlanmaktadır. Bu bağlantılara sinaptik

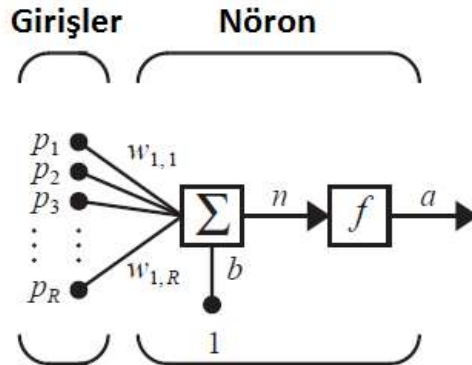


bağlantılar denmektedir. Sinirsel uyarılar hücreden hücreye bu bağlantılar üzerinden biyokimyasal olarak aktarılmaktadır.



Şekil 2.3. Gerçek sinir hücresi yapısı (Zippo, 2011)

Yapay nöron modeli gerçek nörona benzer şekilde çalışmaktadır. YSA nöron modeli Şekil 2.4’de ve matematiksel gösterimi de Eşitlik 2.1’de gösterilmiştir. Eşitlikte  $p$  girişleri,  $a$  çıkışı ifade etmektedir. Girişler, kendilerine ait  $w$  ağırlıkları ile çarpılıp,  $b$  eşiği de dâhil edilerek toplanmaktadır. Daha sonra bu toplam; “transfer” veya “aktivasyon fonksiyonu” olarak adlandırılan  $f$  fonksiyonuna girmektedir. Fonksiyon sonucu, nöronun çıkışı olarak hesaplanmaktadır. Bir sonraki katmandaki nöronun girişi bir başka nöronun çıkışı olmaktadır (Öztemel, 2003).



Şekil 2.4. YSA nöron modeli (Hagan ve ark., 1996)

$$a = f(\sum_i W_i p_i + b) \quad (2.1)$$

Bu nöronların çeşitli şekillerde bağlantılar oluşturarak bir araya gelmeleri ile YSA oluşmaktadır.

### *YSA'nın Tarihsel Gelişimi*

Yapay Zekâ ve makinelerin insan gibi düşünebilmesi fikri çok öncelere dayanmaktadır. 1940'lı yıllarda ilk temel bilimsel araştırma ve çalışmalar başlamış olsa da daha öncesinde Helmholtz, Pavlov, Poincare gibi bazı bilim adamlarının Yapay Zekâ üzerine çalıştıkları bilinmektedir (Baş, 2006).

YSA üzerine ilk çalışma McCulloch ve Pitts (1943) 'in bir sinir hücresinin matematiksel modelini açıklamaları olarak kabul edilir. Bu matematiksel model ile YSA'nın temelleri atılmıştır. Daha sonra Hebb (1949)'in bu hücrelerin "öğrenme" işlemini açıklanmasıyla büyük bir adım daha atılmıştır. Hebb'e göre hücrelerin birbiriyle bağlantılarını yapan elemanları (Akson ve Dendrit) öğrenme süresince yeni bağlantılar yapabildiği gibi kuvvetleniyor veya zayıflıyorlardı. Bu durum daha sonra "Hebb Kuralı" olarak adlandırıldı ve YSA'ların eğitiminde en temel işlem olarak kabul edilmiştir.

Rosenblatt (1958), "Perceptron" yani algılayıcı modelini geliştirmiştir. Bu model basit bir nöronun öğrenme kuralını taklit eden ilk YSA hücresi olarak kabul edilmiştir. Daha sonra bu model çok katmanlı YSA'nın temelini oluşturmuştur.

Marcian Hoff, 1959 yılında ADALINE (Adaptif Linear Neuron) modelini ortaya koymuştur (Baş, 2006). Bu model ile YSA'lar ilk defa mühendislik alanında işlevsellik kazanmıştır. Daha sonraki yıllarda yapılan çalışmalar, YSA modellerinin benzetim (simülasyon) alanında işlevsellik kazanmasını sağlasa da çok hesap yükü olması ve işlem gücü yüksek donanımlara ihtiyaç duyulması sebebiyle popülerliğini kaybetmiştir. 1980'li yıllarda gelişen yarı iletken teknolojisinin bilgisayar sistemlerinde kullanılmasıyla işlem gücü yüksek donanımlar yapılarak daha önce sorun olan işlem yükü çözülmüş ve YSA'lar işlevsellik kazanmıştır (Elmas, 2011). Bilgisayarlarda modellenen YSA'lar ile zor ve karmaşık problemlerin çözülebileceği gösterilmiştir. Optimizasyon gibi teknik problemleri çözebilen ağlar ve SOM (Self Organizing Maps) gibi eğitilmeden öğrenebilen "Danışmasız Öğrenme" algoritmaları geliştirilmiştir (Hopfield, 1982).

Rumelhart ve ark. (1986), ileri beslemeli ağılarda hatanın geriye yayılmasıyla modeli eğiten “Geri Yayılım” algoritmasını geliştirmişlerdir.

Sinir hücrelerinin araştırılmasıyla başlayan çalışmalar gelişen teknolojiye paralel olarak mühendislik çözümleriyle devam etmiştir. Günümüzde bilgisayar üretim teknolojisindeki gelişmeler sayesinde hızlı ve işlem gücü yüksek cihazlar hayatımızın her alanında kullanılmaktadır. Gelişen bu teknoloji araçları sayesinde regresyon, sınıflandırma ve geleceğe yönelik tahmin problemlerinde hızlı ve etkin YSA çözümlerinin kullanımı yaygınlaşmaktadır (Alpaydın, 2010).

### *YSA Sınıflandırması*

YSA’lar öncelikli olarak öğrenme çeşidine göre sınıflandırılmaktadır. YSA modelinin istenilen çözümü verebilecek kabiliyete gelmesine “öğrenme” denilmektedir. Öğrenme, yapay zekâ yöntemleri için *danışmalı* ve *danışmasız* öğrenme olarak ikiye ayrılmaktadır (Alpaydın, 2010). Danışmalı öğrenmede giriş değerleri için çıkışlar bellidir ve öğrenme süreci hesaplanan çıkışların gerçek çıkışlarla karşılaştırılması ile sürdürülmektedir. Danışmasız öğrenmede çıkışlar eğitim sürecine dâhil olmaz. Baştan belirlenen kesin çıkışların bulunması yerine olası çıkışlar girişler değerlendirilerek kestirilmektedir.

Sınıflandırma için önemli olan diğer etmenler ağ yapısı (topolojisi), nöronların bağlantı şekli ve eğitim algoritmalarıdır. Danışmalı öğrenme için bu etmenlere göre YSA sınıflandırması Şekil 2.5’de gösterilmiştir. Nöronların çıkışları kendisine giriş sağlayan daha önceki nöronlara bağlanıyorsa bu ağlar *geriye dönük* veya *geri beslemeli* ağlar olarak adlandırılırlar. Nöronların çıkışları kendinden önceki ağlara bağlanmıyor bir sonraki ağa bağlanıyorsa bunlara da *ileri beslemeli* ağlar denir. YSA’lar yapılarına göre *tek katmanlı* veya *çok katmanlı* olabilirler. İleri beslemeli çok katmanlı ağlar kendi içlerinde *kaskat* ve *hiyerarşik* olarak ikiye ayrılmaktadır. Hiyerarşik ağlar sadece kendinden bir sonraki katmana bağlantı yapabiliyorken, kaskat ağlar daha üst seviyedeki katmanlara da bağlantı yapabilmektedir.

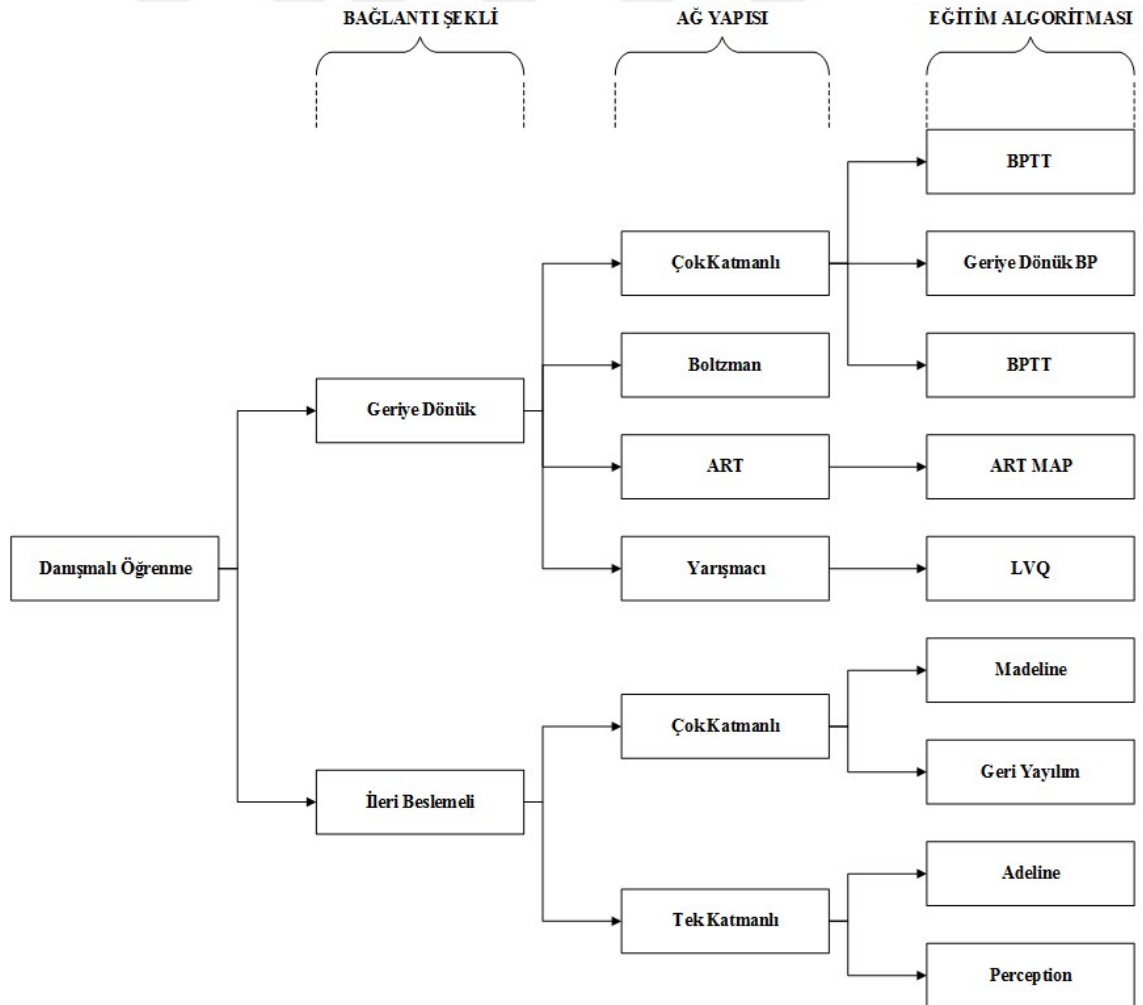
Diğer bir sınıflandırma eğitim algoritmasına göre yapılır. Farklı ağ yapılarına göre çeşitli eğitim algoritmaları geliştirilmiştir.

YSA’larda kullanılacak yapıyı, bağlantıları ve eğitim algoritmalarını belirleyen en önemli etmen, çözümü istenilen problemin çeşididir (Engelbrecht, 2007).

YSA kullanılarak:

- Lineer - Lineer olmayan regresyon
- Örüntü tanıma
- Sınıflandırma
- Kümeleme
- Zaman serisi

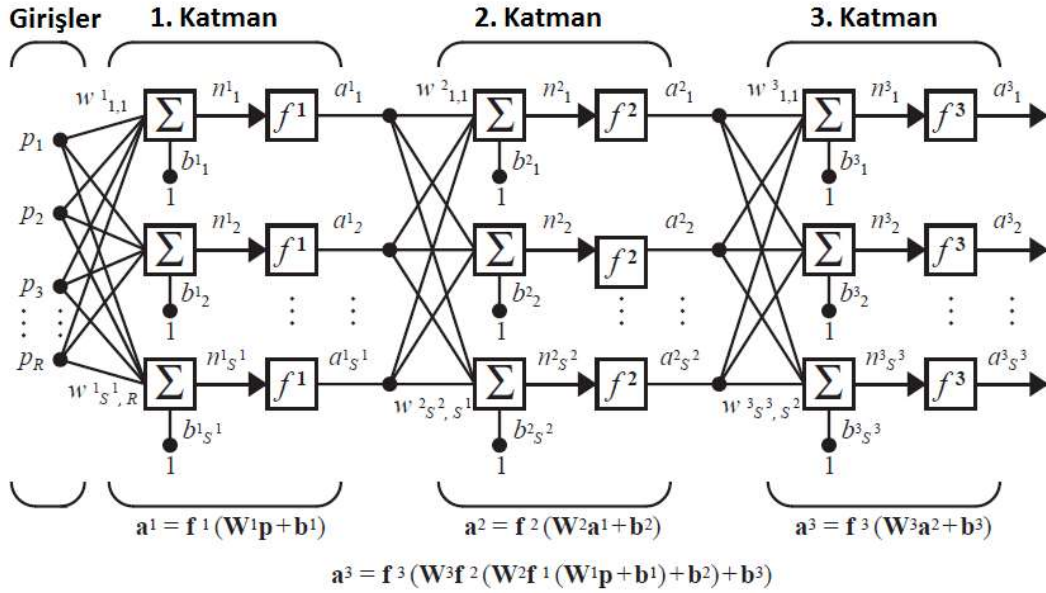
problemleri çözülebilmektedir (Sağiroğlu ve ark., 2003).



Şekil 2.5. Danışmalı öğrenme için YSA sınıflandırması

Regresyon veya sınıflandırma gibi danişmalı öğrenme problemleri için en yaygın kullanılan YSA, ileri beslemeli çok katmanlı geri yayılım ağıdır (Alpaydın, 2010).

Şekil 2.6’de bu ağlara örnek olarak her katmanında 3 nöronu bulunan, 3 katmanlı ileri beslemeli hiyerarşik bir ağı yapı ve matematiksel modeli verilmiştir.



Şekil 2.6. Çok katmanlı ileri beslemeli hiyerarşik ağ ve matematiksel gösterimi (Hagan, ve ark., 1996)

Şekil 2.6’da görüldüğü gibi her bir katmanda ağırlıklandırılmış girişler eşikle beraber toplanıp nöron fonksiyonlarına uygulanmakta, fonksiyon çıktıları da diğer katman nöronlarına giriş olmaktadır.

### YSA Topolojisi

YSA içerisinde nöronlar katmanlar halinde bulunmaktadır. Ağ topolojisi katman sayısını ve katmanlarda bulunan nöron sayısını ifade etmektedir. Her YSA modelinde mutlaka bir giriş bir çıkış katmanı vardır. Giriş katmanı, çıkışı elde edebilmemiz için gerekli bağımsız değişkenlerin yani girişlerin modelde işleme girdiği katmandır. Çıkış katmanı sonucun alındığı katmandır. Regresyon problemleri için istenilen sonuç çeşidi sayısı kadar nöron vardır. Bu nöronlar  $[-1,1]$  aralığında normalize sayısal değerler üretirler. Sınıflandırma ağlarında çıkış katmanındaki nöron sayısı sınıf sayısına göre belirlenmektedir. Bulunması istenilen sınıf sayısı kadar çıkış olur. Her sınıf, kendi elemanı “1”, diğer

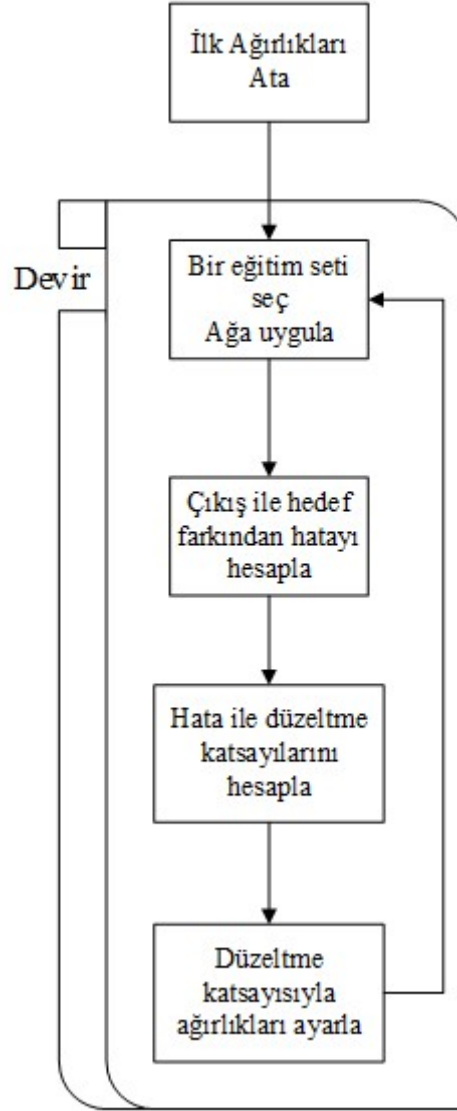
elemanları “0” olan bir çıkış vektörü ile ifade edilir. Sınıf sayısı iki ise tek çıkış, “1” veya “0” olması durumuna göre iki sınıfı da belirleyebilmektedir.

Giriş ve çıkış katmanları arasındaki katmanlara “ara katman” denildiği gibi, çevresel birimlerle doğrudan ilişkileri olmaması sebebiyle “gizli katman” olarak da adlandırılmaktadırlar. Gizli katmanları olmayan, giriş ve çıkış katmanlarından ibaret olan ağlar karmaşık problemler için gerekli olan hesaplama yeteneğinden yoksundurlar (Elmas, 2011). Gizli katman ve gizli katmandaki nöron sayısı YSA’nın başarımını doğrudan etkileyen bir etmendir. Sınıflandırma ağları için tek gizli katmana sahip ağlar yeterli doğrulukla sınıflandırma yapabilmektedir. Fakat çalışmalar göstermiştir ki çift katmana sahip ağlar tek olanlara göre daha başarılıdır (Chegini ve ark., 2008). İki gizli katmanlı ağlarda nöron sayılarını belirlemek daha karmaşık ve zaman alan bir işlemdir. İşlem yükü artmakta ama daha az nöronla etkili sonuçların alınması da mümkün olmaktadır.

İkiden fazla gizli katman, eğitimi çok zor olduğu için kullanışlı olmamaktadır (Hagan ve ark., 1996). Bunun nedeni katmanlar arasında kullanılan “ezici-sıkıştırıcı” transfer fonksiyonlarıdır. Sonsuz giriş aralığını, sonlu bir çıkış aralığına götüren bu fonksiyonlar işlem yükünü arttırmaktadır.

### *Eğitim Algoritmaları*

Çeşitli algoritmalar ile öğrenme sağlanmaktadır. “Eğitim” olarak adlandırılan bu algoritmaların temel işlevi en doğru sonucu verecek YSA modelini elde etmek için ağırlık katsayılarını ve eşikleri ayarlamaktır. Danışmalı öğrenme için en yaygın eğitim yöntemi *Geri Yayılımdır*. Geri yayılım yöntemi, Şekil 2.7’de görüldüğü gibi ağırlıkların rastgele atanmasıyla başlamaktadır. Eğitim verisinden gerçek çıkışı (yani *hedefi*) bilinen bir giriş seti alınıp ağa uygulanmaktadır. İşlemler ileri doğru yürütülerek yeni çıkış, yani *tahmin* elde edilmektedir. Tahmin ile hedef arasındaki sayısal fark *hatayı* vermektedir. Hata ile nöronların düzeltme katsayıları geriye doğru hesap edilmektedir. Düzeltme katsayıları ağırlıkların ve eşiklerin güncellenmesinde kullanılmaktadır. Ağırlıklar ve eşik değerleri hataya göre ayarlandıktan sonra yeni bir giriş seti ve hedef alınarak işlemler tekrarlanmaktadır. Her tekrar bir “devir” olarak adlandırılmaktadır. Her devirde hata azalarak eğitim sonunda hedefe en yakın çıkışları veren ağ elde edilmiş olur.



