



**SAF HAT YUMURTACI TAVUKLARDA VERİM
ÖZELLİKLERİNE YÖNELİK PEDİGRİ TAKİBİ VE
YUMURTA KALİTESİ ANALİZİ**

Kübra ARSLAN

**2022
YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Eftal ŞEHİRLİ**

**SAF HAT YUMURTACI TAVUKLARDA VERİM ÖZELLİKLERİNE
YÖNELİK PEDİGRİ TAKİBİ VE YUMURTA KALİTESİ ANALİZİ**

Kübra ARSLAN

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Eftal ŞEHİRLİ**

**KARABÜK
Haziran 2022**

Kübra ARSLAN tarafından hazırlanan “SAF HAT YUMURTACI TAVUKLARDA VERİM ÖZELLİKLERİNE YÖNELİK PEDİGRİ TAKİBİ VE YUMURTA KALİTESİ ANALİZİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr.Üyesi Eftal ŞEHİRLİ

.....

Tez Danışmanı, Tıp Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.07/06/2022

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Dr. Öğr. Üyesi Abdullah ELEN (BANÜ)

.....

Üye : Dr. Öğr. Üyesi Eftal ŞEHİRLİ (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Ahmet Reşit KAVSAOĞLU (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Kübra ARSLAN

ÖZET

Yüksek Lisans Tezi

SAF HAT YUMURTACI TAVUKLARDA VERİM ÖZELLİKLERİNE YÖNELİK PEDİGRİ TAKİBİ VE YUMURTA KALİTESİ ANALİZİ

Kübra ARSLAN

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Eftal ŞEHİRLİ

Haziran 2022, 74 sayfa

Artan dünya nüfusuyla birlikte insanların beslenme ihtiyacındaki gereksinimler artmaktadır. Bu artış, insanları maliyet olarak düşük ve protein olarak zengin besin maddelerinin geliştirilmesine yönlendirmektedir. Bu özelliklere en uygun besin kaynaklarının başında yumurta gelir. Yumurta ihtiyacının karşılanması için yapılan çalışmalar bu sebeple büyük önem arz etmektedir. Bu çalışmada; insanların doğru beslenmelerine katkı sunmak ve tavuklarda oluşabilecek kuş gribi gibi olumsuz durumlara karşı hazırlıklı olmak için sağlıklı saf hat yumurtacı bireyler yetiştirilmesi hedeflenmiştir. Sağlıklı bireylerin yetiştirilmesi için tam otomatik bir şekilde haugh birimi (HU) kullanılmadan yumurta kalitesinin belirlenmesi ve HU değerlerinin yumurta kalitesinin özellikleri hakkında ne kadar bilgi taşıdığını belirlemek amaçlanmıştır. Çalışma için Tavukçuluk Araştırma Enstitüsü (TAE) tarafından oluşturulan ve 438 tavuktan alınan yumurtalara ilişkin 20 özelliği içeren bir veriseti analiz edilmiştir. Bu çalışmada rastgele orman, lineer diskriminant analizi (LDA),

lojistik regresyon (LR), naive bayes (NB), destek vektör makineleri (DVM), k-en yakın komşu (K-NN), karar ağacı ve yapay sinir ağları (YSA) makine öğrenmesi modelleri kullanılarak yumurta kalitelerini çok iyi ve mükemmel olarak sınıflandırabilen bir uygulama geliştirilmiştir. Buna ek olarak, yumurta kalitesini belirlemede en önemli sınıflandırıcı olan 24. hafta ve 32. hafta HU değerleri, geliştirilen uygulama ile az bilgi, orta bilgi ve çok bilgi veren olarak sınıflandırılmıştır. Yumurta kalitesi, doğruluk (accuracy) ve matthews korelasyon katsayısı (MCC) değerleri bazında, LR modeli tarafından sırasıyla %98.6 ve 0.96 olarak en iyi sınıflandırılmıştır. 24. hafta HU değerleri, doğruluk ve MCC değerleri bazında göre rastgele orman modeli tarafından sırasıyla %96.8 ve 0.93 olarak en iyi sınıflandırılmıştır. 32. hafta HU değerleri, doğruluk ve MCC değerleri bazında rastgele orman modeli tarafından sırasıyla %95.1 ve 0.92 olarak en iyi sınıflandırılmıştır. Bu çalışma temel olarak sadece HU değerlerine göre değil aynı zamanda yumurta karakteristik özelliklerine ve HU değerlerinin bilgilendirici özelliğinin yumurta kalitesini sınıflandırmadaki önemine dayalı olarak yumurta kalitesinin sınıflandırılmasına odaklanmaktadır. Böylece, literatürdeki çalışmalardan farklı olarak HU paratmesi kullanmadan yumurta kalitesi hakkında bilgi elde edilebildiği gözlemlenmiştir. Buna bağlı olarak, en doğru tavuk çiftleri belirlenerek damızlık seçiminde isabet derecesi artırılmıştır ve tavuk damızlık materyal temininde dışa bağımlılığın azaltılarak ülke öz yeterliliğinin artırılmasına katkı sunulmuştur.

Anahtar Sözcükler : Haugh birimi, makine öğrenmesi, sınıflandırma, veri analizi, yumurta kalitesi.

Bilim Kodu : 92517

ABSTRACT

M. Sc. Thesis

PEDIGREE AND EGG QUALITY ANALYSIS FOR YIELD CHARACTERISTICS IN PURE LINE LAYER CHICKENS

Kübra ARSLAN

**Karabük University
Institute of Graduate Programs
Department of Biomedical Engineering**

Thesis Advisor:

Assist. Prof. Dr. Eftal ŞEHİRLİ

June 2022, 74 pages

With the increase in the human population all over the world, the nutritional needs of people are increasing. Increasing of the nutritional needs lead researchers to focus on low-cost, protein-rich food alternatives. Egg is one of the most suitable food source candidates for these characteristics. In this respect, studies aimed at overcoming the need for eggs possess importance. In this study, it is aimed to raise healthy-pure line individual, in order to contribute to the proper nutrition of people and be prepared for adverse situations such as bird flu that may occur in chickens. In order to raise healthy individuals, it is aimed to determine the egg quality without using the haugh unit (HU) in a fully automatic way and determine how much valuable information HU values involve about the characteristics of egg quality. A dataset created by the Poultry Research Institute (TAE) containing 20 characteristics of eggs from 438

chickens was analysed in this study. An application that can classify egg qualities as good and excellent using machine learning models like random forest, linear discriminant analysis (LDA), logistic regression (LR), naïve bayes (NB), support vector machines (DVM), k-nearest neighboring (K-NN), decision tree and artificial neural networks (YSA) has been developed in this study. In addition to that, HU at the 24 th week and the 32 nd week which are the most important classifier to determine egg qualities have been classified as low informative, medium informative, and high informative by the developed application. Egg quality has the best been classified by LR model based on accuracy and matthews correlation coefficient (MCC) values as 98.6% and 0.96, respectively. HU at the 24 th week has the best been classified by random forest based on accuracy and MCC as 96.8% and 0.93, respectively. HU at the 32 nd week has the best been classified by random forest based on accuracy and MCC as 95.1% and 0.92, respectively. This study mainly focuses on the classification of egg quality not only according to HU values, but also based on egg characteristics and the importance of informative feature of HU values in classifying egg quality. Herewith, unlike the studies in the literature, it has been observed that information about the egg quality egg can be obtained without using HU parameter. Accordingly, the most accurate chicken couples were determined, the accuracy of breeder selection was increased, and the country's self-sufficiency was contributed by reducing external dependence in the supply of chicken breeder materials.

Key Word : Haugh unit, machine learning, classification, data analysis, egg quality.

Science Code: 92517

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Eftal őEHİRLİ'ye sonsuz teşekkürlerimi sunarım.

Bu alıőmanın yapılmasında yardımlarını esirgemeyen, Bolu Abant İzzet Baysal Üniversitesi Tıp Fakóltesi Temel Tıp Bilimleri Bölümü öğretim üyesi Prof. Dr. Seyit Ali KAYIő 'a teşekkür ederim.

Eęitim hayatım boyunca üzerimde emeęi olan bütün öğretmenlerime ve arkadaşlarıma teşekkür ederim.

Sevgili aileme maddi ve manevi hiçbir yardımı esirgemedен yanımda oldukları için teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ.....	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiv
BÖLÜM 1.....	1
GİRİŞ.....	1
BÖLÜM 2.....	6
KUŞ GRİBİ.....	6
2.1. DÜNYADA KUŞ GRİBİ ETKİLERİ.....	6
2.2. TÜRKİYE'DE KUŞ GRİBİ ETKİLERİ.....	7
BÖLÜM 3.....	10
PYTHON VE MATLAB.....	10
3.1. PYTHON.....	10
3.2. MATLAB.....	12
BÖLÜM 4.....	14
LİTERATÜR TARAMASI.....	14
BÖLÜM 5.....	18
MATERYAL.....	18

	<u>Sayfa</u>
BÖLÜM 6	24
METOT	24
6.1. PEDİGRİ TAKİBİ.....	25
6.2. SINIFLANDIRMA ALGORİTMALARI	32
6.2.1 Rastgele Orman	34
6.2.2. Lineer Diskriminant Analizi (LDA)	35
6.2.3. Lojistik Regresyon (LR).....	37
6.2.4. Naive Bayes (NB).....	37
6.2.5. Destek Vektör Makineleri (DVM).....	38
6.2.6. K En Yakın Komşu (K-NN).....	40
6.2.7. Karar Ağacı.....	42
6.2.8. Yapay Sinir Ağları (YSA)	44
6.3. PERFORMANS ÖLÇÜTLERİ	46
BÖLÜM 7	48
DENEYSEL SONUÇLAR VE TARTIŞMA.....	48
KAYNAKLAR	63
ÖZGEÇMİŞ	74

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	Tavuk itlafına ait görsel	7
Şekil 2.2.	Kriz yıllarında tavuk yumurtası üretimindeki değişime ait görsel	9
Şekil 3.1.	Python arayüzüne ait görsel	10
Şekil 3.2.	Matlab arayüzüne ait görsel	12
Şekil 6.1.	Pedigri takibi görseli	26
Şekil 6.2.	Projede uygulanan çiftleştirme şeması.....	27
Şekil 6.3.	Hat 1 (H1) ve Hat 2 (H2)	28
Şekil 6.4.	H1 ve H2 SNP ve QTL/QTN lokusları.....	29
Şekil 6.5.	F1 X F1 çiftleştirmelerinden elde edilecek F2 jenerasyonu bireyler	29
Şekil 6.6.	F2 tavuklarının SNP genotip allellerinin ebeveynlerinin takibi.....	30
Şekil 6.7.	F2 tavuklarının fenotip ilişkilendirmesi.....	31
Şekil 6.8.	Pedigri takibi programına ait görsel.....	32
Şekil 6.9.	Makine öğrenmesi modelleri	33
Şekil 6.10.	Rastgele orman algoritmasına ait görsel	35
Şekil 6.11.	LDA modeline ait görsel.....	36
Şekil 6.12.	DVM algoritmasına ait görsel.....	39
Şekil 6.13.	K-NN algoritması sınıf belirleme işlemine ait görsel	41
Şekil 6.14.	Karar ağacı algoritmasına ait görsel.....	43
Şekil 6.15.	YSA algoritmasına ait görsel	45
Şekil 7.1.	Yumurta kalitesini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi	50
Şekil 7.2.	Yumurta kalitesini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi	50
Şekil 7.3.	Yumurta kalitesini sınıflandırmak için kullanılan LR modelinin ROC eğrisi.....	50
Şekil 7.4.	Yumurta kalitesini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.....	51
Şekil 7.5.	Yumurta kalitesini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi.....	51

Şekil 7.6.	Yumurta kalitesini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi	51
Şekil 7.7.	Yumurta kalitesini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi	52
Şekil 7.8.	Yumurta kalitesini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi	52
Şekil 7.9.	24. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi.	54
Şekil 7.10.	24. hafta HU değerlerini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi.	54
Şekil 7.11.	24. hafta HU değerlerini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.....	54
Şekil 7.12.	24. hafta HU değerlerini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi.....	55
Şekil 7.13.	24. hafta HU değerlerini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi.....	55
Şekil 7.14.	24. hafta HU değerlerini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi.	55
Şekil 7.15.	24. hafta HU değerlerini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi	56
Şekil 7.16.	32. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi	57
Şekil 7.17.	32. hafta HU değerlerini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi.....	57
Şekil 7.18.	32. hafta HU değerlerini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.....	57
Şekil 7.19.	32. hafta HU değerlerini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi	58
Şekil 7.20.	32. hafta HU değerlerini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi.....	58
Şekil 7.21.	32. hafta HU değerlerini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi	58
Şekil 7.22.	32. hafta HU değerlerini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi	59

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 1.1. Dünyada yıllık yumurta üretiminde ilk 10'da yer alan ülkeler.....	2
Çizelge 1.2. Türkiyede yıllara göre yumurta üretimi.....	2
Çizelge 2.1. Türkiye'de 2009-2010 yılları arasında kuş gribinin kronolojisi.....	8
Çizelge 5.1. Çalışmaya ait verilerin parametreleri.....	18
Çizelge 5.2. Çalışmaya ait yumurta kalitesi özellikleri.....	19
Çizelge 5.3. Verisetlerinde bulunan parametreler.....	20
Çizelge 5.4. Bilgisayar özellikleri.....	22
Çizelge 5.5. F0'larda COY ve COA değerleri.....	22
Çizelge 5.6. F0'larda yumurta sayısı ve yumurta ağırlığı değerleri.....	22
Çizelge 5.7. F0'larda genetik yönelim.....	22
Çizelge 5.8. F1 genotiplerinin civciv ağırlığı.....	23
Çizelge 5.9. F1 genotiplerinde cinsel olgunluk ağırlığı.....	23
Çizelge 6.1. Algoritma akış sırası.....	24
Çizelge 6.2. K-NN algoritmasının akış şeması.....	41
Çizelge 6.3. Makine öğrenmesi modellerinin özellikleri ve parametreleri.....	46
Çizelge 6.4. Confusion matrix.....	46
Çizelge 7.1. Makine öğrenme modelleri analiz sonuçları.....	49
Çizelge 7.2. 24. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin sonuçları.....	53
Çizelge 7.3. 32. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin sonuçları.....	56
Çizelge 7.4. Literatürdeki çalışmaların karşılaştırılması.....	61

SİMGELER VE KISALTMALAR DİZİNİ

KISALTMALAR

ACC	: Doğruluk Değeri (Accuracy)
ATABEY	: Yerli Beyaz Yumurta Hibrit
AVIAN İNFLUENZA	: Kuş Gribi
BAR	: Barred Rock
COA	: Cinsel Olgunluk Ağırlığı
COY	: Cinsel Olgunluk Yaşı
DSÖ	: Dünya Sağlık Örgütü
DVM	: Destek Vektör Makineleri
EFI	: Equal Frequency İntervals
EWI	: Equal Width İntervals
F0	: Nene-Dede Tavuk Birey
F1	: Anne-Baba Tavuk Birey
F2	: Tavuk Birey
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
G	: Yumurta Ağırlığı
GB	: Gigabayt
GHz	: Gigahertz
H	: Ak Yüksekliği (mm)
HU	: Haugh Birimi (Haugh Unit)
KMC	: K-Means Clustering
K-NN	: K En Yakın Komşu Algoritması
LDA	: Lineer Diskriminant Analizi
LR	: Lojistik Regresyon
MATLAB	: Matris Laboratuvarı (Matrix Laboratory)
MB	: Megabayt

MCC	: Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient)
MTDFREML	: Multiple-trait derivative-free restricted maximum likelihood
NB	: Naive Bayes
NIR	: Near İnfrared
PLS-DA	: Partial Least Square Discrimination Analysis
PLS-DA	: Partial Least Square Discriminant Analysis
QTL	: Kantitatif Karakter Lokusları (Quantitative Character Loci)
QTN	: Niceliksel Özellik Nükleotidi
REML	: Resticted Maximum Likelihood
RIR	: Rhode Island Red
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SNP	: Single Nucleotide Polymorphism
SQL	: Yapılandırılmış Sorgu Dili (Structured Query Language)
SVDD	: Support Vector Data Description
SVM-C	: Support Vector Machine Classification
TAE	: Tavukçuluk Araştırma Enstitüsü
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Positive)
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
YSA	: Yapay Sinir Ağları

BÖLÜM 1

GİRİŞ

Beslenme, insan hayatı için önemli bir yere sahiptir. Günümüzün en büyük sorunlarından biri, insanların sağlıklı besinlerle beslenememeleridir. Sağlıklı bir hayat sürdürülebilmesi için hayvansal ve bitkisel besinlerin yeteri kadar alınması gerekmektedir. Hayvansal ürünlerden sağlanan besin maddeleri, sağlıklı ve uzun bir yaşam için önemli bir etkidir. Sağlıklı bireyler yetiştirilmesi için insanların, vitamin, protein ve mineral bakımından zengin olan gıdaları tüketmesi gerekmektedir. Bu gıdaların başında, doğal bir besin kaynağı ve biyolojik değeri yüksek olan tavuk yumurtası gelmektedir. Tavuk yumurtası, sağlıklı beslenme için insanların ihtiyacı olan vitamin ve minerallerin çoğunu içerisinde bulundurmaktadır [1]. Yumurta, biyolojik değeri yüksek olan protein yapısı ve içeriğinde bulunan diğer besin maddelerinden dolayı proteinlerin kaliteleri için ölçüt olarak kullanılmaktadır. Hayvansal ve bitkisel kökenli besinler içerisinde anne sütünün içerdiği bütün besin maddelerine sahip olan tek besin yumurtadır. Yumurta, vitamin ve minarel olarak da zengindir. Yumurta sarısı içerisinde A, D ve E vitaminlerini; yumurta akı içerisinde niasin vitaminini bulundurmaktadır. Yumurta akı içerisinde sodyum, potasyum, klor, kükürt ve magnezyum minarellerini; yumurta sarısı içerisinde demir, bakır, kalsiyum ve çinko minarellerini bulundurmaktadır [2-6].