Şekil 2.7. Geri yayılım ile ağıın eğitimi

YSA eğitiminde genel olarak hata “Ortalama Hata Kareleri” veya “Ortalama Mutlak Hata” fonksiyonları ile hesaplanmaktadır. Sınıflandırma ağlarında çıkış kümesinin  $\{1,0\}$  şeklinde lojistik olmasından dolayı hata fonksiyonu “Çapraz Entropi” ile hesaplanmaktadır (Bishop, 1995). Eşitlik 2.2’de çapraz entropi hata fonksiyonunun formülü verilmiştir. Formülde  $t$  hedef,  $y$  çıkış,  $i$  de çıkış vektöründeki eleman indisini göstermektedir. Formüle göre minimum hata, tüm  $i$ ’ler için  $i^n = y^i$  olduğunda gerçekleşir. Eğitim algoritmaları bu hata fonksiyonun türevini kullanarak ağırlık ve eşik değerlerini güncellemektedir. Hata fonksiyonunun çalışılan problem için konveks olmasına dikkat edilmelidir. Konkav hata fonksiyonları ağıın eğitimi sırasında yerel minimumlardan

dolayı optimizasyon hatalarına sebep olmaktadır (Hagan ve ark., 1996). Bu nedenle hata fonksiyonunun seçimi eğitim algoritmalarının başarısını doğrudan etkilemektedir.

$$E = - \sum_i \{t^i \ln y^i + (1 - t^i) \ln 1 - y^i\} \quad (2.2)$$

Birçok farklı geri yayılım eğitim algoritması geliştirilmiştir (Alpaydın, 2010). Bu algoritmalarındaki temel farklılık, düzeltme katsayılarının hesabı ve ağırlıkların güncellenme şeklidir. Sınıflandırma ağları için dört geri yayılım algoritmasının başarılı olduğunu bildirilmiştir (Bishop, 1995). Bunlar “Levenberg-Marquard Geri Yayılım” (Marquardt, 1994), “Bayes Düzenleme Geri Yayılım” (MacKay, 1992), “RPROP Geri Yayılım” (Riedmiller ve Braun, 1993) ve “Ölçeklendirilmiş Eşlenik Eğitim Geri Yayılım” (Moller, 1993)’dır. Levenberg-Marquard ve Bayes düzenleme algoritmaları diğerlerine göre hızlıdır fakat daha çok hafızaya ihtiyaç duymaktadırlar. Levenberg-Marquard algoritması lineer olmayan regresyon problemlerinin çözümünde diğerlerinden daha hızlı ve düşük hata oranıyla çalışmaktadır (Hagan ve Menhaj, 1994). Sınıflandırma problemlerinde en iyi çözümü ölçeklendirilmiş eşlenik eğitim geri yayılım algoritması vermektedir (Moller, 1993; Bishop, 1995).

Farklı skalalardaki girişlerin doğrudan ağa uygulanması hata fonksiyonunun eliptikliğinin artmasına dolayısıyla hata yüzeyinde keskin inişlere sebep olur. Optimizasyonu olumsuz etkileyen bu durumun önüne geçmek için girişlerin -1 ve +1 arasına normalizasyonu yapılmaktadır.

### *Transfer Fonksiyonu*

Ağırlıklandırılmış girişlerin ve eşik değerinin toplamının uygulandığı transfer fonksiyonunun çıkışı nöronun çıkışıdır. Dolayısıyla transfer fonksiyonu doğrudan yapay nöronun karakteristiğini belirtmektedir. Ağ yapısı ve araştırılan problemin niteliğine göre çeşitli transfer fonksiyonları kullanılmaktadır (Alpaydın, 2010).




En yaygın kullanılan transfer fonksiyonları:

- Sert limit (Eşitlik 2.3; Şekil 2.8)
- Simetrik Sert Limit (Eşitlik 2.4; Şekil 2.9)
- Lineer (Eşitlik 2.5; Şekil 2.10)
- Logaritmik Sigmoid (Eşitlik 2.6; Şekil 2.11)
- Hiperbolik Tanjant Sigmoid (Eşitlik 2.7; Şekil 2.12)


fonksiyonlarıdır.

$$\text{hardlim}(n) = a = \begin{cases} 0, & n < 0 \\ 1, & n \geq 0 \end{cases} \quad (2.3)$$




Şekil 2.8.  $\text{hardlim}(n)$  transfer fonksiyonunun grafiksel gösterimi (Hagan ve ark., 1996)

$$\text{hardlims}(n) = a = \begin{cases} -1, & n < 0 \\ 1, & n \geq 0 \end{cases} \quad (2.4)$$




Şekil 2.9.  $\text{hardlims}(n)$  transfer fonksiyonunun grafiksel gösterimi (Hagan ve ark., 1996)

$$\text{purelin}(n) = a = n \quad (2.5)$$




Şekil 2.10. purelin(n) transfer fonksiyonunun grafiksel gösterimi (Hagan ve ark., 1996)

$$\text{logsig}(n) = a = \frac{1}{1+e^{-n}} \quad (2.6)$$



Şekil 2.11. logsig(n) transfer fonksiyonunun grafiksel gösterimi (Hagan ve ark., 1996)

$$\text{tansig}(n) = a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (2.7)$$



Şekil 2.12. tansig(n) transfer fonksiyonunun grafiksel gösterimi (Hagan ve ark., 1996)

Transfer fonksiyonları ağ işlemleri içinde önemli bir yer tutmaktadır. Yüksek doğruluk sağlamak için uygun bir transfer fonksiyonu seçilirken toplam işlem yükünün çok arttırılmamasına dikkat edilmelidir.


Sınıflandırma ağlarında son katmandaki nöronlarda “softmax” transfer fonksiyonu kullanılmaktadır. Eşitlik 2.8’de matematiksel ifadesi verilen bu fonksiyon, YSA çıkışlarını sınıflarla ilişkili olasılık olarak almaktadır.

$$a_i = f(n_i) = \frac{\exp(n_i)}{\sum_{j=1}^S \exp(n_j)} \quad (2.8)$$

Eşitlikte  $S$  sınıf sayısını,  $j$  indisini vermektedir.  $i$  çıkışın indisidir. Çıkışlar 0 ve 1 arasında bir sayı olmakta ve bir çıkış setinin toplamı 1’e eşit olmaktadır. En yüksek çıkış veren nöronun değerini 1, diğerlerini 0 alarak sınıflandırmayı yapmaktadır.

#### *Doğrulama*


YSA’nın sürekli eğitimi belirli bir aşamadan sonra model performansının istenilen seviyenin altına düşmesine sebep olmaktadır. Aşırı öğrenme veya ezber denilen bu durum modelin tamamen eğitim kümesine adapte olup farklı girişleri tanımamasından kaynaklanmaktadır. Şekil 2.13’de bu durumun bir örneği gösterilmektedir. Koordinat düzlemindeki noktalara en uygun eğrinin bulunmasının hedeflendiği bu örnekte en uygun eğrinin “C” grafiği olduğu düşünülebilir. Fakat yeni veriler değerlendirilirse en az hata “B” grafiğindeki eğriden elde edilecektir. Bu nedenle modelin ezbere gitmeden eğitimin sonlandırılması gerekmektedir.



Şekil 2.13. Eğri uydurma için öğrenememe (A), tam öğrenme (B) ve ezber (C) durumları

Bazı çalışmalarda eğitim devri belirli bir sayıyla sınırlandırılarak (örneğin 100) ezberin önüne geçilmeye çalışılmıştır (Erentürk ve Erentürk, 2007). Devir sayısına göre sonlandırma eğitimin tam olarak gerçekleştirilip gerçekleştirilmediğinin anlaşılmasını engeller. Ezberden sakınarak tam öğrenmeyi sağlamanın en iyi yolu doğrulama yapmaktır (Hagan ve ark., 1996).

Doğrulama için eğitim ve test veri setlerinden farklı, veri sayısı genelde test veri seti kadar olan üçüncü bir set tüm veri setinden ayrılmaktadır. Eğitimin her devrinde, doğrulama seti model ile yürütülerek hatası kaydedilmektedir. Eğitim süresince bu hata sürekli düşmelidir. Artış gösterirse buna “doğrulama hatası” denir. Şekil 2.14’de eğitim süresince test ve doğrulama setlerinden alınan hatanın değişimi gösterilmektedir.



Şekil 2.14. Eğitim süresince doğrulama ve eğitim hatalarındaki değişim

Belirli bir sayıda doğrulama hatası üst üste alındığında artık model ezber durumuna giriyor demektir. Bu anda eğitim durdurulmalıdır. Doğrulama seti doğrudan eğitime katılmasa da eğitimin sonlandırılması için kullanılmaktadır. Bu nedenle doğrulama veri seti eğitim setinde olduğu gibi model performanslarının değerlendirilmesinde kullanılmaz.

### 2.3 Sınıflandırma modellerinin başarılarının değerlendirilmesi

YSA başarısı, genel olarak ağın toplam hata değeri ile belirlenmektedir. Sınıflandırma ağlarında başarı için özel olarak sınıflandırmanın doğru yapıp yapılmadığının gösterilmesi gerekmektedir. Başarılarının sayısal olarak ifade edilmesi için “Hata Matrisi” kullanılmaktadır. Hata matrisi test sonuçlarının bütünüdür. Şekil 2.15’de hata matrisi üzerindeki değerlerin yerleşimi görülmektedir. Matriste, sınıflandırma kuralına uygun olarak kızgınlıkta olma durumu (olumlu) pozitif sınıf “1”, olmama durumu (olumsuz) negatif sınıf “2” ile kodlanmıştır.

1	DPS	YPS	$\frac{DPS}{(DPS+YPS)}$	
	DPS/T	YPS/T	$\frac{YPS}{(DPS+YPS)}$	
2	YNS	DNS	$\frac{DNS}{(DNS+YNS)}$	
	YNS/T	DNS/T	$\frac{YNS}{(DNS+YNS)}$	
		$\frac{DPS}{(DPS+YNS)}$	$\frac{DNS}{(DNS+YPS)}$	$\frac{(DPS+DNS)}{T}$
		$\frac{YNS}{(DPS+YNS)}$	$\frac{YPS}{(YPS+DNS)}$	$\frac{(YNS+YNS)}{T}$
		1	2	
		Gözlem		

Şekil 2.15. Hata matrisinde değerlerin yerleşimi

Matristeki kısaltmaların açıklamaları aşağıdaki gibidir:

- DPS: Doğru Pozitif Sayısı. Gerçekte sınıf pozitifken modelin pozitif sınıf tahmin etmesidir.
- DNS: Doğru Negatif Sayısı. Gerçekte sınıf negatifken modelin negatif sınıf tahmin etmesidir.
- YPS: Yanlış Pozitif Sayısı. Gerçekte sınıf negatifken modelin pozitif sınıf tahmin etmesidir. 1. tip hata olarak da adlandırılır.
- YNS: Yanlış Negatif Sayısı. Gerçekte sınıf pozitifken modelin negatif sınıf tahmin etmesidir. 2. tip hata olarak da adlandırılır.
- T: Toplam çıkış. DPY, DNS, YPS, YNS toplamı.

Sınıflandırma modellerinde doğruluk, pozitif ve negatif tüm doğru tahminlerin, toplam tahmine bölünmesi ile hesaplanır. Modelin genel doğruluğunu gösterir. Eşitlik 2.9'da formülü verilmiştir. Karşılaştırma matrisinde 5. satır 3. sütunda gösterilmektedir.

$$A = \frac{DPS + DNS}{DPS + YPS + DNS + YNS} \quad (2.9)$$

Doğruluk genel bir ölçüt olarak kabul edilse de sınıflandırma modelinin başarısını göstermede yetersizdir. Problem için değerli olan pozitif sınıfın tahmini istenilen başarıya ulaşmasa dahi negatiflerin yüksek oranda doğru tahmin edilmesi doğruluk oranını yükselterek modeli başarılı göstermektedir. Sınıflandırma ağlarının başarımlarının doğru değerlendirilmesi ve karşılaştırmalarının objektif yapılması için duyarlılık, kesinlik, F Skoru ve ROC puanı hesaplamalarından yararlanılmaktadır.

### 2.3.1 Duyarlılık

Duyarlılık, modelin gerçekleşen kızınlıkların ne kadarını tahmin edebildiğinin göstergesidir. DPS'nin tüm pozitif gözlem sayısına oranıdır. "Doğru pozitif oranı", "yakalama oranı" veya "recall" olarak da adlandırılır. Eşitlik 2.10 ile gösterilmiştir. S ile ifade edilen duyarlılık karşılaştırma matrisinde 5. satır, 1. sütunda bulunmaktadır.

$$S = \frac{DPS}{DPS + YNS} \quad (2.10)$$

### 2.3.2 Kesinlik

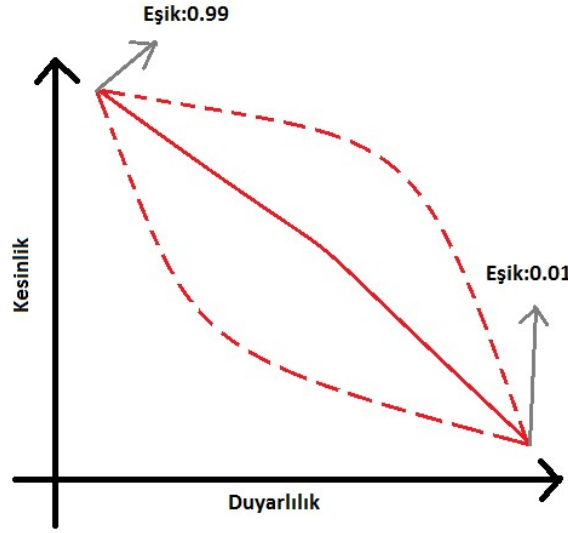
Kesinlik, pozitif tahmin edilenlerin ne kadarının doğru tahmin edildiğinin göstergesidir. P ile gösterilir. Eşitlik 2.11'de matematiksel ifadesi verilmiştir. Karşılaştırma matrisinde 1. satır, 3. sütunda bulunmaktadır.

$$P = \frac{DPS}{DPS + YPS} \quad (2.11)$$

### 2.3.3 F Skoru

Pozitif sınıfın öneminden dolayı başarılı bir sınıflandırma modelinden beklenen duyarlılık ve kesinliğin yüksek olmasıdır. Fakat bu iki ölçüt, modelin karar eşiğine göre ters orantılı olabilmektedir. Şekil 2.16’da değişen karar eşiğine göre kesinlik ve duyarlılık arasındaki bağıntı verilmiştir. Sınıflandırma modeline göre bu eğri kesikli çizgiyle gösterilen şekillerde de olabilmektedir.

Modellerin sınıflandırma başarıları değerlendirilirken hem duyarlılık hem kesinlik beraber dikkate alınmalıdır. Bu gibi iki başarının beraber değerlendirilmesi gerektiği durumlarda genelde ortalama alınmaktadır. Fakat bu büyüklüklerin ortalamaları doğru değerlendirmelerini sağlamamaktadır. Birisi çok küçük birisi çok büyük olduğu durumlarda model, ortalamalarına göre başarılı görülmekte fakat maliyetli bir sınıflandırma söz konusu olmaktadır. Duyarlılığın çok küçük olması pozitif sınıfların kaçırılmasının, kesinliği çok küçük olması yanlış pozitif uyarılarının bir göstergesidir.



Şekil 2.16. Kesinlik ve duyarlılık arasındaki ödünleşim

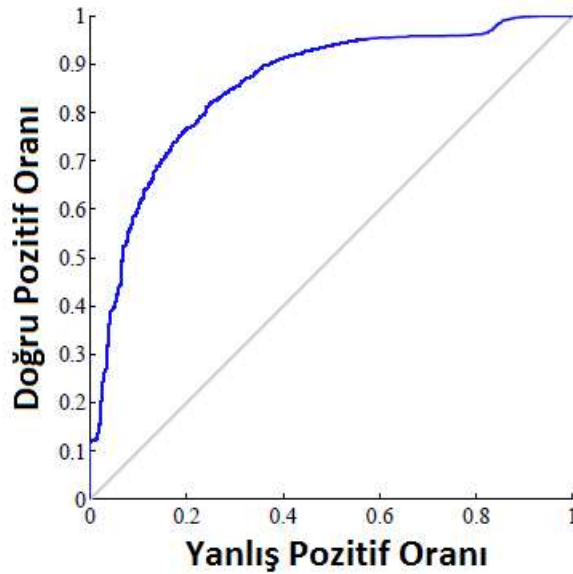
F skoru duyarlılık ve kesinliğin beraber değerlendirilmesi için yeterli bir ölçüttür. Duyarlılık ve kesinliğe göre hesabı Eşitlik 2.12’de verilmiştir. İki değerinde büyük olması durumunda F skoru 1’e yaklaşır. En az birinin azalması değeri de azaltır. F skoru 0 ile 1 arasında değer alır.

$$F = 2 \times \frac{P \times S}{P + S} \quad (2.12)$$

### 2.3.4 ROC ( Receiver Operating Characteristic) Analizi

Türkçe açılımı “Alıcı İşlem Karakteristiği”dir. Haberleşmede, işaret algılama teorisinde kullanılan bir eğridir (Fawcett, 2006). Sınıflandırma yapılan kümede pozitif ve negatif örnekler eşit bir dağılım göstermeyebilir. Böyle durumlarda en iyi ağın belirlenmesi amacıyla ROC analizi kullanılabilir (Gribskov ve Robinson, 1996).

ROC eğrisi, değişen ayırma eşik değerlerine göre doğru pozitif oranının, yanlış pozitif oranına bir fonksiyonu olarak çizilmesidir. Doğru pozitif oranı, duyarlılıktır. Yanlış pozitif oranı 1’den kesinliğin farkıdır. Şekil 2.17’de örnek bir ROC eğrisi gösterilmiştir.



Şekil 2.17. ROC eğrisi örneği (Hagan ve ark., 1996)

Tam doğru bir sınıflandırma modelinde ideal ROC eğrisi (0,0) noktasından (0,1)’e, oradan da (1,1) noktasına gitmelidir. Bu durum hiç yanlış pozitif tahmini olmadan tüm gerçek pozitifler doğru tahmin edilmiş demektir. Eğri, (0,1) noktasına ne kadar yakınsa model o kadar başarılı olmaktadır. Eğrinin sınır ekseni olarak adlandırılan  $y = x$  doğrusunun altına düşmesi sınıflandırmanın başarısız olduğunu göstermektedir. YSA



modelinin başarısı ROC eğrisi altında kalan alan ile ifade edilebilmektedir (Bradley, 1997). AUC (Area Under Curve) olarak ifade edilen bu alana ROC puanı da denmektedir.



### 3. MATERYAL VE YÖNTEM

#### 3.1 Denemelerin Gerçekleştirildiği Tarım İşletmesi ve Gözlem Hayvanları

Çalışma kapsamında yapılan gözlemler ticari bir süt sığırcılığı tarım işletmesinde (40°20'19'' Kuzey, 36°8'44'' Doğu') gerçekleştirilmiştir. İlgili işletme, Tokat il merkezine 37 km uzaklıkta, Tokat Turhal karayolu üzerinde olup 5415 da alana sahiptir. Kaba yem ihtiyacı kendi arazisinden karşılanmaktadır. İşletmede hayvanların bakımı ve kontrolüne yönelik gerekli veterinerlik gereçleri bulunmaktadır. İşletmedeki ahırlar beton zeminli ve yarı açık tiptedir (Şekil 3.1). Buzağılayan hayvanlar 1 No.lu ahırda toplanmakta ve ilk tohumlamaya kadar burada bakımları yapılmaktadır.



Şekil 3.1. Tarım işletmesinde bulunan 1 No.lu ahır

Yüz yirmi baş hayvan kapasiteli 1 no'lu ahır 72 m × 19.5 m ölçülerinde, duraklı sistem, otomatik sıyrıklı ve poliüretan yataklıdır. Hayvan başına 4.8 m<sup>2</sup> açık, 5.64 m<sup>2</sup> kapalı gezinti alanına sahiptir (Şekil 3.2).



Şekil 3.2. Ahırlarda açık gezi alanı

Hayvanlar tohumlamadan sonra 2 No.lu ahıra alınmaktadır. Bu ahır iki yüz elli baş hayvan kapasiteli, 95.8 m × 49.8 m alana sahip, duraklı sistem, otomatik sıyrığı, poliüretan yataklıdır (Şekil 3.3). Hayvan başına gezinti alanı; açıkta 6.2 m<sup>2</sup>, kapalıda 5 m<sup>2</sup>'dir.




Şekil 3.3. Tohumlanan hayvanların alındığı 2 No.lu ahır

İşletmede dönerli (rotary) sağım ünitesiyle tümleşik olarak Dairy Plan (GEA Westfalia Surge) sürü yönetim yazılımı kullanılmaktadır. Bu yazılımda hayvanların doğum ve buzağılama tarihleri, aşı ve ilaç geçmişleri gibi her türlü veteriner kayıtları, ayrıca

laktasyon sayıları, süt verimleri ve sağımdan sağıma alınan hareket verileri sürekli kayıt altında tutulmaktadır. Günde yaklaşık 8 saat aralıklarla 3 defa sağım yapılmaktadır.

Hayvanların izlenebilmesi için kameralı görüntüleme sistemi kullanılmıştır. Sistem yedi kamera ve bir görüntüleme-kayıt merkezinden oluşmaktadır. Kameraların montajı ahırlarda hayvanların rahat gözlemleneceği yüksek noktalara yapılmıştır (Şekil 3.4).



Şekil 3.4. Ahıra monte edilen kameralardan biri

Sağım ünitesi içerisindeki ofise kamera gözlem merkezi kurulmuştur (Şekil 3.5). Gözlem istasyonu yardımıyla hayvanlar sürekli takip edilebilmektedir.