Bir yumurtanın %10'u yumurta kabuğu, %30'u yumurta sarısı ve %60'ı yumurta akından oluşmaktadır. Yumurtadaki protein oranı ortalama %10'dur. Bu oran, yetişkin bir insanın günlük protein ihtiyacının %10'unu karşılamaktadır [6]. Ucuz bir protein kaynağı ve kolay ulaşılabilir olmasına rağmen Türkiye'de yumurta, dünya ortalamasının altında tüketilmektedir [7]. Türkiye'de yumurta tüketimi, yeterli orana sahip olmamasına rağmen, Türkiye dünyada yumurta üretimi en fazla olan ilk on

ülkenin içerisinde yer almaktadır. Dünyada yumurta üretiminin en fazla olduğu ilk on ülke ve ülkelerin yumurta üretim miktarları Çizelge 1.1’de verilmiştir. Türkiye’nin 2010-2021 yılları arasındaki yumurta üretimine ilişkin değerleri ise Çizelge 1.2’de verilmiştir.

Çizelge 1.1. Dünyada yıllık yumurta üretiminde ilk 10’da yer alan ülkeler [8].

Sıra	Ülke	Üretim (ton)
1	Çin	31,338,856
2	ABD	6,258,795
3	Hindistan	4,847,500
4	Japonya	2,601,173
5	Brezilya	2,547,171
6	Meksika	2,171,198
7	Endonezya	1,527,135
8	Türkiye	1,250,075
9	Fransa	955,000
10	Ukrayna	886,500

Çizelge 1.2. Türkiye’de yıllara göre yumurta üretimi değerleri [9].

Yıllar	Yumurta sayısı (adet)
2000	13,508,586
2005	12,052,455
2010	11,840,396
2011	12,954,686
2012	14,910,774
2013	16,496,751
2014	17,145,389
2015	16,727,510
2016	18,097,605
2017	19,281,196
2018	19,643,711
2019	19,898,126
2020	19,788,063
2021	15,994,504

Çizelge 1.2’de yıllara göre yumurta üretim miktarları yer almaktadır. Bu çizelgeye göre; yumurta sayısının, bazı yıllarda önceki yıllara göre azaldığı, bazı yıllarda ise önceki yıllara göre artma eğiliminde olduğu görülmektedir. Bu yıllarda yumurta üretiminin azalmasında, salgın hastalıklar ve ekonomik sorunlar gibi farklı etkenler etkili olmaktadır. Çizelgeye bakıldığında 2005 ve 2010 yıllarında yumurta sayısının, önceki yıllara göre azaldığı görülmektedir. Bu yıllardaki yumurta sayısındaki azalış, uzun süre tüm dünyayı etkisi altına alan kuş gribi salgının o dönemlerde var olmasıyla ilgilidir.

Kuş gribinin en yüksek oranda görüldüğü yıl 2006 yılıdır. Ülkemizde son olarak 2015 yılında görülen kuş gribi salgını, 53 ile yayılmış olup 2,5 milyonun üzerinde kanatlı hayvanın, hastalığın kontrolü amacıyla itlafına neden olmuştur. İtlaf sebebiyle yumurta sayısında azalma eğilimi görülmüştür [10,11]. Bu çalışmanın temel amacı, kuş gribi, tavuk gribi gibi insan sağlığını ve doğru beslenmeyi etkileyecek durumlara karşı oluşabilecek kötü sonuçları önlemektir.

Tavukçuluk Araştırma Enstitüsü (TAE), ülkemizde tavuk yumurtası konusunda araştırmalar yapmaktadır. TAE’de yapılan çalışmalardan biri, hibrit üretime imkân sağlayan ebeveyn saf hatların geliştirilmesidir. İslah çalışmalarında kullanılacak her tavuk ve horozun pedigrî kayıtları titizlikle tutulmakta ve elde edilen bilgiler istatistiksel yöntemlerle değerlendirilmektedir. Bireyler, yüksek yumurta ağırlığı özelliğine sahip cins olan Rhode Island Red (RIR) ve yüksek yumurta verimi özelliğine sahip cins olan Barred Rock (BAR) olarak TAE’de etiketlenmektedir. Massachusetts’te geliştirilen bir hat olarak üretilen RIR, orta ağırlıkta çok iyi yumurtlama kapasitesine sahip bir ırktır. RIR cinsi ile çok iyi bir kombinasyona sahip olan BAR, dayanıklılığı ve ortama çabuk adapte olabilirliliği ile bilinmektedir [12]. 2017 yılı 43 haftalık dönemi kapsayan RIR ve BAR ırklarındaki bireyler ve bu bireylerin yumurta üretim özellikleri hakkındaki bilgiler TAE veritabanında saklanmaktadır.

TAE, yüksek protein ve yumurta verimine sahip en iyi tavuk türlerini belirlemeyi ve yenilemeyi amaçlamaktadır. Bu nedenle, karakteristik yumurta özelliklerini ölçmek ve TAE amacına en uygun genotipe ulaşmak için Det-6000 adlı bir dijital yumurta

test cihazı kullanılmaktadır. Yumurta test cihazı, yumurta ağırlığını, kabuk kalınlığı değerini, mukavemet değerini, HU değerini, albümen yükseklik değerini, yumurta beyazı değerlerini ve yumurta sarısı değerlerini yumurtalarla ilgili olarak ölçmektedir [13]. Bu veriler TAE veritabanına kaydedilmektedir.

Yumurta üretimi ve tüketiminin yanı sıra, yumurta kalitesi de önemlidir. TAE'nin yaptığı araştırmalara göre, bir yumurtanın kalitesi çok iyi ya da mükemmel olarak sınıflandırılmaktadır. Kalitesi düşük olan yumurtalar üzerinde araştırma yapılmamaktadır. Yumurta kalitesinin belirlenmesinde yumurtanın iç ve dış özellikleri ile ilgili bazı kriterler göz önünde bulundurulmaktadır. Bu kriterler; yumurta ağırlığı, kabuk kalitesi ve koyu ak kalitesidir. Bu kriterlere ek olarak, HU bir yumurtanın iç kalitesinin belirlenmesi için bir standart olarak yorumlanmıştır [14]. Bu çalışmada yumurta kalitesi sınıflandırılması için, HU yerine sadece bu özellikler kullanılarak makine öğrenmesi modelleri nden yararlanılmıştır.

Makine öğrenmesi; sınıflandırma, regresyon, kümeleme ve bilgi çıkarma gibi konularda ele alınmaktadır. Günümüzde makine öğrenmesi modellerine en çok sınıflandırılma yapmak için başvurulmaktadır. Sınıflandırma, hastalık tahmini görüntüleme, borsa analizi, biyoloji, ses senkronizasyonu, nesne tanıma, gen çeşitliliği, ilaç tasarımı ve hayvan bilimi gibi birçok alanda yaygın olarak kullanılmaktadır [15,16]. Sınıflandırma, verileri belirli özelliklerine göre gruplandırma işlemidir. Bu tez çalışması, tam otomatik yumurta sınıflandırmayı yapan Matlab programında analiz yapan uygulamayı tanıtmaktadır. Geliştirilen bu uygulama ile birlikte yumurta kalitesiyle ilgili sonuçlar sunulmaktadır. Matlab ve Python, son zamanlarda yapay zeka, biyomedikal, biyoloji, hayvan bilimi ve özellikle veri analizi alanlarında yaygın olarak kullanılmaktadır [17-21].

Bu tez çalışması 7 bölümden oluşmaktadır. Birinci bölüm "Giriş" olup tezin tanımı ve amacı açıklanarak çalışmanın konu özeti verilmiştir. İkinci bölümde kuş gripinin detaylı açıklaması yapılarak dünyadaki ve Türkiye'deki etkilerinden bahsedilmiştir. Üçüncü bölümde bu çalışmada kullanılan python ve matlab programları açıklanmıştır. Dördüncü bölümde bu konudaki literatür özeti verilmiştir. Beşinci bölümde, çalışmanın amacının anlatılmasına ek olarak, deneysel çalışmalarda

kullanılan tavuk bireylerinin türleri, kullanılan veriler ve parametreler anlatılmıştır. Makine öğrenmesi modelleri kullanılarak yapılan sınıflandırma işlemleri için kullanılan HU açıklanmıştır. Ayrıca kullanılan bilgisayar özellikleri tanıtılmış ve tavukların verim özelliklerine ait istatistiki bilgiler verilmiştir. Altıncı bölümde, bireylere ait pedigrî takibi ve bireylerden elde edilen yumurta özelliklerinin analizini yapan makine öğrenmesi modelleri anlatılmıştır. Yedinci bölümde, analiz sonucu elde edilen bulgular sunulmuş ve literatürde bu konuda yapılan çalışmalarla kıyaslanmıştır.