Şekil 3.5. Gözlem-kayıt merkezi

Kızgınlıkların izlenebilmesi için sağlıklı, Holstein cinsi süt sığırlarından ilk üç laktasyon döneminde olan 114 hayvan seçilmiştir. Seçilen tüm hayvanlar işletmenin genel bakım kuralları çerçevesinde değerlendirilmiştir. Gözlemler süresince seçilen hayvanlara özel bir uygulama yapılmamıştır. Bu nedenle 22 baş hayvan topallık, verim düşüklüğü vb. sebeplerle veteriner onayıyla kesime gönderilmiştir. Kalan 92 hayvanın gözleminden elde edilen veriler ile çalışma devam ettirilmiştir. İşletmede hayvanlarla ilgili tüm kayıtlar Gıda, Tarım ve Hayvancılık Bakanlığı tarafından her hayvan için ayrı atanan çiftçi kayıt sistemi barkod numarasına göre tutulmaktadır. Çalışmada gözlemlenen hayvanların rahat takip edilebilmesi için “Küpe No” olarak adlandırılan bu barkod numaraları büyükten küçüğe sıralanıp 1-92 arasında “Hayvan No” ataması yapılmıştır. Çizelge 3.1’de çalışma süresince gözlemlenen hayvanlar gösterilmektedir.

Çizelge 3.1. Gözlemlenen hayvanlar

Küpe No	Hayvan No	Laktasyon Sayısı	Doğum Tarihi
TR16778505	1	3	17.09.2009
TR16778560	2	3	01.11.2009
TR16778578	3	3	16.11.2009
TR16778583	4	3	02.10.2009
TR16778633	5	3	10.10.2009
TR16778658	6	3	31.08.2009
TR16778706	7	3	03.10.2009
TR16778870	8	3	25.11.2009
TR16778886	9	2	17.09.2009
TR16778905	10	3	07.10.2009
TR16778930	11	3	17.11.2009

Çizelge 3.1. Gözlemlenen hayvanlar (devamı)

Küpe No	Hayvan No	Laktasyon Sayısı	Doğum Tarihi
TR16779003	12	3	13.10.2009
TR601045040	13	1	17.01.2011
TR601045059	14	2	22.01.2011
TR601045100	15	1	11.02.2011
TR601045102	16	1	12.02.2011
TR601045127	17	2	24.02.2011
TR601045152	18	2	09.03.2011
TR601045163	19	2	19.03.2011
TR601045219	20	2	19.04.2011
TR601045224	21	2	24.04.2011
TR601045230	22	1	01.05.2011
TR601045237	23	2	02.05.2011
TR601045242	24	1	05.05.2011
TR601045273	25	2	25.05.2011
TR601045289	26	2	01.06.2011
TR601045323	27	1	24.06.2011
TR601045340	28	2	05.07.2011
TR601045377	29	2	18.07.2011
TR601045383	30	2	20.07.2011
TR601045388	31	1	22.07.2011
TR601045479	32	2	23.08.2011
TR601163119	33	3	21.10.2009
TR601163145	34	2	25.10.2009
TR601163156	35	2	01.09.2009
TR601163187	36	3	04.09.2009
TR601163189	37	3	04.09.2009
TR601171564	38	2	11.09.2011
TR601171581	39	2	15.09.2011
TR601171640	40	1	26.09.2011
TR601171667	41	2	01.10.2011
TR601171671	42	2	01.10.2011
TR601171692	43	2	06.10.2011
TR601171734	44	1	16.10.2011
TR601171758	45	1	22.10.2011
TR601171764	46	2	23.10.2011
TR601171793	47	1	29.10.2011
TR601171796	48	2	30.10.2011
TR601171808	49	1	02.11.2011
TR601171818	50	1	03.11.2011
TR601171820	51	1	04.11.2011
TR601171874	52	2	14.11.2011

Çizelge 3.1. Gözlemlenen hayvanlar (devamı)

Küpe No	Hayvan No	Laktasyon Sayısı	Doğum Tarihi
TR601171876	53	2	15.11.2011
TR601180092	54	1	15.01.2012
TR601180128	55	1	04.02.2012
TR601180168	56	1	23.02.2012
TR601180190	57	1	01.03.2012
TR601180210	58	1	14.03.2012
TR601180228	59	1	20.03.2012
TR601180267	60	1	11.04.2012
TR601180284	61	1	23.04.2012
TR601180310	62	1	16.05.2012
TR601180402	63	1	20.07.2012
TR601180417	64	1	28.07.2012
TR601277095	65	1	22.10.2012
TR60637191	66	3	15.01.2008
TR60825293	67	2	10.12.2008
TR60834811	68	3	03.09.2009
TR60834984	69	3	23.11.2009
TR60861257	70	3	28.11.2009
TR60861293	71	3	12.12.2009
TR60861450	72	3	01.02.2010
TR60861459	73	3	06.02.2010
TR60861523	74	3	28.02.2010
TR60861567	75	1	26.03.2010
TR60861588	76	3	04.04.2010
TR60861619	77	3	12.04.2010
TR60861648	78	3	21.05.2010
TR60861660	79	3	24.05.2010
TR60861675	80	3	31.05.2010
TR60861686	81	3	13.06.2010
TR60861709	82	3	02.07.2010
TR60861711	83	3	03.07.2010
TR60948761	84	2	07.08.2010
TR60948769	85	2	14.08.2010
TR60948827	86	3	27.09.2010
TR60948838	87	3	06.10.2010
TR60948881	88	2	08.11.2010
TR60948930	89	2	06.12.2010
TR60948976	90	2	27.12.2010
TR60948995	91	2	02.01.2011
TR60948997	92	3	02.01.2011

### 3.2 İklim Verilerinin Toplanması

Sıcaklık, nem, rüzgâr gibi iklimsel hava şartları büyükbaş hayvanların davranışlarını etkilemektedir (Sönmez ve ark., 2005). İklimsel şartlardan kaynaklanan bu davranış değişikliğinin kızgınlık belirleme üzerine etkisinin incelenmesi için ahırlardaki ve çiftlikteki iklimsel veriler çalışma süresince kaydedilmiştir. İklim verilerinin ölçülmesi ve kaydedilmesi için ahırların bulunduğu alanın ortasına denk gelecek şekilde açık alana iMetos AG/CP/DD 300 (Metos, Hassfurt), gözlemlerin yapıldığı ahırların içine de birer adet iMetos AG/CP/DD 100 (Metos, Hassfurt) iklim ölçüm istasyonu kurulmuştur. Şekil 3.6'da dışarıda bulunan istasyon görülmektedir.



Şekil 3.6. Tarım işletmesine kurulan iklim istasyonu

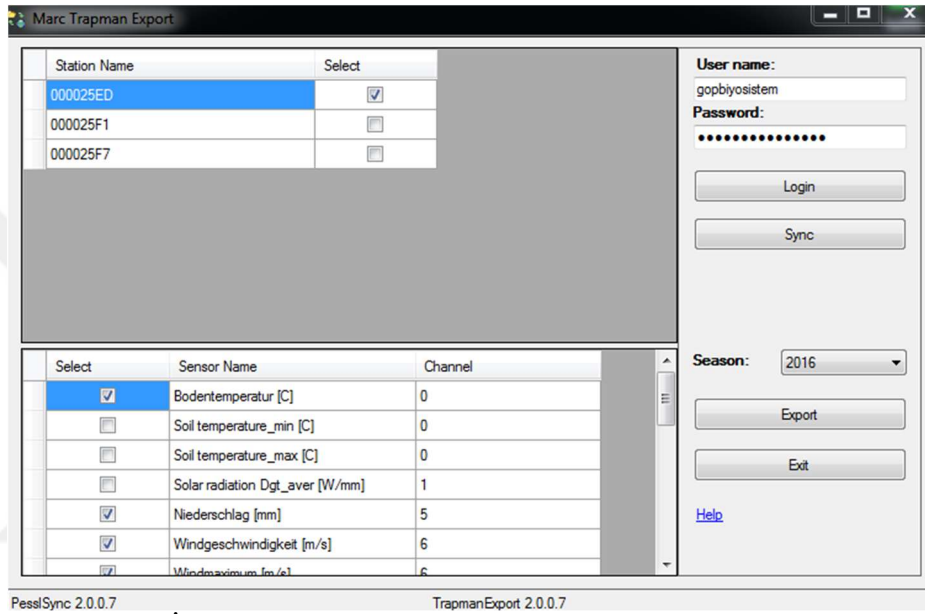
Ahırlardaki istasyonlar nem, sıcaklık ve çiglenme noktası değerlerini ölçmektedir. Dışarıdaki istasyon ise sıcaklık, nispi nem, barometrik basınç, solar radyasyon, rüzgâr hızı ve yönü, yağış, 20 cm derinlikten toprak sıcaklığı ve çiglenme noktasını ölçmektedir. İstasyonlar, ölçümlerini dakikalık yapıp 10, 20, 30, 60 ve 120 dakikalık ortalamalarla kaydedebilmektedirler. Dışarıdan bir güç kaynağına ihtiyaç duymaksızın üzerlerinde bulunan fotovoltaik paneller ve bataryalarıyla kendi enerji ihtiyaçlarını karşılamaktadırlar. GSM modülü ile istenilen kayıt aralığında topladıkları verileri internetteki veri tabanına kaydetmektedirler. Toplanan verilere WEB üzerinden (Şekil 3.7) veya firmanın uygulamaları yardımıyla ulaşabilmektedir.





Şekil 3.7. İklim verilerine ulaşılmasını sağlayan WEB arayüzü

İklim istasyonları tüm ölçümleri en yüksek, en düşük ve ortalama olacak şekilde saatlik alıp internet veri tabanına kaydedecek şekilde ayarlanmıştır. İstasyonlar 8 Mayıs 2014, saat 10:00'dan itibaren iklim verilerini toplamaya başlamıştır. İnternet veri tabanında bulunan ölçümlerin bilgisayara indirilmesi için istasyon firmasının ücretsiz sağladığı Trapman Export yazılımı kullanılmıştır (Şekil 3.8). Bilgisayar işletim sistemi ile zamanlanmış görev ataması yapılarak verilerin haftalık güncellenmesi sağlanmıştır.



Şekil 3.8. İklim veri tabanından ölçümleri otomatik indiren yazılım

Hayvanların iklimsel etmenlerden dolayı konfor veya stres altında olmaları hareketlerini doğrudan etkilemektedir (Sönmez ve ark., 2005). Bu etkinin incelenmesi için tek başına sıcaklık yeterli olmamaktadır. Havanın nemi sıcaklığın hissedilmesini etkilemektedir. Bu nedenle konfor ve stres şartlarını tanımlamamız için nem ve sıcaklığın etkisini birlikte gösteren Sıcaklık Nem İndeksi (SNİ) sayısı kullanılmıştır (Garcia, 2006). İklim verilerinin ölçüldüğü her saat için Eşitlik 3.1 kullanılarak SNİ hesaplanmıştır.

$$SNİ = s + (0.36 \times c) + 41.2 \quad (3.1)$$

Eşitlikte  $s$ , °C cinsinden saatlik ortalama kuru termometre sıcaklığı,  $c$  saatlik ortalama çiğlenme noktasıdır. SNİ hesaplamaları Microsoft Office Excel elektronik tablo programında yapılmıştır.

### 3.3 Hareket ve Kızgınlık Verilerinin Toplanması

Tarım işletmesinde hayvanların hareketlerinin takibi için Kızgınlık ve Hastalık Takip Sistemi (Robolab MOO, Konya) kullanılmaktadır. Bu sistem işletmede kullanılan sürü takip sisteminden bağımsız çalışmaktadır. Sistem, ineklerin bileklerine takılan pedometreler (Şekil 3.9), ara istasyonlar ve merkez sunucudan meydana gelmektedir. Pedometrelerin bir tanesinin genel görünümü Şekil 3.10’da verilmiştir.



Şekil 3.9. Hayvanın bileğine takılan pedometre



Şekil 3.10. Hareket ölçümünde kullanılan pedometre

Pedometreler saatlik verileri kablosuz veri aktarımı ile ahırlarda bulunan ara istasyonlara ulaştırmaktadır. Şekil 3.11’de ahıra yerleştirilmiş ara istasyon görülmektedir. Ara istasyonlar verileri merkez sunucuya ulaştırmakta ve ulaşan veriler burada değerlendirilmektedir.



Şekil 3.11. Hareket takip sistemi ara istasyonu

Hareket takip sistemi pedometrelerin içlerinde bulunan ivme algılayıcısından okuduğu değerlerle bir hareket sayısı hesaplamakta bu sayıyı aktivite verisi olarak değerlendirmektedir. Pedometreler doğrudan adım saymamaktadır. Ayrıca hareketlilikle beraber ineklerin yatma süreleri de ölçülmektedir. Aktivite ve yatma verileri merkez sunucudaki veri tabanına kaydedilmektedir. Mantıksal bir sınama ile eşik değerinden yüksek aktivite ve düşük yatma gösteren inekler için kızgınlık uyarısı verilmektedir. Şekil 3.12’de tipik bir kızgınlık durumunda toplanan verilerin merkezi sistem kontrol ekranındaki görüntüsü verilmiştir. Eşik aktivasyon değeri 4000 olarak sistem kurucuları tarafından daha önce atanmıştır ve hayvanlara göre değişiklik göstermemektedir.

İşletmede kullanılan kızgınlık takip sistemi, hayvanların pedometrelerinden gelen aktivite sayılarını merkezinde bulunan veri tabanına kaydetmektedir. Çalışmada değerlendirmek için bu veri tabanının yedeği alınmıştır. MySQL Workbench (Oracle, ABD) yazılımı kullanılarak yedek veri tabanı çözümlenmiştir. Çalışmada gözlemlenen hayvanların aktivite sayıları SQL sorgularıyla süzülüş, alındığı saat göz önünde bulundurularak hareket verisi olarak kaydedilmiştir.

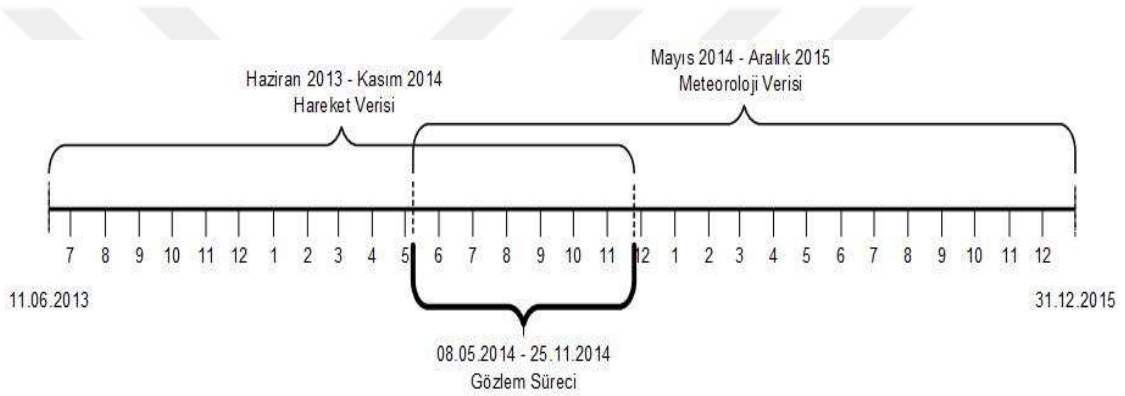
İşletmede veteriner kayıtlarına göre oluşturulmuş takvimler ve mevcut kızgınlık tahmin sistemi kullanılarak kızgınlıklar takip edilmiştir. Takvim takibine göre kızgınlığı yaklaşan hayvanlar için sürü yönetim sistemi 5 gün önceden uyarı vermeye başlamaktadır. Bakıcılar ve veterinerler gözlemlerini bu hayvanlara yoğunlaştırmışlardır. Kızgınlığın belirlenmesi durumunda sisteme kızgınlık kayıt girişi yapılmıştır.

Kızgınlık gösteren hayvan zamanı geldiğinde tohumlama yapılabilmesi için ayrı bir bölme alınmıştır. Mevcut kızgınlık takip sistemi uyarı verdiğinde bakıcılar uyarı veren hayvanı gözlemlemişler, uyarı doğru ise kayda geçmiş uyarı yanlış ise hayvanı yoğun gözlem listesinde bir müddet daha izlemişlerdir. Gözlemler doğrudan yapıldığı gibi, kamera kayıt sisteminden de yararlanılmıştır. Kamera kayıt sistemi canlı görüntü aktarmakta ve bu görüntüleri sürekli kaydetmektedir. Yoğun gözlem yapılan dönemlerde hayvanlar canlı izlenmiştir. Kızgınlıkların onaylanmasında kaydedilen görüntülerden faydalanılmıştır.



### 3.4 Tahmin Modellerinin Denenmesi

Tahmin modellerinin denenmesi için öncelikle toplanılan tüm veri, modellerin eğitim ve testinde kullanılacak şekilde düzenlenmiştir. Bunun için alınan iklim ve adım verilerinin zamansal olarak kesiştiği aralık belirlenmiştir. Şekil 3.13’de görüldüğü gibi iki veri 08.08.2014 ve 25.11.2014 tarihleri arasında kesişmektedir. Bu aralık gözlem süreci olarak isimlendirilmiştir.



Şekil 3.13. Alınan verilerin zaman çizelgesinde gösterimi

Çalışmada kızgınlık takibi yapılan her hayvan için gözlem sürecinin saatlik zaman serisi oluşturulmuştur. Daha sonra hareket takip sisteminden hareket verisi, iklim istasyonundan sıcaklık, bağıl nem ve SNİ, veteriner kayıtlarında da laktasyon sayısı, o anki gün cinsinden yaşı ve kızgınlık durumu zaman serilerinin her saati için kaydedilmiştir.

Ahırlarda çeşitli yerlere yerleştirilen ara istasyonlardan yararlanılarak ineklerin hareket verisi yollama anında buldukları ahırlar belirlenebilmektedir. Böylece verinin alındığı anda hayvanın bulunduğu ahır belirlenerek o ahırdaki iklim istasyonundan yararlanılması mümkün olmaktadır. Sıcaklık, nem ve SNİ'nin kaydında hayvanın bulunduğu ahırdaki iklim istasyonundan yararlanılmıştır.

Bu işlemler sonucunda tahmin modellerinin oluşturulması, eğitilmesi ve testi için kullanılan “deneme verisi” elde edilmiştir. Deneme verisi incelendiğinde bazı hareket bilgilerinin eksik olduğu anlaşılmıştır. Bu eksikliğin mevcut kızgınlık belirleme


sistemindeki veri iletişim sorunlarından kaynaklandığı düşünülmektedir. Genelde deneme verileri düzenlenirken eksiklik olan satırlar veriden çıkarılmaktadır (Bishop, 1995). Fakat mekanistik model incelemesinde kesintisiz zamansal veriye ihtiyaç duyulması sebebiyle bu eksikliklerin giderilmesi gerekmektedir (Roelofs ve ark., 2005). Eksik kısımların tüm verideki veya belirli bir aralıktaki ortalama alınarak giderilmesi mümkündür (Alpaydın, 2010). Bu ortalama, Denklem 3.2'ye göre hesaplanarak eksikler yerine yazılmıştır.

$$R_e = [R_{tüm} + R_{gün} + R_{saat}]/3 \quad (3.2)$$

Denklemden,  $R_e$  kayıp verinin olası değerini vermektedir.  $R_{tüm}$  serideki tüm hareket sayılarının ortalaması,  $R_{gün}$  de kayıp verinin bulunduğu gündeki hareket sayılarının ortalamasını göstermektedir.  $R_{saat}$  ise tüm serideki kayıp verinin bulunduğu saat dilimi için hareket sayısı ortalamasıdır. Denklem 3.2 ile bu üç ortalamaların ortalaması alınarak kayıp veri yerine yazılmıştır. Tüm ortalamalar eksik olan hayvanın hareket bilgilerine göre hesaplanmıştır. Böylece  $R_{tüm}$  ile hayvan karakteri,  $R_{gün}$  ile günün iklimsel özellikleri,  $R_{saat}$  ile de periyodik yaşamdan kaynaklanan etkiler ortalama hesabına dâhil edilmiştir. Bu yöntemin başarısı rastgele seçilmiş, bilinen 1000 hareket verisinin Denklem 2'ye göre tahmin edilmesiyle test edilmiştir.  $\pm\%5$  hata payı ile  $\%82$  doğrulukla hesaplayabildiği görülmüştür.

Gözlemler sonucu oluşturulan eğitim kümesinde veriler saatlik zaman dilimine göre düzenlenmiştir. Mekanistik modelde ihtiyaç duyulan veri iki saatliktir. Mekanistik modelin denemelerinin yapılabilmesi için bir saatlik veriler kullanılarak iki saatlik veriler elde edilmiştir. Bunu için iki saatlik pencereler ötelenerek, hareket verisi için toplamları; sıcaklık, nem ve SNİ için ortalamaları alınmıştır. Bir saat ötelemeli ve iki saat ötelemeli pencereler ile elde edilen iki saatlik veriler, veri zaman diliminin YSA modellerine etkisinin araştırılması için ayrıca oluşturulmuştur (Şekil 3.14).





Şekil 3.14. YSA eğitimleri için iki saatlik pencereleme şekli

### 3.4.1 Mekanistik modelin denenmesi

Her bir hayvan için ayrı hazırlanmış iki saatlik deneme verileri ile mekanistik model denemeleri gerçekleştirilmiştir. Microsoft Excel yazılımı yardımı ile ortalamalar, standart sapmalar ve karşılaştırmalar yapılmıştır. Karşılaştırmalarda kullanılan ortalamalar son on günlük veri ile yapıldığı için her veride ilk on günlük zaman dilimi için karşılaştırma yapılmamış bu süreden sonrası için değerlendirmeler yapılmıştır. Toplamda 109605 satır veri değerlendirilmiştir. Elde edilen sonuçların değerlendirilmesi MATLAB ile elde edilen hata matrisi ve ROC eğrisi ile yapılmıştır.