BÖLÜM 2

KUŞ GRİBİ

Avian influenza virüsleri içerisinde bulunan A tipi virüs, evcil, yabani kanatlılar ve memeli hayvanların bir kısmında solunum ve sindirim sistemine ait belirtiler gösteren bulaşıcı bir hastalığa sebep olmaktadır. Ölüm vakalarına neden olabildiği gözlemlenen bu virüsler, hemaglutinin ve nörominidaz antijenlerine göre ayrılmaktadır [11].

İnfluenza virüsünün ekolojisinde ve epidemiyolojisinde çok önemli bir özelliği türler arasında bulaşmasıdır [22]. İnfluenza virüsünün türler arası geçişinin temel mekanizmalarından biri, esasen değişmemiş bir virüsün bir türden diğerine doğrudan aktarılmasıdır [23]. Hastalık bir ülkeden başka bir ülkeye canlı kümes hayvanı ticareti ile yayılmaktadır. Kuş gribi; Afrika, Asya, Avrupa ve Orta Doğu'da birçok ülkede kümes hayvanlarında ve yabani kuşlarda saptanmıştır [24,25].

2.1. DÜNYADA KUŞ GRİBİ ETKİLERİ

Salgın hastalıklar küresel sistemi, ülkeleri ve toplumları etkilemektedir. Bu etki her salgında aynı olmamaktadır. Bazı salgınlardan sonra küresel sistem köklü değişikliklere uğramaktadır. Bu değişikliklerle birlikte, birçok açıdan yıkıcı olan salgınlardan biri kuş gribi olmuştur. Kuş gribi salgınının var olduğu dönemlerde insanların sağlıklı yumurtaya ulaşma imkanlarını azalmıştır. Çünkü birçok ülkede tavuk itlafı yapılmış ve bu durum yumurta üretiminin azalmasına neden olmuştur. Tavuk itlafına ait görsel Şekil 2.1'de gösterilmiştir [11,26].



Şekil 2.1. Tavuk itlafına ait görsel [27].

Tavuklarda yüksek mortalite ile seyreden kuş gribine, virüslerin neden olduğu düşünülmüştür. Fakat 1955 yılına kadar kanatlı vebalı virüslerin, influenza A virüsleri olduğu anlaşılamamıştır. Güneydoğu Asya’da 1957 ve 1968 yıllarında, bu virüslerle insan virüslerinin temasından oluşan salgınlar ortaya çıkmıştır. 2000 yılında Asya’da patlak veren ve hızla yayılmaya başlayan bu virüsün kontrol altına alınması güçleşmiştir. İnsanlarda da görülmeye başlanmasıyla endişeler ve araştırmalar artmaya başlamıştır [10,28].

Virüs 1997, 2003 ve 2005 yıllarında artış göstermiştir ve insan ölümlerine sebep olmuştur. Dünya Sağlık Örgütü (DSÖ) açıklamalarına göre 2003 yılı ve sonrasında 455 ölüm ve 851 vaka meydana gelmiştir. Bu ölümlerin birçoğu Mısır, Endonezya, Vietnam ve Çin’de gerçekleşmiştir. Giderek global bir tehlikeye dönüşen kuş gribinin, insan sağlığını tehdit eden boyutlara ulaşarak, dünya genelinde büyük ekonomik, sosyal ve kültürel sonuçlar meydana getirdiği gözlemlenmiştir [25,29].


2.2. TÜRKİYE’DE KUŞ GRİBİ ETKİLERİ

Türkiye’de kuş gribi ilk olarak 15 Mayıs 2009 tarihinde Ağrı’nın Doğubeyazıt ilçesinde görülmüştür. 2003-2009 yılları arasında 21 kişide kuş gribi vakası gözlemlenmiş ve bu vakaların 4’ü ölümlerle sonuçlanmıştır. Türkiye’de kuş gribinden kaynaklı 13.591 vaka ve 656 ölüm meydana gelmiştir. [30]. (30) Türkiye’de 2009-2010 yılları arasında kuş gribinin kronolojisi Şekil 2.1’de gösterilmiştir.

Çizelge 2.1. Türkiye’de 2009-2010 yılları arasında kuş gribinin kronolojisi [31].

Tarih	Olay	Durum
12.04.2009	Meksika ve ABD ülkelerinde kuş gribinin görülmesi	Sınırlandırma dönemi
27.04.2009	DSÜ’nün Evre 4’ü ilan etmesi	
29.04.2009	DSÜ’nün Evre 5’i ilan etmesi	
15.05.2009	Türkiye’de ilk kuş gribi vakasının görülmesi	
11.06.2009	DSÜ’nün Evre 6’yı ilan etmesi	
18.06.2009	Türkiye’de ilk yerli vakanın görülmesi	
13.10.2009	Türkiye’de ilk okul salgınının görülmesi	
22.10.2009	Türkiye’de ilk ölümün görülmesi	
26.10.2009	Türkiye’de Pandemi Koordinasyon Merkezi’nin kurulması	
02.11.2009	Türkiye’de aşılamanın başlaması	
30.11.2009	Türkiye’de salgın eğrisinin piki	
03.05.2010	Türkiye’de en son görülen ölüm vakası	Hafifleme dönemi

Kuş gribini küresel olarak salgın bir hastalık halini almasıyla birlikte tavukçuluk sektöründe krizler yaşanmaya başlamıştır. Senelik cirosu iki buçuk milyarı dolara kadar çıkan bu sektörün satışları ilk krizin ardından yarı yarıya düşmüş ve kapasite kullanımı %40'lara gerilemiştir. Tavuk sektöründe ülkemizde yatırım yapan birçok kurum, krizin tavukçuluk sektörünü yarı yarıya daralttığını belirtmişlerdir. Virüsün ülkemizde görülmeye başlandığı andan itibaren yumurta tüketimi doksan puan düşmüştür [24]. Kriz yıllarında tavuk yumurtası üretimindeki değişim (%) Şekil 2.2’de gösterilmiştir.



Şekil 2.2. Kriz yıllarında tavuk yumurtası üretimindeki değişime ait görsel [31].

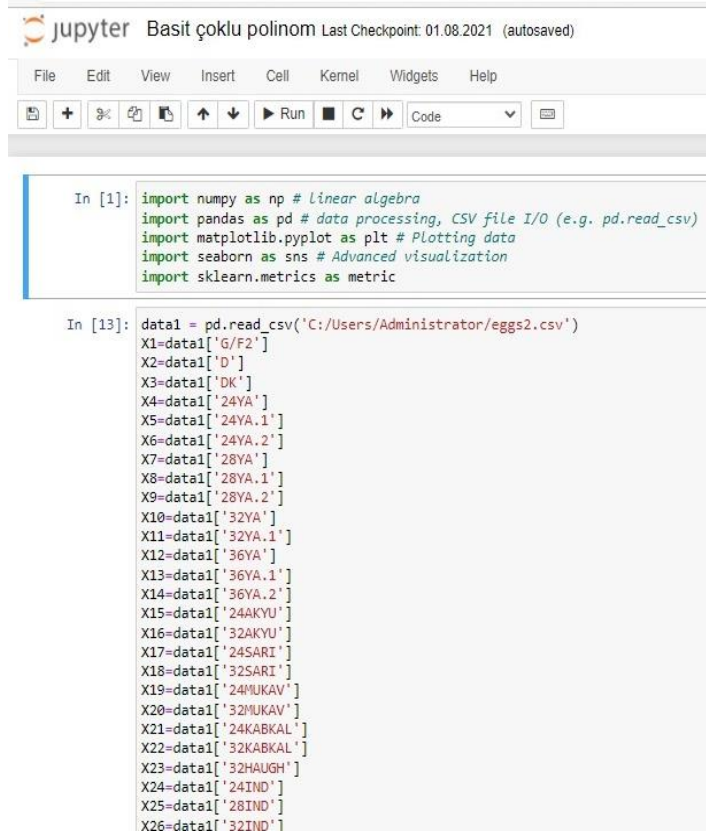
Türkiye’de 1990 yılında kişi başı tavuk tüketimi 3.83 kg iken, 2004 yılında 13.27 kg’a olarak gözlemlenmiştir. Gittikçe artan tüketimle birlikte üretim de artarak gelişmeye başlamıştır. 1991 yılında 7.7 milyar olan sektördeki üretim, 2018 yılında %150 artarak 19.6 milyara ulaşmıştır. Üretim artışı dalgalanma gösterirken, ihracat özellikle 2010 yılından sonra istikrarlı bir şekilde artarak üretimin %26’sına ulaşmıştır. Bu nedenle iç pazardaki gelişmelerle birlikte ticaret ortağı ülkelerin ekonomik ve siyasi durumlarının da önemi artmıştır. Üretim ve ihracatın artması, dünya ticaretinin önemini de artırmış ve dünya ihracatının payı %16’ya yükselmiştir. Tarımsal üretimde yaşanan sorunlardan önemli ölçüde etkilenen alanlardan biri yumurta sektörüdür. Bu sorunlardan biri hayvan ve insan sağlığını etkileyen kuş gribidir [24,32].

BÖLÜM 3

PYTHON VE MATLAB

3.1. PYTHON

Hollandalı bir programcı olan Guido Van Rossum, 90'lı yıllarda Python programlama dilini geliştirmiştir [33]. En üst düzey programlama dillerinden biri olan python; dinamik, hızlı, yorumlanmış ve nesne yönelimlidir. Basit ve kolay öğrenilebilir olmasından dolayı kullanımı yaygındır. Python ara yüzündeki Pytorch, Sklearn, SciKits, NumPy, Matplotlib, SciPy kütüphaneleri makine öğrenimi ve veri bilimi için uygundur. Python arayüzüne ait görsel Şekil 3.1'de gösterilmiştir. [33-36].



```
jupyter Basit çoklu polinom Last Checkpoint: 01.08.2021 (autosaved)
File Edit View Insert Cell Kernel Widgets Help
+ %< > Run ■ C >> Code v
In [1]: import numpy as np # Linear algebra
import pandas as pd # data processing, CSV file I/O (e.g. pd.read_csv)
import matplotlib.pyplot as plt # Plotting data
import seaborn as sns # Advanced visualization
import sklearn.metrics as metric

In [13]: data1 = pd.read_csv('C:/Users/Administrator/eggs2.csv')
X1=data1['G/F2']
X2=data1['D']
X3=data1['DK']
X4=data1['24YA']
X5=data1['24YA.1']
X6=data1['24YA.2']
X7=data1['28YA']
X8=data1['28YA.1']
X9=data1['28YA.2']
X10=data1['32YA']
X11=data1['32YA.1']
X12=data1['36YA']
X13=data1['36YA.1']
X14=data1['36YA.2']
X15=data1['24AKYU']
X16=data1['32AKYU']
X17=data1['24SART']
X18=data1['32SART']
X19=data1['24MUKAV']
X20=data1['32MUKAV']
X21=data1['24KABKAL']
X22=data1['32KABKAL']
X23=data1['32HAUGH']
X24=data1['24IND']
X25=data1['28IND']
X26=data1['32IND']
```

Şekil 3.1. Python arayüzüne ait görsel.

Python birtakım avantajlı özellikler ve dezavantajlar içermektedir. Avantajları:

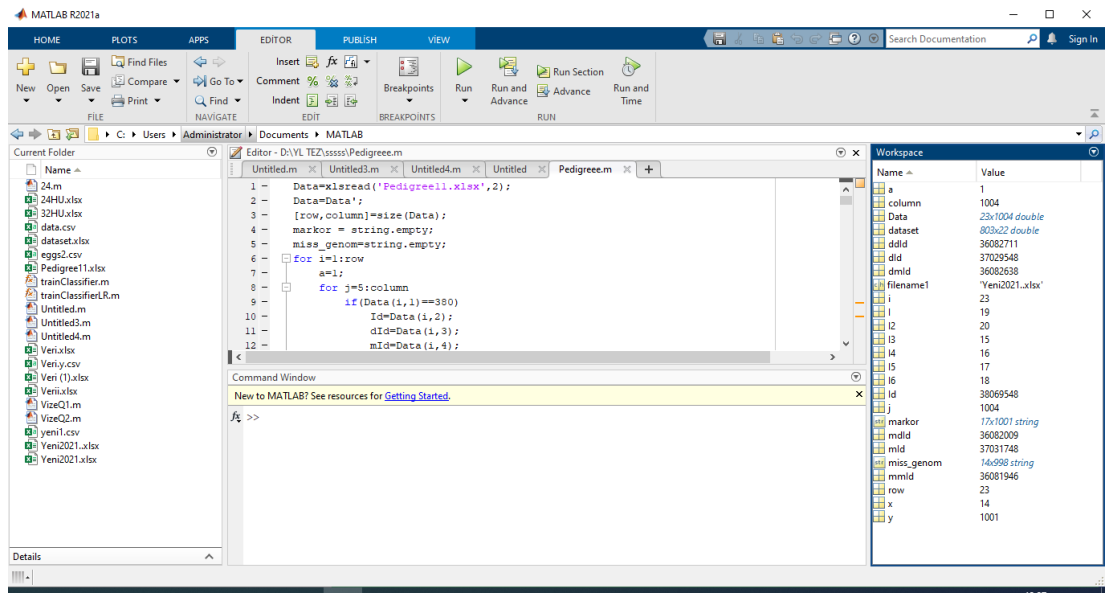
- ✓ Python birçok alanda ücretsiz kaynak erişimi bulundurmaktadır.
- ✓ Windows, Linux veya Mac gibi en çok tercih edilen tüm işletim sistemlerinde ve platformlarda mevcuttur.
- ✓ Kullanımı basit ve kolaydır.
- ✓ Dinamik olarak geliştirilmiş bir programlama dilidir. Bu nedenle, değişkenlerin veri tipinin bildirilmesi şart değildir.
- ✓ Python, prototipleri geliştirmekte kullanılabilir ve hızlıdır.
- ✓ Son derece okunabilir ve hata ayıklaması kolaydır.
- ✓ Kodları sözdizimsel olarak yazmak daha kolaydır.
- ✓ Python ile yazılmış programların kurulumu pek çok işletim sistemi ve platformda çok az değişiklikle veya hiç değişiklik yapılmadan yapılabilmektedir.
- ✓ Python kütüphaneleri geliştirmeler ve güncellemeler almaya devam etmektedir.
- ✓ Veri madenciliği ve makine öğrenmesi gibi alanlarda kullanımı yaygındır [37-39].

Dezavantajları:

- ✓ Python yorumlanan bir dil olduğu için yürütmede yavaştır.
- ✓ Python dinamik olarak yazıldığından, tasarımda kısıtlamaya yol açan çalışma süresi hatasını artırır.
- ✓ Python, mobil geliştirme için uygun değildir.
- ✓ Python'un Global Yorumlayıcı Kilidi (GIL), bir seferde yalnızca bir iş parçasının yürütülmesine izin verir [40].

3.2. MATLAB

Matlab programı, yüksek performanslı bir programlama dilidir. Matlab programı; kontrol, görüntü işleme, istatistik, yapay sinir ağları ve grafik gibi birçok yerde kullanılabilir araç kutuları bulundurmaktadır. Açılımı matris laboratuvarı olan matlab, boyutlandırma gerektirmeyen matrislerden oluşmaktadır. Yapılan tüm girdiler ve çıktılar, bir matris tanımlamaktadır. Kapsamlı ve geliştirilebilir özelliğe sahiptir [41,42]. Matlab programına ait bir görsel Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Matlab programına ait görsel.

Matlab birtakım avantajlı özellikler ve dezavantajlar içermektedir. Avantajları:

- ✓ Matlab modüler yapıdadır ve birçok pakete sahiptir.
- ✓ Matris denklemlerinde boyut sınırı bulunmamaktadır.
- ✓ Matlab kolay kodlama özelliğine sahiptir. Yeni programlar çok hızlı bir şekilde oluşturulabilmektedir.
- ✓ Matlab Winows, Linux ve Mac os işletim sistemlerini desteklemektedir. Bir işletim sisteminde yazılmış program dosyalarını diğer işletim sistemlerinde çalıştırabilmektedir. Bu durum kullanıcıya işletim sistemi güncelleme özgürlüğü sunmaktadır.

- ✓ Çoğu teknik soruna cevap veren yaygın bir fonksiyon kütüphanesiyle sunulmaktadır.
- ✓ Matlab derleyicisi, Matlab ile geliştirilen uygulamaları matlab programının bulunmadığı alanlarda da çalışabilmektedir.
- ✓ Matlab; liner cebir, istatistik, optimizasyon, nümerik analiz, optimizasyon gibi matematiksel hesaplamaları uygularken hızlıdır.
- ✓ Matlab; 2 boyutlu ve 3 boyutlu grafik çizimi, modelleme ve simülasyon yapabilmeye olanak sağlamaktadır [42-44].

Dezavantajları:

- ✓ Matlab programlama dili çok geç sürede açılmaktadır.
- ✓ Matlab ücretli bir programdır [42].

BÖLÜM 4

LİTERATÜR TARAMASI

Günümüzde tavuk üretimi ve tüketimi önemli bir sektör haline gelmiştir. Tavukçulukla birlikte, protein miktarı olarak önemli bir besin maddesi olan tavuk yumurtası öne çıkmaktadır. Türkiye’de yumurta sektörü zamanla artarak dünyada yumurta ihracatında önemli bir noktaya gelmiştir [45]. Bu alandaki çalışmaların sayısı önemli bir artış göstermiştir. Fakat literatürde, saf hat yumurtacı tavuklarda verim özelliklerine yönelik az sayıda çalışma vardır.

Bu tez çalışmasında, ilk olarak tavuklardan alınan verilere göre veri analizi yapılarak, verim özellikleri belirlenmiştir. Daha sonra alınan verilerin pedigrı takibi yapılmış ve makine öğrenmesi modelleri kullanılarak sınıflandırma işlemleri tamamlanmıştır. Bu konular ile ilgili literatürde bulunan bazı çalışmalar aşağıdaki gibi özetlenmiştir.