### 3.4.2 YSA modellerinin denenmesi

Çalımda YSA hedefi, en iyi sonucu veren sınıflandırma ağının bulunmasıdır. Bu nedenle YSA performansını etkileyen giriş çeşitleri ve topoloji araştırılmıştır. Transfer fonksiyonu ve eğitim algoritması için literatür incelenmiş probleme en uygun olanları seçilerek başarımları kontrol edilmiştir.

Bu çalışmadaki YSA'lar, gerçek kızgınlık gözlemlerinin hedef olarak eğitimde kullanılmasından dolayı danışmalı öğrenmeye örnektir. YSA model yapısı Nadimi ve ark. (2012) tarafından başarılı olduğu rapor edilen ileri beslemeli çok katmanlı hiyerarşik ağ olarak belirlenmiştir. Hayvanların kızgınlık durumlarının incelenmesi bir sınıflandırma problemi olarak ele alınmıştır. Hayvanlar "Kızgınlıkta" ve "Kızgınlıkta Değil" şeklinde iki sınıfa ayrılmıştır. Pozitif durum olarak nitelendirilen "Kızgınlıkta" durumu "1" ile, "Kızgınlıkta Değil" durumu "2" ile kodlanmıştır. Çalışmada YSA'dan istenilen, mevcut

girişlerle hayvanın 1. sınıfta olup olmadığına karar vermesidir. YSA'nın çıkış katmanı iki nöronlu olarak seçilmiştir. Gözlem verisi içindeki çıkış, kızgınlıkta (1.Sınıf) için [1,0], kızgınlıkta değil (2. Sınıf) için [0,1] olacak şekilde düzenlenmiştir. Araştırılan YSA modellerinin çıkış katmanları bu iki sınıfı ifade edecek şekilde iki nöronlu olarak belirlenmiştir.

Tüm deneme verisi %10 test, %10 doğrulama ve %80 eğitim olmak üzere üç sete ayrılmıştır. Eğitim seti ile ağlar eğitilirken doğrulama seti ile kontrol edilerek eğitimin aşırı öğrenme durumuna gelmeden sonlandırılması sağlanmıştır. Test seti ile ağın başarısı kontrol edilmiştir.

YSA eğitimine girmeden önce tüm girişlerin -1 ve +1 arasına normalizasyonu sağlanmıştır. Bunun için Eşitlik 3.3' de verilen denklem kullanılmıştır.

$$P_n = 2(P - P_{min}) \div (P_{max} - P_{min}) - 1 \quad (3.3)$$

Eşitlik 5'de  $P$  gerçek girişi,  $P_{min}$  giriş serisinin en küçük değerini,  $P_{max}$  en büyük değerini ifade etmektedir. Eşitliğin sonucu  $P_n$ , normalize edilmiş giriş değerini ifade eder.

#### *Girişlerin Araştırılması*

Girişlerin modele olan etkilerini incelemek ve en uygun girdi kümesini belirlemek için giriş çeşitleri farklı kombinasyonlarda düzenlenerek farklı giriş kümeleri düzenlenmiştir. Bu kümelerde kullanılan giriş çeşitleri:

- HV: Hareket verisi
  - HV1: Zamansal olarak bir önceki hareket verisi
  - HV2: Zamansal olarak iki önceki hareket verisi
  - KSGS: Kızgınlıktan sonra geçen gün sayısı
  - S: Sıcaklık
  - N: Bağıl nem
  - SNİ: Sıcaklık-nem indeksi
  - Y: Hayvanın yaşı (gün olarak)
  - LS: Laktasyon sayısı
- olarak belirlenmiştir.

Bu giriş çeşitleri kullanılarak, hareket verileri ile 3, iklim verileri ile 3 ve diğer hayvan verileri ile 7 farklı kombinasyonda 3 temel giriş grubu hazırlanmıştır. Bu gruplar aşağıdaki gibidir:

- Hareket Grubu
  - HV
  - HV, HV1
  - HV, HV1, HV2
- İklim Grubu
  - S
  - S, N
  - SNİ
- Hayvan Bilgileri Grubu
  - LS
  - Y
  - Y, LS
  - KSGS
  - KSGS,LS
  - KSGS,Y
  - KSGS,Y, LS

Hareket grubu temel alınarak bu grupların birbiriyle kombinasyonları sonucu 96 farklı giriş kümesi oluşturulmuştur. Oluşturulan tüm giriş kümeleri Çizelge 3.2’de verilmiştir. Bu kümeler, tek gizli katmanında 15 nöronu olan ağlarla denenmiştir. En iyi sonucu veren küme en uygun giriş kümesi olarak belirlenmiştir.

Çizelge 3.2. Araştırılan giriş kümeleri

Giriş Küme No	Kullanılan Girişler
1	HV
2	HV HV1
3	HV HV1 HV2
4	HV LS
5	HV HV1 LS
6	HV HV1 HV2 LS
7	HV Y
8	HV HV1 Y
9	HV HV1 HV2 Y
10	HV Y LS
11	HV HV1 Y LS
12	HV HV1 HV2 Y LS
13	HV KSGS
14	HV HV1 KSGS

Çizelge 3.2. Araştırılan giriş kümeleri (devamı)

Giriş Küme No	Kullanılan Girişler				
15	HV	HV1	HV2	KSGS	
16	HV	KSGS	LS		
17	HV	HV1	KSGS	LS	
18	HV	HV1	HV2	KSGS	LS
19	HV	KSGS	Y		
20	HV	HV1	KSGS	Y	
21	HV	HV1	HV2	KSGS	Y
22	HV	KSGS	Y	LS	
23	HV	HV1	KSGS	Y	LS
24	HV	HV1	HV2	KSGS	Y LS
25	HV	S			
26	HV	S	N		
27	HV	SNI			
28	HV	HV1	S		
29	HV	HV1	S	N	
30	HV	HV1	SNI		
31	HV	HV1	HV2	S	
32	HV	HV1	HV2	S	N
33	HV	HV1	HV2	SNI	
34	HV	LS	S		
35	HV	LS	S	N	
36	HV	LS	SNI		
37	HV	Y	S		
38	HV	Y	S	N	
39	HV	Y	SNI		
40	HV	Y	LS	S	
41	HV	Y	LS	S	N
42	HV	Y	LS	SNI	
43	HV	KSGS	S		
44	HV	KSGS	S	N	
45	HV	KSGS	SNI		
46	HV	KSGS	LS	S	
47	HV	KSGS	LS	S	N
48	HV	KSGS	LS	SNI	
49	HV	KSGS	Y	S	
50	HV	KSGS	Y	S	N
51	HV	KSGS	Y	SNI	
52	HV	KSGS	Y	LS	S
53	HV	KSGS	Y	LS	S N
54	HV	KSGS	Y	LS	SNI
55	HV	HV1	LS	S	

Çizelge 3.2. Araştırılan giriş kümeleri (devamı)

Giriş Küme No	Kullanılan Girişler					
56	HV	HV1	LS	S	N	
57	HV	HV1	LS	SNI		
58	HV	HV1	Y	S		
59	HV	HV1	Y	S	N	
60	HV	HV1	Y	SNI		
61	HV	HV1	Y	LS	S	
62	HV	HV1	Y	LS	S	N
63	HV	HV1	Y	LS	SNI	
64	HV	HV1	KSGS	S		
65	HV	HV1	KSGS	S	N	
66	HV	HV1	KSGS	SNI		
67	HV	HV1	KSGS	LS	S	
68	HV	HV1	KSGS	LS	S	N
69	HV	HV1	KSGS	LS	SNI	
70	HV	HV1	KSGS	Y	S	
71	HV	HV1	KSGS	Y	S	N
72	HV	HV1	KSGS	Y	SNI	
73	HV	HV1	KSGS	Y	LS	S
74	HV	HV1	KSGS	Y	LS	S N
75	HV	HV1	KSGS	Y	LS	SNI
76	HV	HV1	HV2	LS	S	
77	HV	HV1	HV2	LS	S	N
78	HV	HV1	HV2	LS	SNI	
79	HV	HV1	HV2	Y	S	
80	HV	HV1	HV2	Y	S	N
81	HV	HV1	HV2	Y	SNI	
82	HV	HV1	HV2	Y	LS	S
83	HV	HV1	HV2	Y	LS	S N
84	HV	HV1	HV2	Y	LS	SNI
85	HV	HV1	HV2	KSGS	S	
86	HV	HV1	HV2	KSGS	S	N
87	HV	HV1	HV2	KSGS	SNI	
88	HV	HV1	HV2	KSGS	LS	S
89	HV	HV1	HV2	KSGS	LS	S N
90	HV	HV1	HV2	KSGS	LS	SNI
91	HV	HV1	HV2	KSGS	Y	S
92	HV	HV1	HV2	KSGS	Y	S N
93	HV	HV1	HV2	KSGS	Y	SNI
94	HV	HV1	HV2	KSGS	Y	LS S
95	HV	HV1	HV2	KSGS	Y	LS S N
96	HV	HV1	HV2	KSGS	Y	LS SNI

### YSA topolojisinin araştırılması

YSA için optimum topolojiyi bulmanın bilgisayar işlemci gücü ve problem karmaşıklığına bağlı olarak çok zaman alan bir işlem olabileceği belirtilmiştir (Madadlou ve ark., 2009). Bu nedenle konuyla ilgili literatür incelenmiş, rapor edilen en iyi sonuç vermiş yöntemler uygulanmıştır.

Bir ve iki gizli katmanlı modeller denenmiştir. Gizli katmanlardaki nöron sayıları tek ve çift gizli katmanlı ağlar için ayrı ayrı denenerek belirlenmiştir. Optimum nöron sayısının bulunması için gizli katmandaki nöron sayısı belirli miktarlarda arttırılarak performansları değerlendirilmektedir (Taner ve ark., 2010). Bu testler sonucunda en düşük hataya sahip ağ seçilmektedir. Tek katmanlı ağda nöron sayıları 10, 20, 30, 40, 50, 60, 70, 80, 90 ve 100 olan ağlar karşılaştırılmıştır. En az hata ile testi geçen ağın beş nöron eksiğinden beş nöron fazlasına kadar on deneme daha yapılmıştır.

Gizli ağda nöron sayısının çok olması işlem yükünü doğrudan arttıracığı için tavsiye edilmemektedir (Alpaydın, 2010). Bu nedenle gizli katman nöron sayısını belirli bir kurala sabitlemek amacıyla çeşitli çalışmalar yapılmıştır (Sheela ve Deepa, 2013). En az ve en etkili nöron sayısının bulunması için daha önce çalışılan bu kurallara göre hesaplanan nöron sayıları ayrıca denenmiştir. Bu çalışmalar ve gizli nöron sayılarını veren formülleri Çizelge 3.3’de verilmiştir. Eşitliklerde  $N_h$  gizli katman nöron sayısını,  $N_i$  ve  $n$  giriş sayısını,  $N_o$  çıkış sayısını,  $N$  giriş ve çıkış toplamını ifade etmektedir.

Çizelge 3.3. Önceki çalışmalarda gizli katman nöron sayısı hesapları

Çalışma	Önerilen Kural Eşitliği
(Li ve ark., 1995)	$N_h = (\sqrt{1 + 8n} - 1)/2$
(Tamura ve Tateishi, 1997)	$N_h = N - 1$
(Zhang ve ark., 2003)	$N_h = 2^n/n+1$
(Shibata ve Ikeda, 2009)	$N_h = \sqrt{N_i N_o}$
(Hunter ve ark., 2012)	$N_h = 2^n - 1$
(Sheela ve Deepa, 2013)	$N_h = (4n^2 + 3)/(n^2 - 8)$

En uygun iki gizli katmanlı ağ yapısını belirlemek için Chegini ve ark. (2008)’nın çalışmasındaki yöntem uygulanmıştır. Tek gizli katmanlı çalışmaya benzer olarak

katmandaki nöron sayıları arttırılmıştır. Birinci katmandaki her artış için ikinci katman sonuna kadar arttırılmış böylece tüm olası durumlar sırasıyla denenmiştir. İlk nöron sayıları 1-1 seçilmiş, artışlar üçer üçer 52-52 ağına kadar yapılmıştır.

Çalışmada eğitimler bu algoritmayla yapılmıştır. Algoritmanın devirler arasında ağırlık değişimini veren  $\sigma$  parametresi  $5.0e^{-5}$ , belirsizliğini düzenleyen  $\mu$  parametresi  $5.0e^{-7}$  seçilmiştir. Eğitim algoritmasının sonlandırma devir sınırı 1000 olarak seçilmiştir. Çalışmadaki tüm eğitimlerde doğrulama yapılmıştır. Üst üste alınan 6 doğrulama hatası eğitim sonlandırma ölçütü olarak seçilmiştir. Hedef performans ölçütü 0 seçilmiştir. Yani hesaplanan eğitim hatası 0 olursa eğitim durdurulacak şekilde ayarlanmıştır. Bir diğer sonlandırma parametresi, hata fonksiyonunun eğiminin alabileceği en küçük değer ise  $1e^{-66}$  olarak belirlenmiştir.

#### *Transfer fonksiyonu*

Denenen YSA modellerinin gizli katman nöronlarında transfer fonksiyonu olarak daha önceki çalışmalarda başarımlı rapor edilen “Hiperbolik Sigmoid Tanjant” fonksiyonu kullanılmıştır (Alpaydın, 2010; Bishop, 1995). Bu fonksiyonun seçilmesinde eğitim algoritmasının hesap kabiliyeti ve hızı düşünülmüştür. Ağların çıkış katmanında “Softmax” transfer fonksiyonu kullanılmıştır.

YSA modellerinin oluşturulması, eğitimi ve testleri, istatistiksel hesaplamalar, sonuçların değerlendirilmesi için oluşturulan tablo ve grafikler MATLAB yazılımı ve NNTool eklentisi ile yapılmıştır. Eğitim verisinin düzenlenmesi ve Mekanistik modelin denenmesi Microsoft Excel ile yapılmıştır.

#### 4. BULGULAR VE TARTIŞMA

Gözlemlerin gerçekleştirildiği 08.08.2014 ve 25.11.2014 tarihleri arasında 11 baş hayvan için kızgınlık rapor edilmemiştir. Bu durumun bazı hayvanlar için gözlem süreci öncesinde gerçekleştirilen yapay tohumlamanın başarılı olmasından kaynaklandığı belirlenmiştir. Gözlem süresince bazı kızgınlıkların gözden kaçırılması da olasıdır. Pedometrelerindeki veri iletişim arızası nedeniyle 3 gözlem hayvanından yeterli hareket verisi alınamamıştır. Kalan 78 gözlem hayvanı için toplam 186 onaylanmış kızgınlık rapor edilmiştir. Çizelge 4.1’de doğrulanmış tüm kızgınlıkların hangi hayvanda gözlemlendiği, tarihi ve saati ile verilmiştir.

Çizelge 4.1. Gözlemlenen kızgınlıklar

H. No	Tarih	Saat	H. No	Tarih	Saat	H. No	Tarih	Saat
1	17.10.2014	7	27	21.11.2014	4	60	28.09.2014	3
1	29.10.2014	8	28	12.09.2014	7	60	19.10.2014	10
2	24.09.2014	10	28	06.10.2014	2	60	09.11.2014	18
2	15.10.2014	17	28	25.10.2014	3	61	04.09.2014	15
3	24.08.2014	22	29	12.08.2014	16	61	17.10.2014	0
3	16.09.2014	20	29	11.09.2014	15	61	08.11.2014	16
3	25.10.2014	16	29	30.09.2014	11	62	27.08.2014	8
4	14.09.2014	10	30	16.10.2014	21	62	16.09.2014	16
4	08.10.2014	17	31	16.11.2014	14	62	11.10.2014	23
4	30.10.2014	2	32	12.11.2014	11	62	04.11.2014	12
4	20.11.2014	11	33	27.08.2014	18	63	02.10.2014	11
6	02.09.2014	12	33	01.10.2014	5	63	18.11.2014	9
6	12.11.2014	16	33	23.10.2014	1	64	06.11.2014	22
8	14.09.2014	12	34	31.08.2014	2	65	19.11.2014	4
8	05.10.2014	18	34	01.11.2014	7	66	19.09.2014	20
8	30.10.2014	2	35	24.08.2014	15	67	10.10.2014	16
9	03.10.2014	8	35	15.09.2014	2	68	24.09.2014	10
9	25.10.2014	7	35	05.10.2014	17	68	08.11.2014	13
10	14.09.2014	14	35	30.10.2014	6	69	25.08.2014	23
10	16.10.2014	14	36	18.11.2014	13	69	11.09.2014	11
10	11.11.2014	6	38	24.10.2014	8	70	13.09.2014	14
11	20.09.2014	1	38	07.11.2014	14	70	03.10.2014	16
11	06.10.2014	17	39	22.09.2014	19	70	18.10.2014	10
11	04.11.2014	16	39	27.10.2014	22	70	22.11.2014	10
11	20.11.2014	3	40	18.08.2014	13	71	29.09.2014	8
12	04.10.2014	21	40	14.09.2014	4	71	28.10.2014	6
12	28.10.2014	3	40	18.10.2014	14	72	24.08.2014	17
12	17.11.2014	17	40	08.11.2014	7	72	23.09.2014	11
12	18.11.2014	2	43	14.09.2014	14	72	29.10.2014	21
14	19.08.2014	21	43	15.10.2014	14	72	20.11.2014	1
14	29.10.2014	15	43	14.11.2014	19	73	06.10.2014	7
15	19.08.2014	20	44	17.09.2014	17	74	23.08.2014	7
15	10.09.2014	22	45	08.09.2014	21	74	19.10.2014	20
15	01.10.2014	17	45	12.10.2014	15	74	13.11.2014	6




Çizelge 4.1. Gözlemlenen kızgınlıklar (devamı)

H. No	Tarih	Saat	H. No	Tarih	Saat	H. No	Tarih	Saat
15	24.10.2014	22	45	05.11.2014	16	75	01.10.2014	4
17	01.10.2014	0	46	08.10.2014	0	75	24.10.2014	8
17	29.10.2014	17	46	28.10.2014	17	75	17.11.2014	9
17	14.11.2014	8	47	14.08.2014	6	76	14.11.2014	19
18	11.09.2014	18	47	11.09.2014	4	79	06.10.2014	15
18	06.10.2014	21	47	18.10.2014	16	80	13.09.2014	12
19	14.09.2014	13	47	08.11.2014	6	80	06.10.2014	14
19	23.10.2014	23	48	01.10.2014	20	81	19.08.2014	11
20	12.08.2014	17	49	13.09.2014	21	81	21.11.2014	20
20	06.09.2014	23	49	05.10.2014	17	83	12.08.2014	20
20	01.10.2014	4	49	29.10.2014	7	83	06.10.2014	18
20	24.10.2014	8	49	21.11.2014	3	83	29.10.2014	13
20	15.11.2014	5	51	07.10.2014	9	83	12.11.2014	2
21	13.08.2014	11	52	19.10.2014	6	84	26.10.2014	1
21	10.09.2014	13	53	11.09.2014	14	85	29.10.2014	9
21	02.10.2014	18	53	16.10.2014	15	85	15.11.2014	7
21	26.10.2014	5	53	14.11.2014	10	86	18.10.2014	22
21	11.11.2014	23	54	13.09.2014	15	86	03.11.2014	16
22	30.08.2014	20	54	08.11.2014	1	89	21.08.2014	21
22	15.11.2014	16	55	04.09.2014	0	89	17.09.2014	6
23	14.09.2014	8	55	24.09.2014	16	89	08.10.2014	13
24	13.09.2014	9	55	15.10.2014	19	89	31.10.2014	2
25	24.08.2014	15	56	10.10.2014	13	90	24.08.2014	14
25	15.10.2014	7	56	20.10.2014	18	90	17.09.2014	6
25	05.11.2014	18	58	09.09.2014	10	90	30.10.2014	17
26	17.09.2014	21	58	12.11.2014	5	91	31.10.2014	18
27	05.10.2014	17	59	07.10.2014	9	91	21.11.2014	16
27	25.10.2014	14	59	31.10.2014	8	92	30.10.2014	14

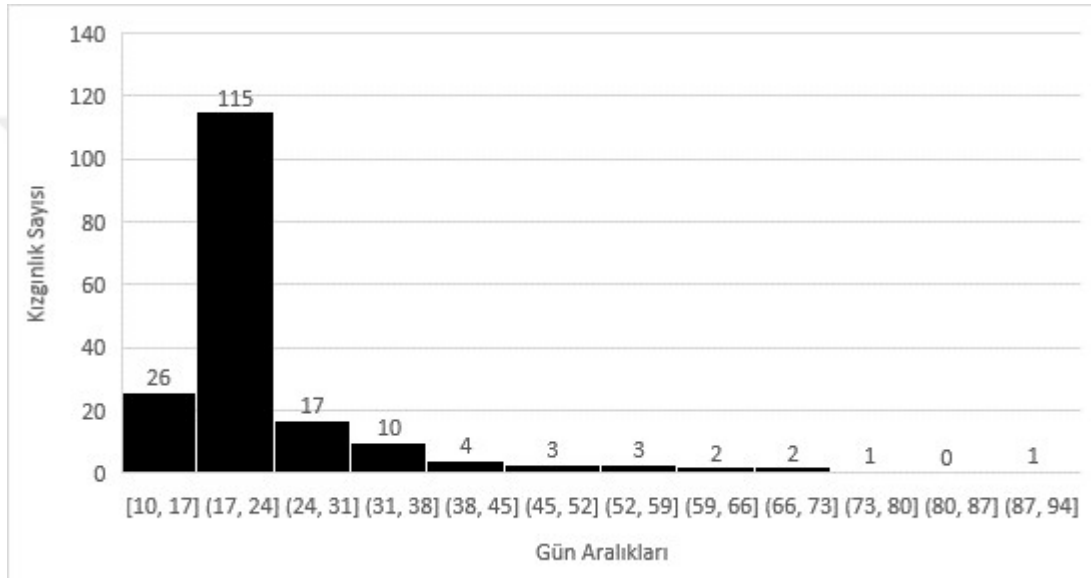
Şekil 4.1’de her bir hayvan için gözlemlenen kızgınlık sayıları verilmiştir. En çok 20 ve 21 No’lu hayvanlarda beşer kez kızgınlık gözlemlenmiştir. On üç hayvanda 4, on sekizinde 3, yirmi beşinde 2 ve yirmisinde de 1 kez kızgınlık gözlemlenmiştir. Gözlem süresince yapay tohumlamanın başarılı olduğu hayvanlar, gebe kalmaları sebebiyle daha sonra kızgınlık göstermemişlerdir. Tek sefer kızgınlık gösteren hayvan sayısından hareketle, ilk seferde tohumlama başarısının yaklaşık %25 olduğu anlaşılmıştır.

## Kızgınlık Sayısı



Şekil 4.1. Her bir hayvan için gözlemlenen kızgınlık sayısı grafiği

Kızgınlığın olduğu anki KSGS verisi, bir hayvan için iki kızgınlık arasında geçen gün sayısını vermektedir. Şekil 4.2’de kızgınlıklar arasında geçen gruplanmış gün sayılarına göre kızgınlık sayılarının dağılımı verilmiştir. Kızgınlıklar en çok 18-24 gün aralıklarla gerçekleşmiştir. Grafikte görüldüğü gibi on beş civarında kızgınlık 40 gün aralığının üstünde gözlemlenmiştir. Hayvanlarda doğal kızgınlık gösterme periyodunun bu kadar uzun olması mümkün değildir. Dolayısıyla bu aralıkta kızgınlıkların gözden kaçtığı ve rapor edilmediği sonucuna varılmaktadır.




Şekil 4.2. Kızgınlıklar arasında geçen gün sayısına göre kızgınlık sayıları

#### 4.1 Deneme Verilerinin Genel Değerlendirilmesi

##### 4.1.1 İklim verilerinin değerlendirilmesi

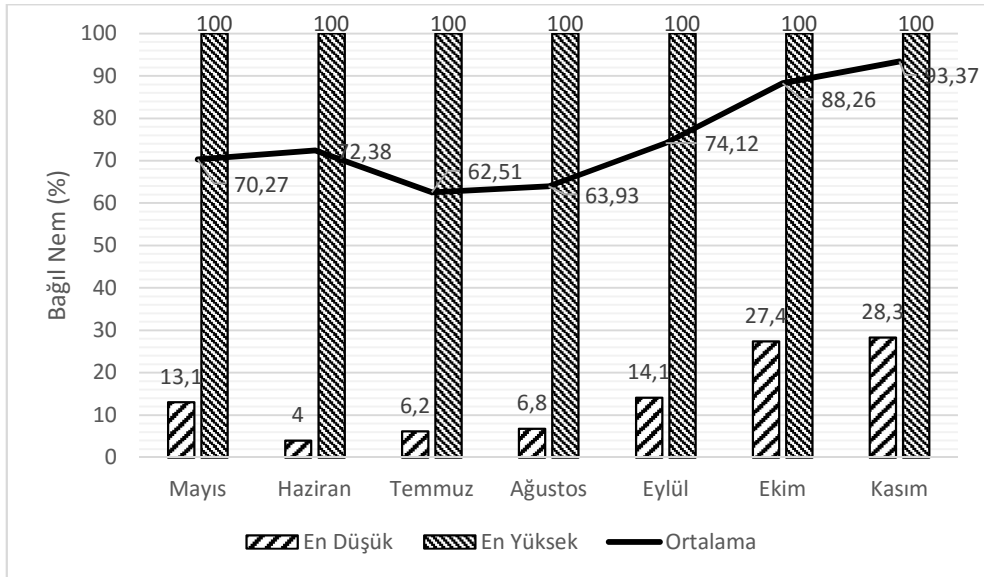
Deneme süresince alınan iklim verileri incelendiğinde en yüksek sıcaklık 39.7 °C ile 17.08.2014 tarihinde saat 16:00’da, en düşük sıcaklık -3.4 °C ile 05.11.2014 tarihinde saat 06:00’da alınmıştır. Hesaplanan tüm SNI’ler içinde en yükseği 15.08.2014 saat 14:00 için 82.84 bulunmuştur. En düşük SNI 36.64, 05.11.2014 saat 06:00 için hesaplanmıştır. Ek 1’de çalışma dönemi için alınan iklimsel veriler ve hesaplanan SNI’lerin aylık dönemlerde günlük ortalamalarını gösteren grafikler verilmiştir. Şekil 4.3’de gözlem sürecinde sıcaklığın aylık en yüksek en düşük ve ortalamasını veren grafik görülmektedir.

Ölçümler sonucu alınan sıcaklık verileri mevsim özelliklerine uygundur. En sıcak aylar Temmuz ve Ağustos iken Kasım ayında sıfırın altında sıcaklıklar ölçülmüştür.




Şekil 4.3. Gözlem süresinde aylık sıcaklık değişimi

Şekil 4.4'de gözlem süresince elde edilen en yüksek en düşük ve ortalama bağıl nem değerleri görülmektedir. Her ay bağıl nem %100'ü bulmuştur. Bu da çiğlenme veya yağışa işaret etmektedir. Sıcak olan aylarda ortalama bağıl nem düşmüş soğuk aylarda yükselmiştir.



Şekil 4.4. Gözlem süresince ölçülen aylık bağıl nem değerleri

Hesaplanan SNI'lerin aylık en yüksek, en düşük ve ortalamaları incelendiğinde, en düşük ile en yüksek farkının sıcaklık ve neme göre daha az olduğu görülmektedir (Şekil 4.5). Yaz aylarında sıcaklıktaki artışa bağlı olarak artmıştır. Daha soğuk olan Ekim ve Kasım aylarında bağıl nemdeki artış sebebiyle sıcaklıktaki kadar dik bir düşüş yaşanmamıştır.




Şekil 4.5. Hesaplanan SNI'lerin aylık gösterimi

Haziran, Temmuz, Ağustos ve Eylül aylarında SNI'nin 70'in üstüne çıktığı gözlemlenmiştir. SNI'nin 70 sınırının üstünde olması hayvanların "düşük stres" denilen duruma gelmelerine sebep olmaktadır (Sönmez ve ark., 2005). Bu durumun hayvan hareketliliğine etkisi olduğu düşünülmektedir. SNI, "yüksek stres" sınırı olan 80'e ulaşmamıştır.

#### 4.1.2 Hareket verilerinin değerlendirilmesi


Gözlem hayvanlarının her birinin hareket verisi ortalamaları büyükten küçüğe doğru sıralanmış haliyle Şekil 4.6'daki grafikte gösterilmiştir. Grafikte kesikli çizgi ile gösterilen doğru, tüm hareket verilerinin ortalaması olan 111.88'i göstermektedir. Tüm hareket verisi içerisinde elde edilmiş en yüksek veri, 45 No'lu hayvanın pedometresi tarafından 05.11.2014 tarihinde saat 23:00'da 1330 olarak kaydedilmiştir. En düşük hareketlilik 0 olarak, muhtemelen hayvanların uyumaları sırasında kaydedilmiştir. Otuz dokuz hayvanın ortalama hareketi genel ortalamadan yüksek olmuştur.



Şekil 4.6. Tüm hayvanların ortalama hareket verileri

En yüksek ortalama hareketlilik 64 No'lu hayvan için 236.71 bulunmuştur. Bunu 180.39 ve 179.55 hareket ortalamalarıyla 61 ve 51 No'lu hayvanlar izlemiştir. Elli sekiz hayvan genel ortalamanın altında hareket etmiştir. En düşük hareketlilik ortalama 50.49 ile 85 No'lu hayvanda gözlemlenmiştir. 111.66 ile ortalamaya en yakın hareketlilik gösteren 75 No'lu hayvan olmuştur.

Hayvanların günlük hareketliliği saatlik olarak araştırılmıştır. Şekil 4.7'deki grafikte gün içerisinde saatlere göre hayvanların ortalama hareketliliği verilmiştir. Grafikte kesikli çizgi ile gösterilen tüm hayvanlar için alınan ortalamadır. Grafikte ayrıca, en çok hareketli (No 64), en az hareketli (No 85) ve ortalamaya en yakın hareketlilik gösteren (No 75) hayvanların hareketleri de karşılaştırılmıştır. En hareketli hayvan haricinde diğer hayvan hareketlerinin hesaplanan genel ortalamaya benzer biçimde azalıp arttığı görülmüştür. Ortalamaya en yakın hareketlilik gösteren 75 No'lu hayvanın saatlik hareketlerinin ortalamaya değer bakımından da yakın olduğu anlaşılmaktadır.

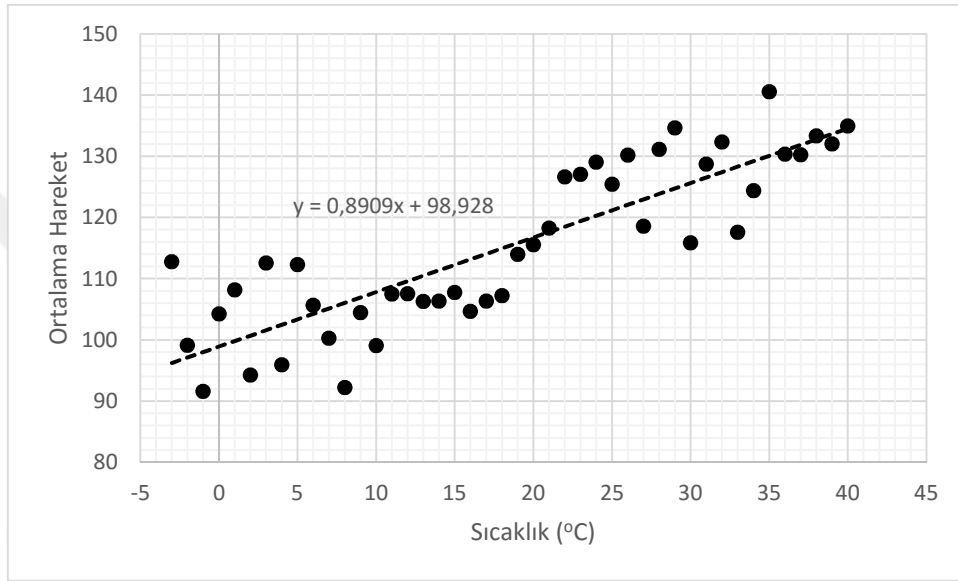


Şekil 4.7. Günün saatleri için hareket ortalamaları

#### 4.1.3 İklimsel veriler ile hareketlilik ilişkisi


Sıcaklık, nem ve SNİ ile hareketlilik arasındaki ilişkinin görülebilmesi için tüm sıcaklık, nem ve SNİ değerlerinde elde edilen hareket verilerinin ortalamaları alınmıştır. Sıcaklık

için ortalama aralığı 1°C olarak belirlenmiştir. Her bir derecelik sıcaklık için ölçülen hareket verilerinin ortalaması alınarak o sıcaklık için ortalama hareket olarak kaydedilmiştir. Şekil 4.8’de bu hareket ortalamaları ile sıcaklık arasındaki dağılım grafiği görülmektedir. En küçük kareler yöntemi ile elde edilmiş birinci dereceden karakter doğrusu:  $y = 0.8909x + 98.928$  olarak hesaplanmıştır. Grafikten de anlaşılacağı sıcaklık artışı ile hareketlilik de artmaktadır.



Şekil 4.8. Sıcaklık ile ortalama hareketlilik dağılımı

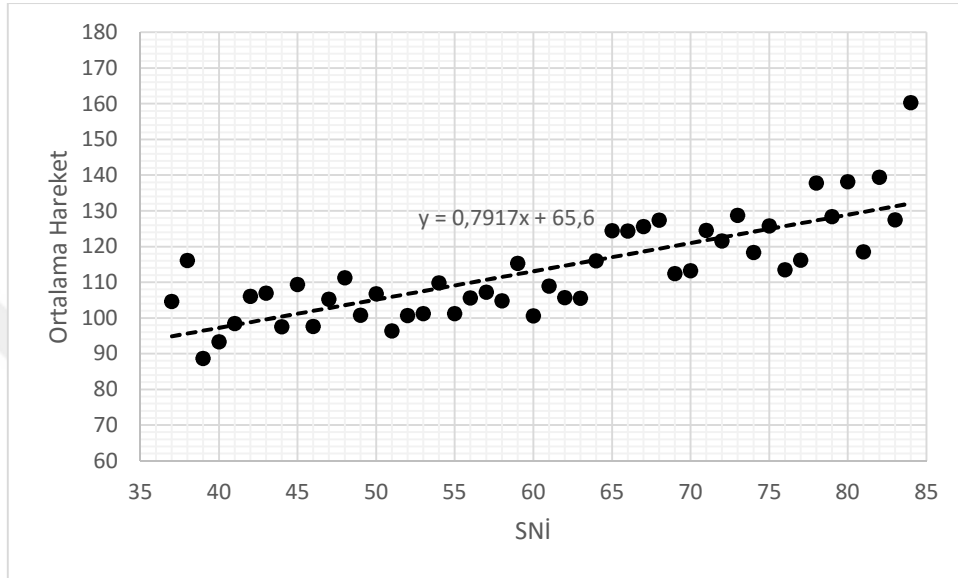
Aynı işlem her %1’lik bağıl nem için yapıldığında Şekil 4.9’daki dağılım ve karakter doğrusu elde edilmiştir. Nem artışı ile hareketliliğin düştüğü görülmektedir.



Şekil 4.9. Nem ve ortalama hareket dağılımı



Sıcaklık ve nem deęişimlerinin hayvan hareketlerine farklı etkileri olduęu anlaşılmıştır. İki iklim şartının beraber deęerlendirilmesine olanak veren SNI için ortalamalar alınıp daęılımlara bakıldığında SNI arttıkça hareketliliğin arttığı görülmüştür (Şekil 4.10). Daęılımın karakter doęrusu:  $y = 0.7917x + 65.6$  olarak hesaplanmıştır.



Şekil 4.10. SNI ve ortalama hareket daęılımı

## 4.2 Model Performansları

### 4.2.1 Mekanistik model

Her bir hayvan için kızgınlık durumu mekanistik modele göre ayrı ayrı incelenmiştir. Ortalama ve standart sapmalar son on gün üzerinden hesaplandığı için her hayvana ait ilk on günlük veri karşılaştırmada kullanılmamıştır. Mekanistik model denemesi için 176'sı kızgınlık olan 45513 adet örnek veri kullanılmıştır. Tüm hayvanlarla yapılan mekanistik model denemelerinin grafikleri Ek 2'de verilmiştir. Mekanistik model tahminleri ile gerçek gözlemlerin karşılaştırması ile elde edilen hata matrisi Şekil 4.11'de gösterilmiştir.

Tahminler	Gözlemler		
	1	2	
1	42 0.1%	244 0.5%	14.7% 85.3%
2	134 0.3%	45093 99.1%	99.7% 0.3%
	23.9% 76.1%	99.5% 0.5%	99.2% 0.8%

Şekil 4.11. Mekanistik modelin hata matrisi

Mekanistik modelin tahmin doğruluğu 0.9916 hesaplanmıştır. Duyarlılığı 0.2386, kesinliği 0.1468, F skoru 0.1818 hesaplanmıştır. ROC altında kalan alan 0.5006 olarak hesaplanmıştır.

#### 4.2.2 YSA modeli

##### *En İyi Giriş Kümesinin Belirlenmesi*

Belirlenen giriş kümeleri ile elde edilen ağların sonuçları Çizelge 4.2’de verilmiştir. Tüm giriş kümeleri için doğruluk %99’un üstünde çıkmıştır. Bazı denemelerde hiç pozitif doğru tahmin yapılmadığı için kesinlik, duyarlılık ve bunlara bağlı olarak da F skoru 0 bulunmuştur. Denemelerin aynı dağılıma sahip eğitim setleri ile yapılmasından dolayı karşılaştırmalar F skoruna göre yapılmıştır. En başarılı giriş, 0.1706 F skoru ile 65. küme seçilmiştir. Bu giriş kümesinde; hareket verisi, bir saat önceki hareket verisi, kızgınlıktan sonra geçen gün sayısı, sıcaklık ve nem verileri bulunmaktadır. Duyarlılığı 0.0978, kesinliği 0.6667 ve AUC 0.9583 olarak hesaplanmıştır.

Aynı giriş kümesinde sıcaklık ve nem yerine SNİ'nin tek başına kullanıldığı 66. kümede F skoru 65'e göre daha düşük olarak 0.1020 hesaplanmıştır. Buradan sıcaklık ve nemin SNİ yerine giriş olarak kullanılmasının başarıyı arttırdığı anlaşılmaktadır.

65. kümedeki girişlere kızgınlıktan sonra geçen gün sayısının dahil olmadığı 44. nolu kümenin denemesinde F skoru 0.0995 hesaplanmıştır. KSGS verisinin F skoru üzerine ciddi bir etkisinin olduğu görülmektedir.

Hareketteki ani artışı gösterme kabiliyetinden dolayı hareket verisiyle beraber bir saat önceki hareket verisi tahminde başarıyı arttırmıştır. İki saat önceki hareket verisinin 65. kümedeki girişlere dâhil olmasıyla elde edilen 86. kümenin F skoru 0.1300 bulunmuştur. Daha düşük F skoru verdiği için iki saat önceki hareket verisinin girişe eklenmesinin başarı açısından olumsuz olduğu anlaşılmıştır.