TAE’de, Göger tarafından yapılan bir projede saf hatlarda üzerinde durulan verim özelliklerine ait kalıtım derecelerinin bilinmesi ve bu özelliklerin seleksiyonla geliştirilmesi amaçlanmıştır. Bu çalışmada 11 saf hat kullanılmıştır. Bunların 5 tanesi beyaz ve 6 tanesi kahverengidir. Bu saf hatların anne ve baba hattı olmalarına önem verilmiştir. Çalışmada yumurtadan elde edilen verim özelliklerinin varyans-kovaryans çeşitleri, multiple-trait derivative-free restricted maximum likelihood (MTDFREML) bilgisayar programı kullanılarak animal model göz önünde tutularak restricted maximum likelihood (REML) modeli ile belirlenmeye çalışılmıştır. Yumurta verimine ilişkin kalıtım derecesi 0.05-0.27 aralığında tahmin edilmiştir. Bu çalışma ile elde edilen sonuçlarda tavukların olması gereken yaştan daha önce cinsel eğilime yönelmesi durumuna getirilmesi, tavuğun ürettiği yumurta sayısında artış gözlemlenmiştir. Erken cinsel olgunluk yaşına gelen tavukların küçük yumurta vermediği, büyüme çağındaki tavuklara yemleme ve aydınlatma uygulanmasının cinsel eğilimi etkilediği ve cinsel eğilim olması gereken dönemden daha geç olması

piliç büyütme masraflarında artış ve kuluçkalık yumurta sayısında azalış gösterdiği saptanmıştır [46].

Eren ve Gün, kurulması düşünülen bir tavuk çiftliğinde, yetiştirilmesi en uygun olan ırkın belirlenmesi amacıyla bir alan çalışması yapmışlardır. Çalışmada, veri kaynağı olarak internet sitelerindeki bilgileri kullanarak, leghorn ırkına sahip bireylerin yumurta analizlerini incelemişlerdir. Bu analizde, yumurta verimliliği ile ilgili parametreleri; yumurta sıklığı, canlı tavuk ağırlığı ve yumurta ağırlığı olarak belirlenmişlerdir. En verimli yumurtaya ait yumurta sıklığı, tavuk ağırlığı ve yumurta ağırlığı parametre değerleri sırasıyla 0.392211, 0.224623 ve 0,383166 olarak gözlemlenmiştir. Çalışma sonucunda Leghorn ırkının yumurta sıklığı ve yumurta ağırlığının diğer alternatif ırklara göre daha yüksek olduğu gözlemlenmiştir [47].

Cruz-Tirado vd. yaptıkları çalışmada, yumurta tazeliğinin çevrimiçi tahmini için en küçük ve en ucuz near infrared (NIR) spektrometrelerinden birinin performansını araştırmışlardır. NIR spektroskopisi, yumurtaların tazeliğinin tahmini için kullanılmıştır. Çalışmalarında toplam 660 tane yumurta kullanmışlardır. Yumurtalarla ilgili spektral veriler farklı ön işlem kombinasyonları kullanılarak işlenmiştir. Bu yumurtalardan HU değerine göre oluşturdukları verisetini %70 eğitim seti ve %30 test seti olarak ayırmışlardır. Taze ve bayat yumurtaların sınıflandırılması için partial least square discriminant analysis (PLS-DA) yöntemi ve support vector machine classification (SVM-C) yöntemi kullanılmıştır. PLS-DA yöntemi daha iyi sonuçlar vermiş ve %87.0 doğruluk oranı elde ettiklerini belirtmişlerdir [48].

Zhang vd. yaptıkları çalışmada, yumurta iç kalitesini değerlendirmek için hiperspektral görüntüleme kullanmışlardır. Bu hiperspektral görüntüleme sistemini geliştirmek ve HU değerinin belirlenmesini kalibre etmek için NIR spektroskopisinin dalga boyunu optimize etmişlerdir. Hiperspektral görüntü özellikleri çıkarılmıştır. Yumurtanın iç kabarcıklarını belirlemek için çıkarılan özellikler uygulanmıştır. Saçılmış yumurta sarısı tespitinde, yumurta sarısı ile ilgili özellikleri çıkarmak için bir görüntü segmenti algoritması oluşturulmuştur. Çalışmalarında 645 adet yumurta kullanmış ve 3 sete ayırmışlardır. Bu setlerdeki yumurtalar, günler boyunca

depolanmıştır. Her üç sette de yumurtaların %60'ı kalibrasyon ve %40'ı modelin tahmini için kullanılmıştır. Bir spektral aralık kullanarak yumurta tazeliğinin sınıflandırılması için SPA-SVC yöntemi kullanılmıştır. Bu sınıflandırma işlemi sonucunda, SPA-SVC yöntemi ile %84.0 doğruluk başarısı elde edilmiştir [49].

Zhao vd. yaptıkları çalışmada, örüntü tanıma ile birlikte NIR spektroskopisi kullanarak yumurtaların tazeliğini sınıflandırmışlardır. Çalışmalarında toplam 101 tane yumurta kullanmışlardır. Bu yumurtalar tazelik durumlarına göre derecelendirilmemiş ve 5 gün depolanmıştır. Depolamanın sonunda, tüm yumurtaların NIR spektrumları toplanmıştır. Bu çalışmada, taze ve taze olmayan yumurtaları sınıflandırmak için partial least square discrimination analysis (PLS-DA), k en yakın komşu (K-NN), yapay sinir ağları (YSA), destek vektör makineleri (DVM) ve support vector data description (SVDD) yöntemi kullanılmıştır. Bu sınıflandırma işlemi için kullanılan bu yöntemler karşılaştırıldığında, SVM'nin taze olmayan yumurtaları ayırt etmede en düşük performansa sahip olduğu görülmüştür. SVDD yöntemi daha iyi sonuçlar vermiş ve %93.3 doğruluk oranı elde edilmiştir [50].

Avşar ve Akpınar çalışmalarında, sarı tüylü renkli japon bıldırcınların belirli sürelerle depolanan kuluçkalık yumurtaların iç ve dış kalite özelliklerini araştırmışlardır. Çalışmada her bir katta yirmi hayvan ve beş katlı kafes sisteminde yer alan 100 adet sarı tüylü renkli japon bıldırcınları bulunmaktadır. Yaş ve depolama süresinin, yumurta dış ve iç kalite özellikleri üzerindeki etkisini saptamak için 8. hafta ve 32. hafta aralığında 7 ayrı yaş dönemlerinde olan yumurtalar, 0, 7 ve 14 gün süre ile depolanmıştır. Yumurtaların bireysel tartımı yapıldıktan sonra boy ve en kesitine ait ölçümlerini kaydetmişlerdir. Tüm yaş gruplarında yumurtaların ağırlığı, yumurtaların başlangıç ağırlığı ve yumurtaların depolama sonundaki ağırlıkları kaydedilerek dış kalite özellikleri her yaş için ayrı ayrı belirlemişlerdir. İç kalite özellikleri ak indeksi, sarı indeksi, HU, sarı ve ak yüzdesi, kabuk oranı ve kabuk kalınlığı, kabuk ağırlığı ve gözenek sayısı olarak tespit etmişlerdir. Bu çalışmaya göre, HU etkili bir parametre olarak saptanmıştır. HU yumurta depolama süresi ve hayvan yaşından etkilendiğini belirlemişlerdir [51].

Cebeci ve Yıldız yaptıkları çalışmada, tavuk yumurtasının kalite özelliklerini ayırtlamak için equal width intervals (EWI), equal frequency intervals (EFI) ve K-means clustering (KMC) yöntemlerini performans bakımından deneysel olarak analiz ederek araştırmışlardır. Bu analiz işlemi için 14 sürekli özelliğin bulunduğu bir veri seti kullanmışlardır. Bu yöntemlerin sınıflama ağacı modellerinin öğrenme hatalarını azalttığını ve doğruluğu artırdığını belirlemişlerdir. C5.0 sınıflama modelinin kullanıldığı çalışmalara göre EWI, EFI ve KMC modellerinin benzer sonuçlar verdiklerini gözlemlemişlerdir. Aralık sayısını tahmin etmekte en iyi sonucu EWI'in verdiği, EFI'in vermediğini belirlemişlerdir. Ayırtlama işlemi için EWI kullanılarak en yüksek doğruluk %54.43, EFI kullanarak en yüksek doğruluk %53.20 ve KMC kullanarak %52.54 değeri elde edilmiştir [52].