Çizelge 4.2. Giriş kümelerinin deneme sonuçları

Giriş Kümesi	Doğruluk	Duyarlılık	Kesinlik	F Skoru
1	0.9982	0.0272	0.2174	0.0483
2	0.9981	0.0652	0.2609	0.1043
3	0.9983	0.0163	1.0000	0.0321
4	0.9983	0.0163	0.3333	0.0311
5	0.9983	0.0163	1.0000	0.0321
6	0.9983	0.0217	0.6667	0.0421
7	0.9983	0.0109	0.6667	0.0214
8	0.9983	0.0326	0.5000	0.0612
9	0.9983	0.0109	0.6667	0.0214
10	0.9982	0.0272	0.2500	0.0490
11	0.9983	0.0326	0.4286	0.0606
12	0.9982	0.0272	0.2273	0.0485
13	0.9983	0.0652	0.5714	0.1171
14	0.9983	0.0870	0.5161	0.1488
15	0.9983	0.0000	0.0000	0.0000
16	0.9984	0.0815	0.6522	0.1449
17	0.9983	0.0217	0.3333	0.0408
18	0.9984	0.0707	0.6190	0.1268
19	0.9984	0.0489	0.7500	0.0918
20	0.9984	0.0870	0.5714	0.1509
21	0.9984	0.0978	0.6429	0.1698
22	0.9984	0.0652	0.6316	0.1182

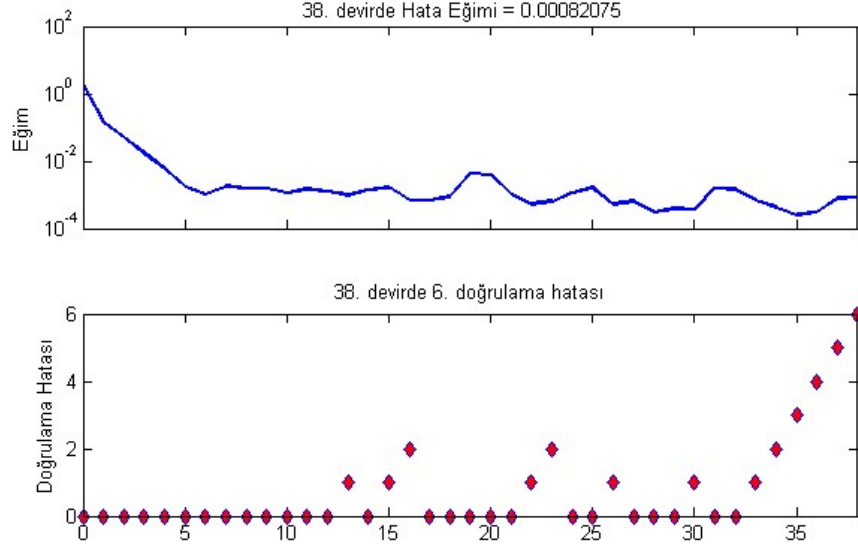
Çizelge 4.2. Giriş kümelerinin deneme sonuçları (devam)

Giriş Kümesi	Doğruluk	Duyarlılık	Kesinlik	F Skoru
23	0.9984	0.0707	0.6190	0.1268
24	0.9983	0.0652	0.5217	0.1159
25	0.9983	0.0217	0.3636	0.0410
26	0.9983	0.0000	0.0000	0.0000
27	0.9983	0.0163	0.4286	0.0314
28	0.9983	0.0109	0.5000	0.0213
29	0.9983	0.0109	0.5000	0.0213
30	0.9983	0.0272	0.4167	0.0510
31	0.9983	0.0217	0.3636	0.0410
32	0.9983	0.0054	0.3333	0.0107
33	0.9982	0.0272	0.2273	0.0485
34	0.9982	0.0543	0.2778	0.0909
35	0.9983	0.0109	1.0000	0.0215
36	0.9984	0.0217	1.0000	0.0426
37	0.9983	0.0163	0.3000	0.0309
38	0.9983	0.0054	1.0000	0.0108
39	0.9983	0.0163	1.0000	0.0321
40	0.9983	0.0054	1.0000	0.0108
41	0.9983	0.0054	1.0000	0.0108
42	0.9983	0.0109	0.6667	0.0214
43	0.9984	0.0652	0.6667	0.1188
44	0.9983	0.0543	0.5882	0.0995
45	0.9983	0.0000	0.0000	0.0000
46	0.9984	0.0815	0.6818	0.1456
47	0.9984	0.0815	0.6000	0.1435
48	0.9984	0.0598	0.8462	0.1117
49	0.9984	0.0870	0.6957	0.1546
50	0.9983	0.0000	0.0000	0.0000
51	0.9984	0.0543	0.6667	0.1005
52	0.9984	0.0543	0.7692	0.1015
53	0.9984	0.0543	0.8333	0.1020
54	0.9984	0.0924	0.5667	0.1589
55	0.9983	0.0163	1.0000	0.0321
56	0.9983	0.0163	0.3750	0.0313
57	0.9982	0.0272	0.2381	0.0488
58	0.9984	0.0272	1.0000	0.0529
59	0.9983	0.0272	0.5000	0.0515
60	0.9983	0.0109	0.3333	0.0211

Çizelge 4.2. Giriş kümelerinin deneme sonuçları (devam)


Giriş Kümesi	Doğruluk	Duyarlılık	Kesinlik	F Skoru
61	0.9983	0.0163	0.4286	0.0314
62	0.9984	0.0380	0.7000	0.0722
63	0.9983	0.0489	0.3600	0.0861
64	0.9984	0.0380	0.8750	0.0729
<b>65</b>	<b>0.9984</b>	<b>0.0978</b>	<b>0.6667</b>	<b>0.1706</b>
66	0.9984	0.0543	0.8333	0.1020
67	0.9983	0.0326	0.6667	0.0622
68	0.9983	0.0761	0.5000	0.1321
69	0.9983	0.0435	0.5333	0.0804
70	0.9983	0.0000	0.0000	0.0000
71	0.9984	0.0489	0.6923	0.0914
72	0.9984	0.0707	0.6500	0.1275
73	0.9983	0.0326	0.6000	0.0619
74	0.9984	0.0707	0.6500	0.1275
75	0.9984	0.0543	0.7143	0.1010
76	0.9983	0.0163	0.7500	0.0319
77	0.9983	0.0380	0.4118	0.0697
78	0.9982	0.0707	0.3824	0.1193
79	0.9983	0.0217	0.5000	0.0417
80	0.9983	0.0272	0.5000	0.0515
81	0.9983	0.0000	0.0000	0.0000
82	0.9983	0.0163	0.7500	0.0319
83	0.9983	0.0163	0.6000	0.0317
84	0.9983	0.0109	0.6667	0.0214
85	0.9983	0.0543	0.5882	0.0995
86	0.9984	0.0707	0.8125	0.1300
87	0.9984	0.0598	0.7333	0.1106
88	0.9984	0.0380	0.8750	0.0729
89	0.9984	0.0815	0.7143	0.1463
90	0.9984	0.0489	0.6923	0.0914
91	0.9983	0.0380	0.6364	0.0718
92	0.9983	0.0707	0.5417	0.1250
93	0.9984	0.0815	0.6522	0.1449
94	0.9982	0.0598	0.3667	0.1028
95	0.9983	0.0000	0.0000	0.0000
96	0.9984	0.0652	0.7500	0.1200

En başarılı 65. giriş kümesi ile ağı eğitimi Şekil 4.12’de alttaki grafikte görüldüğü gibi doğrulama hatası ile 38. devirde sonlanmıştır. Şekil 4.12’de üstteki grafikte hata eğimi değişimi görülmektedir.

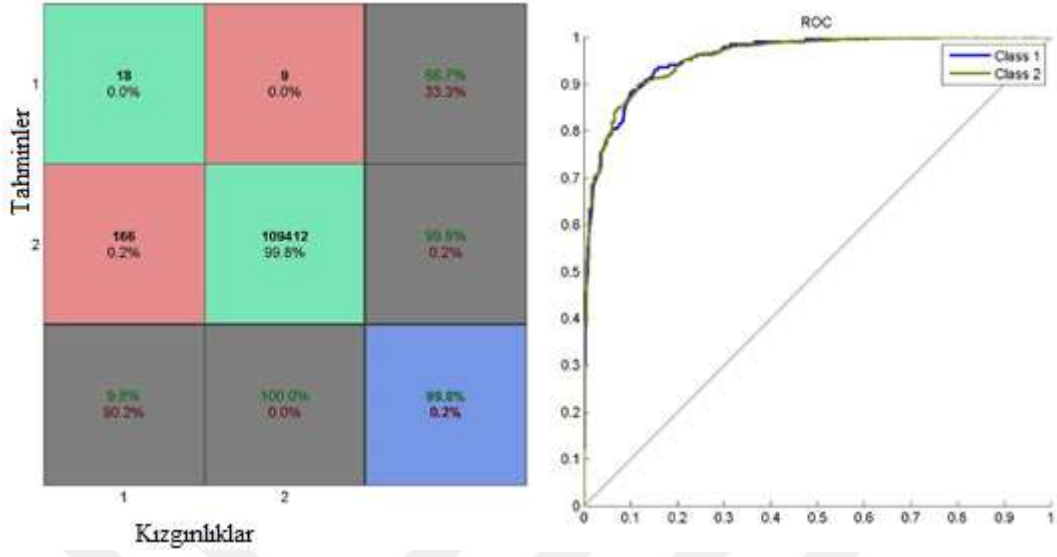


Şekil 4.12. En başarılı girişin hata eğrisi (üstte) ve doğrulama hataları (altta)

En düşük çapraz entropi hatası 0.35288 ile ağ eğitimi tamamlanmıştır (Şekil 4.13). Hata matrisi ve ROC eğrisi Şekil 4.14’de verilmiştir. Bu giriş kümesi tek ve iki katmanlı ağ denemelerinde giriş olarak kullanılmıştır.



Şekil 4.13. En iyi giriş kümesinin eğitim hata grafiği



Şekil 4.14. En iyi giriş kümesi hata matrisi (solda) ve ROC eğrisi (sağda)

### Tek Katmanlı YSA Modeli

İlk aşamada gizli katmanında 10, 20, 30, 40, 50, 60, 70, 80, 90 ve 100 nöronu olan ağlar sırayla eğitilmiş ve sınıflandırma başarıları incelenmiştir. Çizelge 4.3’de bu eğitimlerin sonunda elde edilen sonuçlar görülmektedir.

Çizelge 4.3. Tek katmanda birinci aşama deneme sonuçları


Nöron Sayısı	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
10	0.9983	0.0598	0.5789	0.1084	0.9660
20	0.9983	0.0924	0.5484	0.1581	0.9670
30	0.9983	0.0543	0.5882	0.0995	0.9661
40	0.9983	0.0000	0.0000	0.0000	0.5026
50	0.9983	0.0870	0.4571	0.1461	0.9671
60	0.9983	0.0761	0.5600	0.1340	0.9658
70	0.9984	0.0707	0.5909	0.1262	0.9608
80	0.9984	0.0761	0.6087	0.1353	0.9699
<b>90</b>	<b>0.9984</b>	<b>0.0978</b>	<b>0.5806</b>	<b>0.1674</b>	<b>0.9587</b>
100	0.9982	0.0870	0.3556	0.1397	0.9702

Nöron sayısı 90 olan ağ yapısı F skoru'na göre diğerlerinden daha başarılı bulunmuştur. İkinci aşama olarak 90'ın beş altı ve beş üstü yani 85 ve 95 arasında nörona sahip ağlar denenmiştir (Çizelge 4.4).

Çizelge 4.4. Tek katmanda ikinci aşama deneme sonuçları


Nöron Sayısı	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
85	0.9984	0.0598	0.6471	0.1095	0.9698
86	0.9983	0.0652	0.4138	0.1127	0.9638
87	0.9983	0.0000	0.0000	0.0000	0.5000
88	0.9983	0.0000	0.0000	0.0000	0.5989
89	0.9983	0.0000	0.0000	0.0000	0.5000
90	0.9984	0.0978	0.5806	0.1674	0.9587
<b>91</b>	<b>0.9984</b>	<b>0.0978</b>	<b>0.6667</b>	<b>0.1706</b>	<b>0.9654</b>
92	0.9983	0.0598	0.4783	0.1063	0.9679
93	0.9982	0.0978	0.4000	0.1572	0.9505
94	0.9983	0.0000	0.0000	0.0000	0.5000

Çizelge 4.4'de görüldüğü gibi 91 nöronlu YSA modeli 0.098 duyarlılık ve 0.667 kesinlikle en başarılı ağdır. Bu ağın eğitimi 43. devirde, 6. doğrulama hata uyarısı ile sonlandırılmıştır (Şekil 4.15). En başarılı ağ 0.35269 doğrulama hatası ile 37. devirde elde edilmiştir (Şekil 4.16).




Şekil 4.15. Tek katmanlı en başarılı ağın eğitim süreci





Şekil 4.16. Tek katmanlı en başarılı ağıın doğrulama hata grafiđi

Bu ađın tüm veri ile testi sonucu Şekil 4.17'deki hata matrisi ve ROC eğrisi elde edilmiştir. YSA'nın duyarlılıđı 0.0978, kesinliđi 0.6667 ve bunlarla hesaplanan F skoru 0.1706 bulunmuştur. ROC eğrisi altında kalan alan AUC, 0.9654 hesaplanmıştır.



Şekil 4.17. Tek katmanlı en başarılı ağıın hata matrisi (solda), ROC eğrisi (sađda)

## Önceki Çalışmalarda Belirtilen Formüllerin Sonuçları


Optimum nöron sayısının hesabına yönelik daha önce yapılan çalışmalardan elde edilen formüllerle elde edilen nöron sayılarında ağlar eğitilmiştir. Bu ağlardan elde edilen sonuçlar Çizelge 4.4’de gösterilmiştir. Hunter ve ark. (2012)’nin formülü ile elde edilen 31 nöronlu YSA, 0.1751 F skoru ile diğerlerine göre daha başarılı sınıflandırma yapmıştır.

Çizelge 4.5. Önceki çalışmalardaki formüllerden elde edilen sonuçlar

Çalışma	Hesaplanan Nöron Sayısı	Doğruluk	Duyarlılık	Keskinlik	F Skoru	AUC
(Li ve ark., 1995)	3	0.9983	0.0489	0.5	0.0891	0.9541
(Shibata ve Ikeda, 2009)						
(Zhang ve ark., 2003)	5	0.9983	0.0434	0.7272	0.0820	0.9615
(Tamura ve Tateishi, 1997)	6	0.9983	0	0	0	0.9592
(Sheela ve Deepa, 2013)						
<b>(Hunter ve ark., 2012)</b>	<b>31</b>	<b>0.9983</b>	<b>0.1032</b>	<b>0.5757</b>	<b>0.1751</b>	<b>0.9679</b>


### *İki Katmanlı YSA Modeli*

İki gizli katmana sahip ağların denemeleri için 1-1 den 52-52 yapıdaki ağlara kadar nöron sayıları üçer artırılarak tüm kombinasyonlarda 324 adet ağ elde edilmiştir. Ek 3’te bu ağların testleri sonucu elde edilen tüm sonuçlar verilmiştir. Şekil 4.18’deki grafikte katmanlardaki nöron sayılarına göre F skoru değişimi verilmiştir. Eksenler 1. ve 2. katmanlardaki nöron sayısını, renkli eğrilerle belirtilen bölgeler F skoru değerlerini göstermektedir.



Şekil 4.18. İki katmanlı YSA'da nöron sayılarına göre F skor değişimi

En başarılı ağ 0.1775 F skoru ile 230. sıradaki ağ olmuştur. Bu ağın ilk gizli katmanında 37, ikincisinde 40 nöron vardır. Eğitim, doğrulama hatası uyarısı ile sonlandırılmıştır. Eğitim sürecini gösteren grafikler Şekil 4.19'da verilmiştir. Ağ, eğitiminin erken devirlerinde birçok kez doğrulama hatası vermiştir. Daha önce iki defa üst üste 5 doğrulama hatası vermesine karşın 6 eşliğine 63. Devirde ulaşmıştır. Bu erken doğrulama hataları, iki katmanlı ağın hızlı öğrenme kabiliyetinden kaynaklanmaktadır.




Şekil 4.19. En başarılı iki katmanlı ağın eğitim süreci grafikleri

Ağın, hata matrisi Şekil 4.20’de verilmiştir. Ağın duyarlılığı 0.1032, kesinliği 0.6334 bulunmuştur. Şekil 4.21’ de gösterilen ROC eğrisi altında kalan alan 0.9733 hesaplanmıştır.

Tahminler	1	19 0.0%	11 0.0%	63.3% 36.7%
	2	165 0.2%	109410 99.8%	99.8% 0.2%
		10.3% 89.7%	100.0% 0.0%	99.8% 0.2%
		1	2	
		Gözlemler		

Şekil 4.20. İki katmanlı en başarılı ağın hata matrisi



Şekil 4.21. İki katmanlı en başarılı ağın ROC eğrisi

### 4.2.3 Modellerin karşılaştırılması

Mekanistik model ve YSA modellerinin denemeleri sonucunda elde edilen en başarılı ağların sonuçlarının karşılaştırması Çizelge 4.6’da verilmiştir. Tüm modeller için doğruluk 0.99 üzerinde çıkmıştır. Duyarlılık ve kesinlik, dolayısıyla da F skoru en yüksek mekanistik modelden elde edilmiştir. YSA modelleri kendi içlerinde değerlendirildiğinde Chegini ve ark. (2008) bulduğu sonuca benzer biçimde iki katmanlı YSA tek katmanlıya göre daha başarılı bulunmuştur.

Çizelge 4.6. Modellerin karşılaştırılması


Tahmin Modeli	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
Mekanistik Model	0.9916	0.2386	0.1468	0.1818	0.5006
91 Nöronlu YSA	0.9984	0.0978	0.6667	0.1706	0.9654
31 Nöronlu YSA	0.9983	0.1032	0.5757	0.1751	0.9679
<b>37-40 Nöronlu YSA</b>	<b>0.9983</b>	<b>0.1032</b>	<b>0.6334</b>	<b>0.1775</b>	<b>0.9733</b>

Mekanistik model ile yapılan denemelerde eğitim setinin sınıf dağılımı YSA modellerindekinden farklıdır. Dolayısıyla YSA ve Mekanistik modelin F skoru ile karşılaştırılması objektif bir sonuç vermemektedir. Sınıf dağılımından bağımsız bir başarı ölçümü olan AUC ile modeller kıyaslandığında 37-40 nöron yapısına sahip iki katmanlı YSA, 0.9733 AUC ile en başarılı sonucu vermektedir. Mekanistik model ise 0.5006 ile en düşük ROC değerini vermiştir.

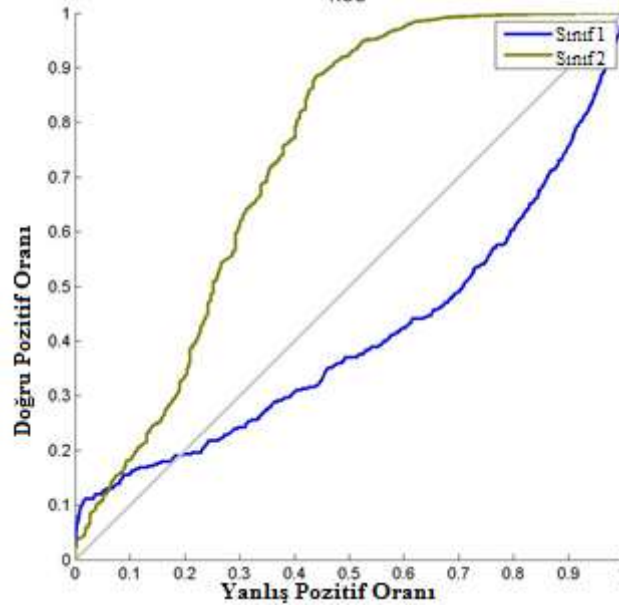
#### *YSA Modellerinde Tek Saatlik Veriler ile İki Saatlik Verilerin Karşılaştırılması*

Çalışmada en iyi sonucu veren çift katmanlı YSA modeli, iki saatlik pencerelerle alınan veri kümesi kullanılarak tekrar eğitilmiştir. Test sonucu doğruluk 0.9951, duyarlılık 0.1159, kesinlik 0.2622 ve F skoru 0.1608 olarak hesaplanmıştır. Hata matrisi Şekil 4.22’de verilmiştir. AUC değeri 0.4054 bulunmuştur. Bu değer iyi bir sınıflandırma için çok düşüktür. Şekil 4.23’deki ROC eğrisinden de görüldüğü gibi sınıf 1 yani kızgınlık durumunun tahmin performansı, kılavuz çizgisinin altına düşmüştür.

YSA eğitiminin birer saatlik iç içe girişik iki saatlik verilerle yapılması eğitim verisi sayısını arttırmasına rağmen tahmin başarısını düşürmüştür. Bunun nedeni, iki saatlik pencere birer saat ötelenerek veri oluşturulduğunda kızgınlık görülen durumların iki saatlik pencerelerde üst üste iki defa yer almasıdır.




Şekil 4.22. İki saatlik verilerle eğitilen ağın karşılaştırma matrisi




Şekil 4.23. İki saatlik verilerle eğitilen ağın ROC eğrisi

İki saatlik pencerelerin çakışmadığı mekanistik modeldekine benzer bir şekilde eğitim seti düzenlendiğinde veri sayısı normalde kullanılanın yaklaşık yarısı kadar, 54811 olmuştur. Duyarlılık 0.0217, kesinlik 0.6667, F skoru 0.0421 hesaplanmıştır. AUC ise 0.9362 bulunmuştur. Test sonucu elde edilen karşılaştırma matrisi ve ROC eğrisi Şekil 4.24 ve Şekil 4.25’de verilmiştir.



Şekil 4.24. Çakışmayan iki saatlik verilerle eğitilmiş ağın karşılaştırma matrisi



Şekil 4.25. Çakışmayan iki saatlik verilerle eğitilmiş ağın ROC eğrisi

Çakışmayan pencerelerle veri düzenlendiğinde eğitime giren veri sayısı ile beraber sınıfların dağılımında da değişim meydana gelmiştir. Bu değişim sebebiyle çakışan ve çakışmayan pencerelerle eğitilen bu iki ağın karşılaştırması AUC ile yapılmıştır. Çakışmayan pencerelerle yapılan çalışmada AUC 0.9362 bulunarak yaklaşık birincinin iki katı bir performans elde edilmiştir. Fakat bir saatlik verilerle karşılaştırıldığında daha iyi bir sonuç elde edilmemiştir.

## 5. SONUÇ

Çalışma süresince toplamda 186 kızgınlık gösteren 78 süt sığırının hareket verileri, iklimsel verilerle beraber değerlendirilmiştir. Hayvanların ortalama hareketlilikleri hesaplanmıştır. Hareketliliğin hayvan karakterine bağlı olarak değişebildiği görülmüştür.

Sıcaklık ve nemin hareketliliğe etkisi incelenmiştir. Sıcaklık ve nemin beraber değerlendirilmesini sağlayan SNİ hesaplanmıştır. SNİ arttığında hayvanların hareketliliğinin de arttığı gözlemlenmiştir.

Çalışmada mekanistik model ve YSA ile kızgınlık tahmini araştırılmıştır. YSA eğitimleri için en uygun girişler araştırılmış ve hareket verisi, bir önceki zaman dilimine ait hareket verisi, bir önceki kızgınlıktan sonra geçen gün sayısı, sıcaklık ve nem en uygun giriş olarak bulunmuştur. Çevresel faktörlerin YSA ile kızgınlık belirlemede önemli bir faktör olduğu görülmüştür. Bu durum Sönmez ve ark. (2005)'nin belirttiği iklim etkisinden kaynaklanmaktadır. Sıcaklık ve nem hayvanların hareketliliğini etkilediği için kızgınlık tahminini dolaylı olarak etkilemektedir.

Tüm denemelerde doğruluk 0.99'un üstünde çıkmıştır. Bunun nedeni negatif sınıf sayısının pozitif sınıfa oranla çok olmasından dolayı doğru tahmin edilen negatif sınıf oranının bu doğruluk oranını arttırmasıdır. Doğruluk oranları modelleri için hesaplanmış fakat karşılaştırmalarda kullanılmamıştır. Aynı veri seti ile eğitilen modellerin karşılaştırılmasında duyarlılık ve kesinliğin beraber değerlendirilmesini sağlayan F skoru kullanılmıştır. Farklı dağılıma sahip veri setleri ile yapılan denemelerde modellerin karşılaştırmaları için ROC eğrisi altında kalan eğrinin alanını ifade eden AUC değeri kullanılmıştır.

En iyi sonuç 0.9734 AUC değeri ile birinci katmanında 37, ikinci katmanında 40 nöronu bulunan iki katmanlı YSA sınıflandırma modeli ile elde edilmiştir. Bu modelin duyarlılığı 0.1032 hesaplanmıştır. Gözlemlenen 186 kızgınlıktan 19'unu doğru tahmin etmiştir. En düşük AUC mekanistik modelden elde edilmiştir. Mekanistik model için Roelofs ve ark. (2005)'nin çalışmalarındaki başarıya ulaşamamasının temel nedeni adım yerine hareket verisinin kullanılması ve değerlendirme için Roelofs ve ark. (2005) çalışmalarının aksine takvime uygunluğun araştırılmamasından kaynaklandığı düşünülmektedir.



Çalışmada ayrıca bir saatlik yerine iki saatlik verilerin YSA eğitiminde kullanılmasının sonuçları araştırılmıştır. İki saatlik verilerle yapılan eğitimlerde bir saatliklere göre daha düşük AUC elde edilmiştir. Bir saatlik verilerin YSA modelinde kullanışlı olduğu anlaşılmıştır.

YSA eğitiminde kullanılan ve kızgınlık tahmini için elzem görülen hareket verileri mevcut sistemdeki hareket algılayıcılarının ürettiği sayısal bir değerdir. Hayvanların hareketleri ile ilişkili bir büyüklük olsa da net adım sayısını belirtmemektedir. Daha önceki çalışmalar adım sayısı ile iyi sonuçlar alındığını göstermektedir (Krieter, 2005; Nadimi ve ark., 2012). Doğrudan adım bilgisi alınan bir YSA modelinde çevresel veriler ve hayvan verilerinin de değerlendirmeye dâhil edilmesiyle daha başarılı sonuçların alınacağı düşünülmektedir.

## 6. KAYNAKLAR

- Akkaya, G., 2007. Yapay Sinir Ağları ve Tarım Alanındaki Uygulamaları. Atatürk Üniversitesi Ziraat Fakültesi 38(2), 195-202.
- Alpaydın, E., 2010. Introduction to Machine Learning, The MIT Press, Cambridge, Massachusetts.
- Anonim, 2013. Hayvansal Üretim İstatistikleri, Türkiye İstatistik Kurumu, Ankara.
- Anonim, 2014a. Hayvancılık Sektör Raporu. T.C. Tarım İşletmeleri Genel Müdürlüğü, Ankara.
- Anonim, 2014b. Onuncu Kalkınma Planı(2014-2018), Özel İhtisas Komisyonu Hayvancılık Raporu, Ankara: T.C. Kalkınma Bakanlığı.
- Anonim, 2015. Hayvansal Üretim İstatistikleri, Türkiye İstatistik Kurumu, Ankara.
- Anonim, 2016. Türkiye İstatistik Kurumu Hayvansal Üretim Veritabanı.  
<https://biruni.tuik.gov.tr/hayvancilikapp/hayvancilik.zul> (01 05 2016).
- Aras, İ., 2015. Süt ve Süt Ürünleri Sektörü Raporu, Mevlana Kalkınma Ajansı Araştırma Etüt Planlama Birimi, Konya.
- Ataseven, Z. ve Gülaç, N., 2014. Durum ve Tahmin, Süt ve Süt Ürünleri, Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü, Ankara.
- Baş, N., 2006. Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama (Yüksek Lisans Tezi), Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bishop, C. M., 1995. Neural Network for Pattern Recognition. Clarendon, Oxford.
- Bradley, A. P., 1997. The Use of Area under The ROC Curve in The Evaluation of Machine Learning Algorithms. Pattern Recognition, 30(7), 1145-1159.
- Brunassi, L. A., Moura, D. J., Naas, I. A., Vale, M. M., Souza, S. R. L., Lima, K. A. O., Carvalho, T. M. R. ve Bueno, L. G. F., 2010. Improving Detection of Dairy Cow Estrus Using Fuzzy Logic. Scientia Agricola, 67(5), 503-509.
- Chegini, G. R., Khazaei, J., Ghobadian, B. ve Goudarzi, A. M., 2008. Prediction of Process and Product Parameters in an Orange Juice Spray Dryer Using Artificial Neural Networks. Journal of Food Engineering, 84(2008), 534-543.
- Çakıcı, İ., 2006. Türkiye'de Yaygın Olarak Kullanılan Sürü Yönetim Yazılımlarının Karşılaştırılması (Yüksek Lisans Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Daniel, U., 2006. Sığırcılık. Bilge Kültür Sanat, İstanbul.
- De Mol, R. M., Keen, A., Krozeze, G. H. ve Achten, J. M. F. H., 1999. Description of a Detection Model for Oestrus and Diseases in Dairy Cattle Based on Time Series Analysis Combined with a Kalman Filter. Computer and Electronics in Agriculture, 22(1999), 171-185.
- De Mol, R. M. ve Woldt, W. E., 2001. Application of Fuzzy Logic in Automated Cow Status Monitoring. Journal of Dairy Sci., 84(2001), 400-410.
- Demirci, E., 2007. Evcil Hayvanlarda Reprodüksiyon; Suni Tohumlama ve Androloji Ders Notları, F.Ü. Veterinerlik Fakültesi Ders Teksiri No:57.
- Elmas, Ç., 2011. Yapay Zeka Uygulamaları. Seçkin Yayınevi, Ankara.
- Engelbrecht, A. P., 2007. Computational Intelligence: An Introduction. John Wiley & Sons LTD, Chichester.
- Erentürk, S. ve Erentürk, K., 2007. Comparison of genetic algorithm and neural network approaches for the drying process of carrot. Journal of Food Engineering, 78(3), 905-912

- Fawcett, T., 2006. An Introduction to ROC Analysis. *Pattern Recognition Letters*, 27(2006), 861-874.
- Firk, R., Stamer, E., Junge, W. ve Krieter, J., 2002. Automation of Oestrus Detection in Dairy Cows: A Review. *Livestock Production Science*, 75(2002), 219-232.
- Garcia, A., 2006. Dealing With Heat Stress in Dairy Cows. [http://pubstorage.sdstate.edu/AgBio\\_Publications/articles/EXEX4024.pdf](http://pubstorage.sdstate.edu/AgBio_Publications/articles/EXEX4024.pdf)
- Gribskov, M. ve Robinson, N. L., 1996. Use of Receiver Operating Characteristic (ROC) Analysis to Evaluate Sequence Matching". *Computers Chem.*, 20(1), 23-33.
- Hagan, M. T., Demuth, H. B., Beale, M. B. ve De Jesus, O., 1996. *Neural Network Design (2nd Edition)*. PWS Publishing, Boston, ABD.
- Hagan, M. T. ve Menhaj, M. B., 1994. Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993.
- Hamm, L., Brorsen, B. W. ve Hagen, M. T., 2007. Comparison of Stochastic Global Optimization Methods to Estimate Neural Network Weights. *Neural Processing Letters*, 26(2007), 145-158.
- Hebb, O., 1949. *Neural Networks*. Macmillan Collage Printing Company, New Jersey.
- Hopfield, J., 1982. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences*, 79(1982), 2554-2558.
- Hulsen, J., 2012. *Sığır Davranışları, Çevirmenler: Ayhan Öztürk, Birol Dağ, Uğur Zülkadir. Zutphen, ROODBant Publishers, Hollanda.*
- Hunter, D., Yu, H., Pukis III, M. S., Kolbusz, J. ve Wilamowski, B. M., 2012. Selection of Proper Neural Network Size and Architectures: A Comparative Study. *IEEE Transactions on Industrial Informatics*, 8(2), 228-240.
- Krieter, J. S. E. J. W., 2005. Oestrus Detection in Dairy Cows Using Control Charts and Neural Networks. 56th Annual Meeting of the Eurapan Association for Animal Production(EAAP) 5-8 Nisan, Uppsala-Sweden.
- Li, J. Y., Chow, T. W. S. ve Yu, Y. L., 1995. Estimation Theory and Optimization Algorithm for The Number of Hidden Units in The Higher-order Feedforward Neural Network. *Proceedings of the IEEE International Conference on Neural Networks*, (3), 1229-1233.
- MacKay, D. J. C., 1992. Bayesian Interpolation. *Neural Computation*, 4(3), 415-447.
- Madadlou, A., Emam-Djomeh, Z., Mousavi, M. E., Ehsani, M., Javanmard, M. ve Sheehan, D., 2009. Response Surface Optimization of an Artificial Neural Network for Predicting the Size of Re-assembled Casein Micelles. *Computers and Electronics in Agriculture*, 68(2009), 216-221.
- Marquardt, D., 1994. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *SIAM Journal on Applied Mathematics*, 11(2), 431-441.
- McCulloch, W. ve Pitts, W., 1943. A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, (5), 115-133.
- Memmedova, N. ve Keskin, İ., 2011. İneklerde Bulanık Mantık Modeli ile Hareketlilik Ölçüsünden Yararlanılarak Kızgınlık Tespiti. *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 17(6), 1003-1008.
- Mitchell, R. S., Sherlock, R. A. ve Simith, L. A., 1996. An Investigation Into Use of Machine Learnings for Determining Oestrus in Cows. *Computers and Electronics in Agriculture*, 15(1996), 195-213.
- Moller, M., 1993. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. *Neural Networks*, 6(1993), 525-533.

- Nadimi, E. S., Jorgensen, R. N., Blanes-Vidal, V. ve Christensen, S., 2012. Monitoring and Classifying Animal Behavior Using ZigBee-Based Mobile Ad Hoc Wireless Sensor Networks and Artificial Neural Networks. *Computer and Electronics in Agriculture*, 2012(82), 44-54.
- Öztemel, E., 2003. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul.
- Perrone, M. P. ve Cooper, L. N., 1993. When Networks Disagree: Ensemble Methods for Hybrid Neural Networks. *Neural Networks for Speech Image Processing*, 126-142.
- Riedmiller, M. ve Braun, H., 1993. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. San Francisco, Proceeding of The IEEE International Conference on Neural Networks. 586-591.
- Roelofs, J. B., van Eerdenburg, F., Soede, N. M. ve Kemp, B., 2005. Pedometer Readings for Estrous Detection and As Predictor for Time of Ovulation in Dairy Cattle. *Theriogenology*, (64), 1690-1703.
- Rosenblatt, F., 1958. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. Cornell Aeronautical Laboratory, *Psychological Review*. 65(6), 386-408.
- Rumelhart, D. E., Hinton, D. E. ve Williams, R. J., 1986. Learning Representation by Backpropagating Errors. *Nature*, 323(9), 533-536.
- Sağiroğlu, S., Beşdok, E. ve Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları. Ufuk Kitabevi, Kayseri.
- Sarıbay, M. K. ve Erdem, H., 2008. İneklerde Gözlem Yöntemi ile Östrus Tespiti. *Veteriner Hekimler Derneği Dergisi*, 79(3), 43-50.
- Sheela, K. G. ve Deepa, S. N., 2013. Review on Methods to Fix Number of Hidden Neurons in Neural Networks. *Mathematical Problems in Engineering*, Article ID 425740(2013).
- Shibata, K. ve Ikeda, Y., 2009. Effect of Number of Hidden Neurons on Learning in Large-scaled Layered Neural Networks. *Proceedings of The ICROS-SICE International Joint Conference*. 5008-5013.
- Sönmez, M., Demirci, E., Türk, G. ve Gür, S., 2005. Effect of Season on Some Fertility Parameters of Dairy and Beef Cows in Elazığ Province. *Turk J Vet Anim Sci*, 29(2005), pp. 821-828.
- Tamura, S. ve Tateishi, M., 1997. Capability of A Four-layered Feedforward Neural Network: four layers versus three. *IEEE Transaction on Neural Networks*, 8(2), 251-255.
- Taner, A., Gültekin, S. S. ve Çarman, K., 2010. Yapay Sinir Ağları ile Radyal Santrifüj Pompa Parametrelerinin Tahmini. *Selçuk Tarım ve Gıda Bilimleri Dergisi*, 24(1), 28-38.
- Tarhan, S., Özgüven, M. M. ve Ertuğrul, M., 2015. Süt Sığırcılığı İşletmelerindeki Bilgi Teknolojileri Uygulamaları. GAP VII Tarım Kongresi, 28-30 Nisan, Şanlıurfa.
- Tömek, B., 2007. Süt Sığırcılığında Sürü Yönetimi Alanında Kullanılan Çağdaş Teknoloji Uygulamaları Üzerine Bir Değerlendirme (Yüksek Lisans Tezi). Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Uzmay, C., Kaya, İ. ve Tömek, B., 2010. Süt Sığırcılığında Hassas Sürü Yönetim Uygulamaları. *Hayvansal Üretim*, 2(51), 50-58.
- Williamson, N., Alawneh, J., Bailey, D. ve Butler, K., 2006. Electronic Heat Detection. South Island Dairy Event (SIDE), South Island.

- Yıldız, A. K., Tarhan, S. ve Özgüven, M. M., 2013. Tarımda Yapay Zeka Uygulamaları. 28. Ulusal Tarımsal Mekanizasyon Kongresi, Konya.
- Zhang, Z., MA, X. ve Yang, Y., 2003. Bounds on The Number of Hidden Neurons in Three-layer Artificial Neural Networks. Neural Networks, 16(7), 995-1002.
- Zippo, A. G., 2011. Neuronal Ensemble Modeling and Analysis with Variable Order Markov Models. Ledizioni LediPublishing, Milan-İtalya.




## 7. EKLER


### EK 1

İklim istasyonundan alınan günlük sıcaklık ve nem ortalamaları ve hesaplanan SNI'ler :


Mayıs 2014:




Haziran 2014:




Temmuz 2014:




## Ağustos 2014:




## Eylül 2014:



## Ekim 2014:



## Kasım 2014:







## EK 2

Her bir Hayvan No için mekanistik model sonuçlarının grafik gösterimi:


1




6




2




8




3




9




4




10



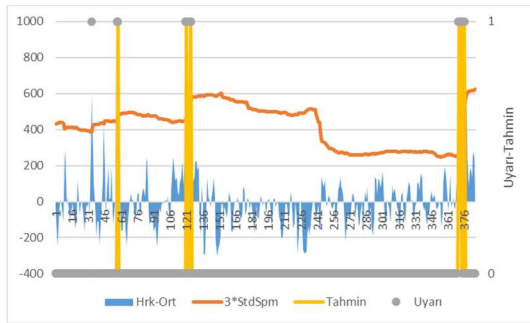
11




17




12




18




14




19




15




20




21




25




22




26




23




27




24




28




29




33




30




34




31




35



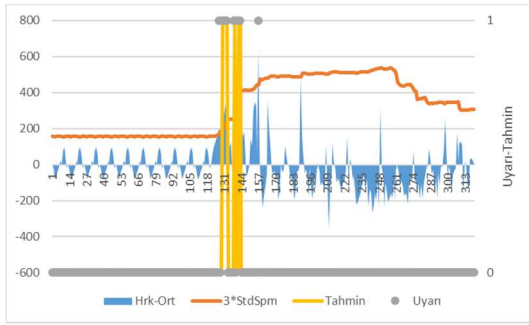
32




36




38




44




39




45




40




46




43




47




48




53




49




54




51




55




52




56




58




62




59




63




60




64




61




65




66




70




67




71




68




72



69




73







74




80




75




81




76




83




79




84




85




91




86




92



89



90



### EK 3

#### İki katmanlı ağ deneme sonuçları:

Ağ no.	Nöron Sayıları		Değerlendirme				
	1.Katman	2. Katman	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
1	1	1	0.998321244	0	0	0	0.951839187
2	1	4	0.998321244	0	0	0	0.160378934
3	1	7	0.998321244	0.027173913	0.5	0.051546392	0.955301581
4	1	10	0.998339492	0.010869565	1	0.021505376	0.95565239
5	1	13	0.99828475	0.032608696	0.375	0.06	0.950752787
6	1	16	0.998339492	0.010869565	1	0.021505376	0.955603517
7	1	19	0.998239131	0.043478261	0.32	0.076555024	0.954827793
8	1	22	0.998321244	0	0	0	0.956111229
9	1	25	0.998321244	0	0	0	0.945159114
10	1	28	0.998266502	0.027173913	0.3125	0.05	0.923883838
11	1	31	0.998312121	0.005434783	0.333333333	0.010695187	0.913557995
12	1	34	0.998312121	0	0	0	0.758618487
13	1	37	0.998257379	0.027173913	0.294117647	0.049751244	0.886674692
14	1	40	0.998339492	0.02173913	0.666666667	0.042105263	0.925845647
15	1	43	0.998257379	0.016304348	0.230769231	0.030456853	0.947724098
16	1	46	0.998321244	0	0	0	0.620636916
17	1	49	0.998321244	0	0	0	0.436809582
18	1	52	0.998321244	0	0	0	0.506216268
19	4	1	0.998321244	0	0	0	0.949325263
20	4	4	0.998321244	0	0	0	0.751495719
21	4	7	0.998321244	0.02173913	0.5	0.041666667	0.956214787
22	4	10	0.998330368	0.005434783	1	0.010810811	0.936115415
23	4	13	0.998339492	0.027173913	0.625	0.052083333	0.964092021
24	4	16	0.998312121	0	0	0	0.958837635
25	4	19	0.998321244	0	0	0	0.5
26	4	22	0.998321244	0	0	0	0.5
27	4	25	0.998366863	0.032608696	0.857142857	0.062827225	0.956902647
28	4	28	0.998321244	0	0	0	0.5
29	4	31	0.998302997	0	0	0	0.957408571
30	4	34	0.998357739	0.02173913	1	0.042553191	0.958047905
31	4	37	0.998357739	0.048913043	0.642857143	0.090909091	0.964048412
32	4	40	0.998293873	0	0	0	0.95544423
33	4	43	0.998339492	0.016304348	0.75	0.031914894	0.951396888
34	4	46	0.998321244	0	0	0	0.955562391
35	4	49	0.998366863	0.032608696	0.857142857	0.062827225	0.96848888
36	4	52	0.998321244	0	0	0	0.954606818
37	7	1	0.998321244	0	0	0	0.959041921
38	7	4	0.998321244	0	0	0	0.966147753
39	7	7	0.998330368	0.005434783	1	0.010810811	0.929894627
40	7	10	0.998321244	0	0	0	0.949445957
41	7	13	0.998330368	0.016304348	0.6	0.031746032	0.963720053
42	7	16	0.998339492	0.02173913	0.666666667	0.042105263	0.95378684
43	7	19	0.998330368	0.005434783	1	0.010810811	0.959735592
44	7	22	0.998321244	0.027173913	0.5	0.051546392	0.934814893
45	7	25	0.998339492	0.059782609	0.55	0.107843137	0.966688643
46	7	28	0.998375986	0.043478261	0.8	0.082474227	0.965360059
47	7	31	0.998348615	0.027173913	0.714285714	0.052356021	0.95433826
48	7	34	0.998394234	0.048913043	0.9	0.092783505	0.966679206
49	7	37	0.998321244	0	0	0	0.961231709
50	7	40	0.998394234	0.065217391	0.75	0.12	0.961227338
51	7	43	0.998321244	0	0	0	0.5
52	7	46	0.998321244	0	0	0	0.5
53	7	49	0.998339492	0.010869565	1	0.021505376	0.961102769
54	7	52	0.998321244	0.010869565	0.5	0.021276596	0.956206244
55	10	1	0.998321244	0	0	0	0.57285557
56	10	4	0.998321244	0	0	0	0.955839244
57	10	7	0.998339492	0.027173913	0.625	0.052083333	0.963907502
58	10	10	0.998366863	0.027173913	1	0.052910053	0.95876795
59	10	13	0.998357739	0.076086957	0.583333333	0.134615385	0.964617564
60	10	16	0.998357739	0.032608696	0.75	0.0625	0.964654021
61	10	19	0.998357739	0.02173913	1	0.042553191	0.957089451
62	10	22	0.998339492	0.010869565	1	0.021505376	0.942934956