Akkuş, iki farklı yumurtacı tavuk türünde, yaş ve kafes katının yumurta kalitesi üzerindeki etkilerini araştırmıştır. Bu iki tür beyaz renkli (Nick-Chick) ve kahverenkli (Nick-Brown) yumurtacı tavuklardır. Bu araştırmada temel amaç yumurta tavukçuluğu yaparken yumurtalardan beklenen kalitenin artmasının yanı sıra artan kaliteli yumurtanın da tüketicilere ulaşmasını sağlayacak bir pazar ortamının oluşturulmasıdır. Kahverengi ve beyaz olmak üzere iki çeşit yumurta için hem iç hem dış kalite değişimlerinin gözlenmesi, gözlem sonucuna göre başarılı değişimlerin daha çok geliştirilip başarısız değişimlerin azaltılabilmesi amacıyla yetiştiricilikte üretim yöntemlerinde uygulanması gereken metotları belirlemiştir. Akkuş yaptığı çalışmaya göre kahverengi yumurtaların beyaz yumurtalardan kütle olarak daha ağır ve özgül ağırlık olarak daha yüksek olduğu sonucuna ulaşmıştır. Çalışmaya göre beyaz olan yumurtaların sarı ve beyaz kısımlarında et parçası ve kan izinin daha düşük olduğunu gözlemlemiştir. Tavuklarda yaşın ilerlemesiyle birlikte yumurta kabuklarının kalınlıklarının, ak kısmın boyutunun, et parçası ve kan izi lekelerinin değerlerinde düşüş olduğunu saptamıştır [53].

BÖLÜM 5

MATERYAL

Bu tez çalışması sırasında kullanılan malzemeler bu bölümde tanıtılmaktadır. Tez çalışması boyunca saf hatlardan daha üstün özelliklerde yeni anne ve baba hatlarının oluşturulması için yumurtacı genotiplerle çalışmalar gerçekleştirilmiştir. TAE’de, RIR ve BAR cinslerindeki bireyler ve bu bireylerin 2017 yılındaki 43 haftalık dönemi kapsayan yumurta verim özelliklerine ait bilgiler kaydedilmiştir. Bu bireylerden elde edilen 803 adet yumurta bu çalışmada kullanılmıştır. Kullanılan 803 yumurtaların 542 adedi mükemmel ve 261 adedi çok iyi sınıfına aittir. Bireylere ait verilerin kolay bulunması için her bir birey etiketlenmiştir. Çalışmaya ait bireylerin parametreleri Çizelge 5.1’de listelenmiştir.

Çizelge 5.1. Çalışmaya ait bireylerin parametreleri.

Bireylerin Parametreleri
Etiket
Cinsiyet
Genotip
Renk
Aile
Tarih
Civciv Ağırlığı
Yumurta Ağırlığı
Yumurta Sıklığı
Yumurta Kabuk Ağırlığı

Bireylerin yumurtalarına ait kalite özellikleri yumurta ağırlığı, yumurta akı yüksekliği, yumurta sarısı ağırlığı, yumurta mukavemeti, kabuk kalınlığı ve indeks değerleridir. Bu kalite özellikleri, bu çalışmanın verisetinin parametrelerini oluşturmaktadır. Verisetinin parametreleri hafta değerlerine göre değişkenlik

göstermektedir. Bu çalışma veriseti, eğitim seti ve test seti olarak sırasıyla %80 ve %20 olarak ayrılmıştır. Çalışmada kullanılan verisetinin sahip olduğu yumurta kalitesi özellikleri Çizelge 5.2’de listelenmiştir.

Çizelge 5.2. Çalışmaya ait yumurta kalitesi özellikleri.

Yumurta kalitesi özellikleri
24. hafta 1. ölçüm yumurta ağırlık değerleri
24. hafta 2. ölçüm yumurta ağırlık değerleri
24. hafta 3. ölçüm yumurta ağırlık değerleri
24. hafta yumurta akı yükseklik değerleri
24.hafta yumurta sarısı ağırlık değerleri
24. hafta yumurta mukavemet değerleri
24. hafta kabuk kalınlığı değerleri
28.hafta indeks değerleri
28. hafta 1. ölçüm yumurta ağırlık değerleri
28. hafta 2. ölçüm yumurta ağırlık değerleri
32. hafta indeks değerleri
32. hafta 1. ölçüm yumurta ağırlık değerleri
32. hafta 2. ölçüm yumurta ağırlık değerleri
32. hafta yumurta akı yükseklik değerleri
32.hafta yumurta sarısı ağırlık değerleri
32. hafta yumurta mukavemet değerleri
32. hafta kabuk kalınlığı değerleri
36. hafta indeks değerleri
36. hafta 1. ölçüm yumurta ağırlığı
36. hafta 2. ölçüm yumurta ağırlığı

Çizelge 5.2’deki tüm bu parametrelerden yola çıkılarak ilk veriseti için 21. parametresi, mükemmel (0) ve çok iyi (1) olarak yumurta kalitesidir. İkinci verisetinin 21. parametresi, 24. hafta az bilgi (0), orta bilgi (1) ve çok bilgi (2) veren olarak HU değeridir. Üçüncü verisetinin 21. parametresi, 32. hafta az bilgi (0), orta bilgi (1) ve çok bilgi (2) veren olarak HU değeridir. Bunun sonucunda bu çalışmada

kullanılan ve analizi yapılan üç ayrı verisetlerinin boyutları eşittir ve 803x21'dir. Verisetlerinde bulunan parametreler Çizelge 5.3'te sunulmuştur.

Çizelge 5.3. Verisetlerinde bulunan parametreler.

#	Parametre Adı	Veriseti 1	Veriseti 2	Veriseti 3
1	24. hafta 1. ölçüm yumurta ağırlık değerleri	✓	✓	✓
2	24. hafta 2. ölçüm yumurta ağırlık değerleri	✓	✓	✓
3	24. hafta 3. ölçüm yumurta ağırlık değerleri	✓	✓	✓
4	24. hafta yumurta akı yükseklik değerleri	✓	✓	✓
5	24.hafta yumurta sarısı ağırlık değerleri	✓	✓	✓
6	24. hafta yumurta mukavemet değerleri	✓	✓	✓
7	24. hafta kabuk kalınlığı değerleri	✓	✓	✓
8	28.hafta indeks değerleri	✓	✓	✓
9	28. hafta 1. ölçüm yumurta ağırlık değerleri	✓	✓	✓
10	28. hafta 2. ölçüm yumurta ağırlık değerleri	✓	✓	✓
11	32. hafta indeks değerleri	✓	✓	✓
12	32. hafta 1. ölçüm yumurta ağırlık değerleri	✓	✓	✓
13	32. hafta 2. ölçüm yumurta ağırlık değerleri	✓	✓	✓
14	32. hafta yumurta akı yükseklik değerleri	✓	✓	✓
15	32.hafta yumurta sarısı ağırlık değerleri	✓	✓	✓
16	32. hafta yumurta mukavemet değerleri	✓	✓	✓
17	32. hafta kabuk kalınlığı değerleri	✓	✓	✓
18	36. hafta indeks değerleri	✓	✓	✓
19	36. hafta 1. ölçüm yumurta ağırlığı	✓	✓	✓
20	36. hafta 2. ölçüm yumurta ağırlığı	✓	✓	✓
21	Yumurta kalitesi	✓	X	X
22	24. haftada HU değerleri	X	✓	X
23	32. haftada HU değerleri	X	X	✓

Kırık yumurta, çizik yumurta vb. kalitedeki sınıfı oluşturan yumurtalar, Çizelge 5.2'de gösterilen tüm yumurta kalitesi özelliklerini sağlamadıkları için verisetine dahil edilmemiştir. Bir başka deyişle, süpermarketlerde satılabilecek yumurtalar bu çalışmada tercih edilmiştir. Bu yumurtalardan mükemmel sınıf ve çok iyi sınıf TAE

tarafından yumurta kalitesi açısından değerlendirilmiş ve sınıflandırılmıştır. Yumurta kalitesinin, 24. hafta HU değerinin ve 32. hafta HU değerinin sınıflandırması için makine öğrenmesi modelleri kullanılarak tam otomatik olarak sınıflandırma işlemleri gerçekleştirilmiştir.

Yumurta kalitesinin belirlenmesinde iç ve dış kaliteyle ilgili bazı kriterler göz önünde bulundurulmaktadır. Örneğin, yemeklik yumurtalar kırıldığı zaman koyu akın daha çok alana dağılması bayatlık olarak düşünülmektedir. Tazelik, yumurta ve yumurta ürünlerinin kalitesine büyük katkı sağlamaktadır. Tüketiciler, tazelikteki değişkenliği kalite eksikliği olarak algılayabilmektedir. Tazelik, bazı (biyo)-kimyasal, mikrobiyal ve fiziksel parametrelerle açıklanabilir ve bundan dolayı nesnel bir nitelik olarak düşünülebilir. Yumurta tazeliği, yumurtanın bazı ölçümleri sonucunda elde edilen özellikler kullanılarak belirlenebilmektedir. Depolama sırasında yumurtaların kalitesini tanımlayan en önemli parametreler; ak yüksekliği, HU, yumurta sarısı indeksi ve hava odası boyutudur. HU, tavuk yumurtalarının tazeliğini tahmin etmek için kullanılan ve Brezilya yumurta sanitasyonu yönetmeliği tarafından tanınan referans parametredir [54]. HU, esas olarak nem kaybına bağlı olarak depolama süresi ile azalan yumurta akının yüksekliği ve yumurtanın ağırlığı kullanılarak hesaplanmaktadır ve Eşitlik 5.1'deki gibi gösterilmiştir. [54-57].

$$HU = 100 \log (H + 7.57 - 1.7G^{0.37}) \quad (5.1)$$

Eşitlik 5.1'de yer alan H değeri mm cinsinden yumurtanın ak yüksekliğini ve G değeri g cinsinden yumurtanın ağırlığını ifade etmektedir.