Ağ no.	1.Katman	2. Katman	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
63	10	25	0.998375986	0.054347826	0.714285714	0.101010101	0.960919939
64	10	28	0.998366863	0.059782609	0.647058824	0.109452736	0.968101366
65	10	31	0.998394234	0.048913043	0.9	0.092783505	0.960396433
66	10	34	0.998357739	0.02173913	1	0.042553191	0.958177738
67	10	37	0.99838511	0.048913043	0.818181818	0.092307692	0.966294921
68	10	40	0.998375986	0.070652174	0.65	0.12745098	0.968472589
69	10	43	0.998321244	0	0	0	0.5
70	10	46	0.998348615	0.076086957	0.56	0.133971292	0.967297331
71	10	49	0.998321244	0	0	0	0.417965731
72	10	52	0.998248255	0.016304348	0.214285714	0.03030303	0.949759614
73	13	1	0.998321244	0	0	0	0.95980046
74	13	4	0.998321244	0.005434783	0.5	0.010752688	0.935508366
75	13	7	0.998312121	0	0	0	0.952620672
76	13	10	0.998348615	0.02173913	0.8	0.042328042	0.962886714
77	13	13	0.998375986	0.054347826	0.714285714	0.101010101	0.961609935
78	13	16	0.998330368	0.02173913	0.571428571	0.041884817	0.961752881
79	13	19	0.998357739	0.059782609	0.611111111	0.108910891	0.969922662
80	13	22	0.998403358	0.048913043	1	0.093264249	0.963262358
81	13	25	0.998348615	0.016304348	1	0.032085561	0.959011375
82	13	28	0.99838511	0.048913043	0.818181818	0.092307692	0.965036071
83	13	31	0.998421605	0.070652174	0.866666667	0.130653266	0.958546378
84	13	34	0.99838511	0.048913043	0.818181818	0.092307692	0.969028032
85	13	37	0.998348615	0.086956522	0.551724138	0.150234742	0.967280692
86	13	40	0.998348615	0.02173913	0.8	0.042328042	0.951035252
87	13	43	0.998348615	0.02173913	0.8	0.042328042	0.963462472
88	13	46	0.998348615	0.027173913	0.714285714	0.052356021	0.964280066
89	13	49	0.998321244	0	0	0	0.49999543
90	13	52	0.998357739	0.032608696	0.75	0.0625	0.962395393
91	16	1	0.998321244	0	0	0	0.962787576
92	16	4	0.998321244	0	0	0	0.962489068
93	16	7	0.998375986	0.038043478	0.875	0.072916667	0.965166749
94	16	10	0.998357739	0.059782609	0.611111111	0.108910891	0.962972492
95	16	13	0.99838511	0.070652174	0.684210526	0.128078818	0.96562817
96	16	16	0.998339492	0.048913043	0.5625	0.09	0.960626696
97	16	19	0.998321244	0.038043478	0.5	0.070707071	0.960438303
98	16	22	0.998357739	0.059782609	0.611111111	0.108910891	0.94831118
99	16	25	0.998366863	0.032608696	0.857142857	0.062827225	0.968490469
100	16	28	0.998330368	0.005434783	1	0.010810811	0.960262526
101	16	31	0.998357739	0.065217391	0.6	0.117647059	0.964043545
102	16	34	0.998366863	0.092391304	0.586206897	0.159624413	0.966769057
103	16	37	0.998375986	0.065217391	0.666666667	0.118811881	0.961317337
104	16	40	0.998330368	0.005434783	1	0.010810811	0.930921226
105	16	43	0.998339492	0.054347826	0.555555556	0.099009901	0.965064035
106	16	46	0.998366863	0.065217391	0.631578947	0.118226601	0.966901125
107	16	49	0.998348615	0.054347826	0.588235294	0.099502488	0.967421751
108	16	52	0.998366863	0.059782609	0.647058824	0.109452736	0.955733052
109	19	1	0.998321244	0	0	0	0.958236198
110	19	4	0.998330368	0.005434783	1	0.010810811	0.968099379
111	19	7	0.998339492	0.010869565	1	0.021505376	0.962415558
112	19	10	0.998321244	0	0	0	0.95222531
113	19	13	0.998348615	0.048913043	0.6	0.090452261	0.967530376
114	19	16	0.998366863	0.065217391	0.631578947	0.118226601	0.963611577
115	19	19	0.998339492	0.032608696	0.6	0.06185567	0.96449374
116	19	22	0.99838511	0.054347826	0.769230769	0.101522843	0.968143038
117	19	25	0.998348615	0.048913043	0.6	0.090452261	0.963325238
118	19	28	0.998339492	0.016304348	0.75	0.031914894	0.937797986
119	19	31	0.998357739	0.038043478	0.7	0.072164948	0.966444771
120	19	34	0.998321244	0	0	0	0.499744108
121	19	37	0.998375986	0.048913043	0.75	0.091836735	0.963208765
122	19	40	0.998348615	0.016304348	1	0.032085561	0.956828045
123	19	43	0.998321244	0	0	0	0.501843746
124	19	46	0.998321244	0	0	0	0.5
125	19	49	0.998321244	0	0	0	0.588493292
126	19	52	0.998394234	0.065217391	0.75	0.12	0.970319663
127	22	1	0.998321244	0	0	0	0.608580222
128	22	4	0.998366863	0.076086957	0.608695652	0.1352657	0.964138114
129	22	7	0.998321244	0	0	0	0.384033816
130	22	10	0.998366863	0.032608696	0.857142857	0.062827225	0.963372026

Ağ no.	1.Katman	2. Katman	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
131	22	13	0.998357739	0.048913043	0.642857143	0.090909091	0.96406664
132	22	16	0.998348615	0.032608696	0.666666667	0.062176166	0.955091136
133	22	19	0.998348615	0.065217391	0.571428571	0.117073171	0.963061746
134	22	22	0.998357739	0.043478261	0.666666667	0.081632653	0.962715259
135	22	25	0.998330368	0.010869565	0.666666667	0.021390374	0.962209037
136	22	28	0.998330368	0.027173913	0.555555556	0.051813472	0.964541373
137	22	31	0.998366863	0.048913043	0.692307692	0.091370558	0.965626233
138	22	34	0.998312121	0.016304348	0.428571429	0.031413613	0.897244657
139	22	37	0.998357739	0.038043478	0.7	0.072164948	0.96982104
140	22	40	0.998375986	0.070652174	0.65	0.12745098	0.96902237
141	22	43	0.998321244	0	0	0	0.5
142	22	46	0.998330368	0.048913043	0.529411765	0.089552239	0.964348808
143	22	49	0.998357739	0.038043478	0.7	0.072164948	0.964881801
144	22	52	0.998357739	0.043478261	0.666666667	0.081632653	0.966580912
145	25	1	0.998321244	0	0	0	0.957132861
146	25	4	0.998321244	0	0	0	0.948916341
147	25	7	0.998366863	0.038043478	0.777777778	0.07253886	0.958766509
148	25	10	0.998339423	0.038043478	0.583333333	0.071428571	0.963519094
149	25	13	0.998394234	0.070652174	0.722222222	0.128712871	0.964375281
150	25	16	0.998375986	0.038043478	0.875	0.072916667	0.968374841
151	25	19	0.998375986	0.048913043	0.75	0.091836735	0.960414313
152	25	22	0.998375986	0.048913043	0.75	0.091836735	0.969019737
153	25	25	0.998330368	0.005434783	1	0.010810811	0.948645499
154	25	28	0.998357739	0.054347826	0.625	0.1	0.971322173
155	25	31	0.998375986	0.054347826	0.714285714	0.101010101	0.964232931
156	25	34	0.998357739	0.027173913	0.833333333	0.052631579	0.958582487
157	25	37	0.998366863	0.032608696	0.857142857	0.062827225	0.963192573
158	25	40	0.998394234	0.081521739	0.681818182	0.145631068	0.971823627
159	25	43	0.998357739	0.032608696	0.75	0.0625	0.958870515
160	25	46	0.998375986	0.086956522	0.615384615	0.152380952	0.961329158
161	25	49	0.998357739	0.065217391	0.6	0.117647059	0.962010958
162	25	52	0.998348615	0.065217391	0.571428571	0.117073171	0.948638545
163	28	1	0.998394234	0.048913043	0.9	0.092783505	0.968120786
164	28	4	0.998321244	0	0	0	0.963945102
165	28	7	0.998357739	0.027173913	0.833333333	0.052631579	0.959825145
166	28	10	0.998394234	0.070652174	0.722222222	0.128712871	0.955624278
167	28	13	0.998330368	0.005434783	1	0.010810811	0.954089768
168	28	16	0.998394234	0.065217391	0.75	0.12	0.968716759
169	28	19	0.998348615	0.076086957	0.56	0.133971292	0.958545087
170	28	22	0.998366863	0.038043478	0.777777778	0.07253886	0.960290589
171	28	25	0.998348615	0.02173913	0.8	0.042328042	0.958021431
172	28	28	0.998321244	0	0	0	0.346421286
173	28	31	0.998366863	0.032608696	0.857142857	0.062827225	0.959996948
174	28	34	0.998375986	0.048913043	0.75	0.091836735	0.969585264
175	28	37	0.998330368	0.016304348	0.6	0.031746032	0.951094109
176	28	40	0.998394234	0.048913043	0.9	0.092783505	0.969156574
177	28	43	0.998348615	0.070652174	0.565217391	0.125603865	0.963491528
178	28	46	0.998348615	0.043478261	0.615384615	0.081218274	0.951133993
179	28	49	0.998321244	0	0	0	0.740874546
180	28	52	0.998348615	0.032608696	0.666666667	0.062176166	0.96442182
181	31	1	0.998321244	0	0	0	0.843802438
182	31	4	0.998321244	0	0	0	0.945771875
183	31	7	0.998366863	0.10326087	0.575757576	0.175115207	0.887943525
184	31	10	0.998321244	0.010869565	0.5	0.021276596	0.957480988
185	31	13	0.998348615	0.016304348	1	0.032085561	0.962194186
186	31	16	0.99838511	0.043478261	0.888888889	0.082901554	0.956862763
187	31	19	0.998330368	0.032608696	0.545454545	0.061538462	0.950398997
188	31	22	0.998357739	0.043478261	0.666666667	0.081632653	0.963456363
189	31	25	0.99828475	0.097826087	0.45	0.160714286	0.929545408
190	31	28	0.998366863	0.048913043	0.692307692	0.091370558	0.964990525
191	31	31	0.99838511	0.043478261	0.888888889	0.082901554	0.963768431
192	31	34	0.998321244	0	0	0	0.493391848
193	31	37	0.998348615	0.054347826	0.588235294	0.099502488	0.948101777
194	31	40	0.998357739	0.032608696	0.75	0.0625	0.957569795
195	31	43	0.998321244	0	0	0	0.678213545
196	31	46	0.998302997	0.059782609	0.458333333	0.105769231	0.950847355
197	31	49	0.998321244	0	0	0	0.5
198	31	52	0.998321244	0	0	0	0.5

Ağ no.	1.Katman	2. Katman	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
199	34	1	0.998321244	0	0	0	0.957976779
200	34	4	0.998375986	0.038043478	0.875	0.072916667	0.962429863
201	34	7	0.998321244	0	0	0	0.957664861
202	34	10	0.998366863	0.043478261	0.727272727	0.082051282	0.961174341
203	34	13	0.998357739	0.054347826	0.625	0.1	0.968586628
204	34	16	0.998375986	0.059782609	0.6875	0.11	0.96868224
205	34	19	0.998366863	0.070652174	0.619047619	0.126829268	0.966489075
206	34	22	0.998375986	0.043478261	0.8	0.082474227	0.965363884
207	34	25	0.998375986	0.070652174	0.65	0.12745098	0.959055382
208	34	28	0.998366863	0.048913043	0.692307692	0.091370558	0.961155368
209	34	31	0.998403358	0.054347826	0.909090909	0.102564103	0.959830708
210	34	34	0.998375986	0.070652174	0.65	0.12745098	0.969025102
211	34	37	0.998375986	0.054347826	0.714285714	0.101010101	0.962508737
212	34	40	0.998348615	0.059782609	0.578947368	0.108374384	0.941553277
213	34	43	0.99838511	0.070652174	0.684210526	0.128078818	0.961537965
214	34	46	0.998348615	0.027173913	0.714285714	0.052356021	0.960782655
215	34	49	0.99838511	0.054347826	0.769230769	0.101522843	0.965692888
216	34	52	0.998366863	0.038043478	0.777777778	0.07253886	0.963787305
217	37	1	0.998321244	0	0	0	0.959982147
218	37	4	0.998330368	0.027173913	0.555555556	0.051813472	0.942636895
219	37	7	0.99838511	0.076086957	0.666666667	0.136585366	0.967660756
220	37	10	0.998321244	0	0	0	0.955830899
221	37	13	0.998394234	0.081521739	0.681818182	0.145631068	0.966524737
222	37	16	0.998339492	0.043478261	0.571428571	0.080808081	0.965377642
223	37	19	0.998366863	0.054347826	0.666666667	0.100502513	0.962095693
224	37	22	0.99838511	0.048913043	0.818181818	0.092307692	0.966302917
225	37	25	0.998348615	0.054347826	0.588235294	0.099502488	0.965145342
226	37	28	0.998357739	0.032608696	0.75	0.0625	0.955925717
227	37	31	0.998330368	0.043478261	0.533333333	0.08040201	0.954909647
228	37	34	0.99838511	0.081521739	0.652173913	0.144927536	0.965580389
229	37	37	0.99838511	0.076086957	0.666666667	0.136585366	0.967377347
<b>230</b>	<b>37</b>	<b>40</b>	<b>0.998394234</b>	<b>0.10326087</b>	<b>0.633333333</b>	<b>0.177570093</b>	<b>0.973367822</b>
231	37	43	0.998366863	0.059782609	0.647058824	0.109452736	0.969429354
232	37	46	0.99838511	0.043478261	0.888888889	0.082901554	0.964119985
233	37	49	0.998357739	0.043478261	0.666666667	0.081632653	0.96858484
234	37	52	0.998366863	0.086956522	0.592592593	0.151658768	0.972165098
235	40	1	0.998375986	0.065217391	0.666666667	0.118811881	0.962988038
236	40	4	0.998312121	0.054347826	0.476190476	0.097560976	0.952784628
237	40	7	0.998357739	0.02173913	1	0.042553191	0.957033127
238	40	10	0.998357739	0.065217391	0.6	0.117647059	0.966965595
239	40	13	0.998330368	0.005434783	1	0.010810811	0.960017859
240	40	16	0.998339492	0.010869565	1	0.021505376	0.957600639
241	40	19	0.998394234	0.070652174	0.722222222	0.128712871	0.968667339
242	40	22	0.998394234	0.076086957	0.7	0.137254902	0.966774272
243	40	25	0.998348615	0.065217391	0.571428571	0.117073171	0.964228957
244	40	28	0.998403358	0.065217391	0.8	0.120603015	0.967603935
245	40	31	0.998348615	0.054347826	0.588235294	0.099502488	0.958604441
246	40	34	0.998339492	0.086956522	0.533333333	0.14953271	0.965814924
247	40	37	0.998375986	0.054347826	0.714285714	0.101010101	0.969961751
248	40	40	0.998375986	0.059782609	0.6875	0.11	0.966673196
249	40	43	0.998375986	0.070652174	0.65	0.12745098	0.966577286
250	40	46	0.998403358	0.086956522	0.695652174	0.154589372	0.970912159
251	40	49	0.998339492	0.027173913	0.625	0.052083333	0.969752597
252	40	52	0.998321244	0	0	0	0.587990919
253	43	1	0.998330368	0.070652174	0.52	0.124401914	0.955764244
254	43	4	0.998412481	0.065217391	0.857142857	0.121212121	0.962139501
255	43	7	0.998321244	0	0	0	0.961024044
256	43	10	0.998375986	0.043478261	0.8	0.082474227	0.963011482
257	43	13	0.998330368	0.005434783	1	0.010810811	0.959320413
258	43	16	0.998366863	0.048913043	0.692307692	0.091370558	0.968078965
259	43	19	0.998348615	0.065217391	0.571428571	0.117073171	0.965060906
260	43	22	0.998375986	0.081521739	0.625	0.144230769	0.970404596
261	43	25	0.998394234	0.092391304	0.653846154	0.161904762	0.964034555
262	43	28	0.998394234	0.054347826	0.833333333	0.102040816	0.961668941
263	43	31	0.998357739	0.043478261	0.666666667	0.081632653	0.958609308
264	43	34	0.998375986	0.059782609	0.6875	0.11	0.963480701
265	43	37	0.998403358	0.059782609	0.846153846	0.111675127	0.966489671
266	43	40	0.998375986	0.043478261	0.8	0.082474227	0.963817453

Ağ no.	1.Katman	2. Katman	Doğruluk	Duyarlılık	Kesinlik	F Skoru	AUC
267	43	43	0.99838511	0.054347826	0.769230769	0.101522843	0.969230531
268	43	46	0.998366863	0.065217391	0.631578947	0.118226601	0.967184037
269	43	49	0.998339492	0.065217391	0.545454545	0.116504854	0.959558425
270	43	52	0.998339492	0.010869565	1	0.021505376	0.959183874
271	46	1	0.998302997	0.010869565	0.333333333	0.021052632	0.856247887
272	46	4	0.998321244	0	0	0	0.955841777
273	46	7	0.998375986	0.070652174	0.65	0.12745098	0.96966826
274	46	10	0.998366863	0.054347826	0.666666667	0.100502513	0.965806232
275	46	13	0.998357739	0.038043478	0.7	0.072164948	0.965190789
276	46	16	0.998321244	0	0	0	0.962070908
277	46	19	0.998339492	0.032608696	0.6	0.06185567	0.966205766
278	46	22	0.998348615	0.038043478	0.636363636	0.071794872	0.968732455
279	46	25	0.998394234	0.070652174	0.722222222	0.128712871	0.966642849
280	46	28	0.998330368	0.086956522	0.516129032	0.148837209	0.969757117
281	46	31	0.998339492	0.038043478	0.583333333	0.071428571	0.965171865
282	46	34	0.99838511	0.054347826	0.769230769	0.101522843	0.967369947
283	46	37	0.99838511	0.076086957	0.666666667	0.136585366	0.943482453
284	46	40	0.998321244	0	0	0	0.5
285	46	43	0.998366863	0.032608696	0.857142857	0.062827225	0.968068982
286	46	46	0.998375986	0.054347826	0.714285714	0.101010101	0.959624832
287	46	49	0.998339492	0.027173913	0.625	0.052083333	0.962270427
288	46	52	0.998321244	0	0	0	0.5
289	49	1	0.998321244	0	0	0	0.958822585
290	49	4	0.998321244	0	0	0	0.965898218
291	49	7	0.998321244	0	0	0	0.953107871
292	49	10	0.998394234	0.086956522	0.666666667	0.153846154	0.967707047
293	49	13	0.998339492	0.065217391	0.545454545	0.116504854	0.966636094
294	49	16	0.998357739	0.054347826	0.625	0.1	0.964665097
295	49	19	0.998366863	0.038043478	0.777777778	0.07253886	0.958253384
296	49	22	0.998375986	0.065217391	0.666666667	0.118811881	0.967892112
297	49	25	0.998375986	0.054347826	0.714285714	0.101010101	0.964865708
298	49	28	0.998394234	0.070652174	0.722222222	0.128712871	0.967432281
299	49	31	0.998357739	0.081521739	0.576923077	0.142857143	0.9665228
300	49	34	0.998412481	0.070652174	0.8125	0.13	0.965874427
301	49	37	0.998375986	0.070652174	0.65	0.12745098	0.967838222
302	49	40	0.998375986	0.059782609	0.6875	0.11	0.964457383
303	49	43	0.998394234	0.076086957	0.7	0.137254902	0.967546171
304	49	46	0.998403358	0.092391304	0.68	0.162679426	0.969246921
305	49	49	0.998357739	0.059782609	0.611111111	0.108910891	0.964584336
306	49	52	0.998339492	0.043478261	0.571428571	0.080808081	0.960688384
307	52	1	0.998321244	0	0	0	0.957344648
308	52	4	0.998321244	0	0	0	0.96065163
309	52	7	0.99838511	0.065217391	0.705882353	0.119402985	0.965335126
310	52	10	0.99838511	0.054347826	0.769230769	0.101522843	0.96739498
311	52	13	0.998339492	0.027173913	0.625	0.052083333	0.959802893
312	52	16	0.998357739	0.038043478	0.7	0.072164948	0.964256474
313	52	19	0.998348615	0.048913043	0.6	0.090452261	0.965350771
314	52	22	0.998394234	0.081521739	0.681818182	0.145631068	0.972536917
315	52	25	0.998330368	0.048913043	0.529411765	0.089552239	0.9435053
316	52	28	0.998339492	0.010869565	1	0.021505376	0.960796066
317	52	31	0.998394234	0.070652174	0.722222222	0.128712871	0.969444304
318	52	34	0.998375986	0.043478261	0.8	0.082474227	0.967738637
319	52	37	0.99838511	0.065217391	0.705882353	0.119402985	0.965481499
320	52	40	0.998375986	0.070652174	0.65	0.12745098	0.968506264
321	52	43	0.998366863	0.059782609	0.647058824	0.109452736	0.968496777
322	52	46	0.998366863	0.059782609	0.647058824	0.109452736	0.969207683
323	52	49	0.998321244	0	0	0	0.499931457
324	52	52	0.998348615	0.070652174	0.565217391	0.125603865	0.965020972

## 8. ÖZGEÇMİŞ

**Adil Koray YILDIZ**

**Doğum Tarihi:** 1984

**Doğum Yeri:** Niksar/TOKAT

**Lisans:** Ankara Üniversitesi, Mühendislik Fakültesi, Elektronik Mühendisliği Bölümü  
(Mezuniyet Yılı: 2009)

**Yüksek Lisans:** Tokat Gaziosmanpaşa Üniversitesi, Fen Bilimleri Enstitüsü, Tarım  
Makinaları Programı (Mezuniyet Yılı: 2013)