Bu çalışmada kullanılan verilerin saklanması ve yönetilmesi için Microsoft SQL Server kullanılmıştır. Verilerin saklanması ve sınıflandırma işlemleri için kullanılan bilgisayarın özellikleri Çizelge 5.4'te gösterilmiştir.

Çizelge 5.4. Bilgisayar özellikleri.

Bilgisayar	Özellik
Merkezi işlem birimi	Core i5 2.30 Gigahertz (GHz)
Rastgele erişimli bellek	4,00 Gigabayt (GB)
Sabit disk	256 GB
Ön bellek	2 Megabayt (MB)
Ekran kartı	2 MB
Ekran boyutu	22 inç
İşletim sistemi	Windows 10 (64-bit)

TAE’de, RIR ve BAR cinslerindeki bireyler ve bu bireylerin 2017 yılındaki 43 haftalık dönemi kapsayan F0 bireyelerine ait cinsel olgunluk yaşı (COY), cinsel olgunluk ağırlığına (COA), yumurta sayısı, yumurta ağırlığı ve genetik yönelim değerleri kaydedilmiştir. Bu değerler Çizelge 5.5-5.7’de gösterilmiştir. Bu iki genotipin ortalama yumurta ağırlığı arasında 8.36 g fark olduğu görülmektedir.

Çizelge 5.5. F0’larda COY ve COA değerleri.

Hat	Adet	COY (Gün)			COA (g)		
		En Küçük	En Büyük	X±Sx	En Küçük	En Büyük	X±Sx
BAR	595	128	157	143.97±0.307	1240	1720	1525.23±7.356
RIR	525	135	184	150.91±0.620	1880	1880	1499.38±6.829

Çizelge 5.6. F0’larda yumurta sayısı ve yumurta ağırlığı değerleri.

Hat	Adet	Yumurta Sayısı (Adet)			Yumurta Ağırlığı (g)		
		En Küçük	En Büyük	X±Sx	En Küçük	En Büyük	X±Sx
BAR	595	93	173	152.01±0.805	44	59	50.97±0.209
RIR	525	62	173	140.42±1.162	51	70	59.33±0.236

Çizelge 5.7. F0’larda genetik yönelim

Hat	Adet	COY	COA	YS	YA
BAR	595	-1.13	-29.35	30.95	2.94
RIR	525	-1.03	-21.43	2.84	1.72

F1 tavuk ve horozlardan F2 tavukların üretilmesi çalışmalarına, 15 Nisan 2019 tarihinde horoz ve tavuklardan aileler oluşturularak başlanmıştır. Projenin F0

düzeyini; RIR ve BAR hatlarından 6'şar adet tavuk ve horoz oluşturmuştur. F1 genotiplerinin civciv ağırlığı (g) Çizelge 5.8'de verilmiştir.

Çizelge 5.8. F1 genotiplerinin civciv ağırlığı

#	Adet	Ortalama ± standart hata	Grup	P
BAR*RIR	231	39.598 ± 2.240	A	0.001
RIR*BAR	187	32.158 ± 2.034	B	

Çizelge 5.8 incelendiğinde; BAR*RIR genotipinde civciv ağırlığının RIR*BAR genotipine göre daha ağır olduğu görülmektedir. Bu durumun nedeni RIR genotipinde yumurta ağırlığının daha fazla olmasıdır. F1 Cinsel olgunluk ağırlığına (g) ait ortalama değerler ise Çizelge 5.9'da verilmiştir.

Çizelge 5.9. F1 genotiplerinde cinsel olgunluk ağırlığı

#	Adet	Ortalama ± standart hata	Grup	P
BAR*RIR	231	1687.0 ± 96.7	A	0.001
RIR*BAR	187	1535.7 ± 104.8	B	

Çizelge 5.9'da BAR*RIR genotipinde cinsel olgunluk ağırlığının RIR*BAR genotipine göre daha ağır olduğu gözlemlenmiştir.

BÖLÜM 6

METOT

Bu bölümde; verilerin uygulanma aşamaları, pedigrî takibi ve sınıflandırma algoritmaları anlatılmıştır. Hayvancılıkta verilerin saklanması oldukça önem arz etmektedir. Saklanan veriler, verimin yükseltilmesi ve nitelikli damızlık ihtiyacının giderilmesi gibi birçok fayda sağlamaktadır [58]. Sağlıklı verilerin alınması ve alınan verilerin depolanması için SQL veritabanı yazılımı kullanılmıştır. Bu depolanan verilere kolaylıkla ulaşılabilen ve istenildiği zaman kullanılabilir duruma getirilmektedir. Veriler, rahatlıkla kategorize edilebilmektedir. Verilerin toplanması ve analizi için uygulanan adımlar Çizelge 6.1’de gösterilmiştir.

Çizelge 6.1. Algoritma akış sırası.

Algoritma akış sırası	
1	Verilerin TAE’den alınması
2	Veri seçimi
3	Ön işleme
4	Veri analizi
5	Sonuçların kıyaslanması
6	Sonuçların doğrulanması
7	Sonuçların bir sonraki kurama iletilmesi


Bu çalışmada RIR ve BAR ırklarındaki bireylerin verimlilik özellikleri pedigrî takibi ile değerlendirilmiştir. Pedigrî takibi yöntemine göre bilgisi tam olan bireyler araştırmaya dahil edilirken, bilgisi eksik olan veya hiç bilgisi olmayan bireyler çalışmaya dahil edilmemiştir. Pedigrî takibi yöntemine göre seçilen bireylerden elde edilen yumurtaların özellikleri TAE tarafından veritabanında tutulmuştur. Bu nedenle boyutları 803x21 olan üç ayrı veriseti oluşturulmuştur. Verisetleri, k katmanlı çapraz doğrulamaya (k-fold cross validation) dayalı olarak eğitim seti ve test seti olarak sırasıyla %80 ve %20 oranında iki sete ayrılmıştır. K, 5 olarak seçilmiştir. Bir başka deyişle, 5 kat çapraz doğrulama altında mükemmel kalitedeki 542 yumurtadan 433’ü

rastgele seçilerek eğitim setine eklenmiştir. Mükemmel kalitedeki 542 yumurtadan 109'u test setine eklenmiştir. 5 kat çapraz doğrulama altında iyi kalitedeki 261 yumurtadan 208'i rastgele seçilmiş ve eğitim setine eklenmiştir. İyi kalitedeki 261 yumurtadan 53'ü test setine eklenmiştir. Çapraz doğrulama tekniği kullanılarak eğitim setlerinde ve test setlerinde her seferinde farklı yumurtalar kullanılmaktadır. Böylece, çapraz doğrulama sayesinde makine öğrenmesi modellerinin veriler üzerindeki performansları olabildiğince objektif ve doğru bir şekilde değerlendirilmiştir.

6.1. PEDİGRİ TAKİBİ

Ebeveyn tayini, bir canlının alt, üst ve yansoylarından alınan bilgilerin kullanılmasıdır. Ebeveyn tayinlerinde, moleküler markörler kullanılmaktadır. Moleküler markörler ile yapılan ebeveyn tayinlerini, kan grupları ve diğer biyolojik markörler ile yapılan testlerden daha kesin sonuçlar içermektedir. Moleküler markörler, hayvanların ilerleyen zamanlarda verim performansını tahmin etmeyi sağlayarak hayvan ıslahına önemli katkılar sunmaktadır. Hayvanlarda verimin belirlendiği karakterler olan kantitatif karakterler, süreklilik gösteren birçok gen tarafından kontrol altına alınamayan karakterler içerisinde bulunmaktadır. Bunları kodlayan genler kromozomda yer alan kantitatif karakter lokusları (QTL)'dir. Dünyada geniş kapsamlı araştırılan QTL'lerin, hayvanların kayıt altına alınmaması zaman ve maliyet isteyen bir durum olmasından dolayı Türkiye'de çalışma alanı dardır [59,60].

Bu çalışmada, bireylerin verimlilik özellikleri pedigri takibi ile değerlendirilmiştir. Pedigri takibi, bir ailenin bütün üyelerinin tek bir tabloda soyağacı şeklinde düzenlenmesidir. Aile üyelerinin genetik pedigrileri; dede/nine, anne/baba ve torun olarak en az üç kuşağı kapsamaktadır. Pedigri takibi, moleküler analiz yapılacak bireyleri seçmek ve genetik hastalık takibi yapmak için önemlidir [61,62]. Pedigri takibi çizelgesi Şekil 6.1'de gösterilmiştir.

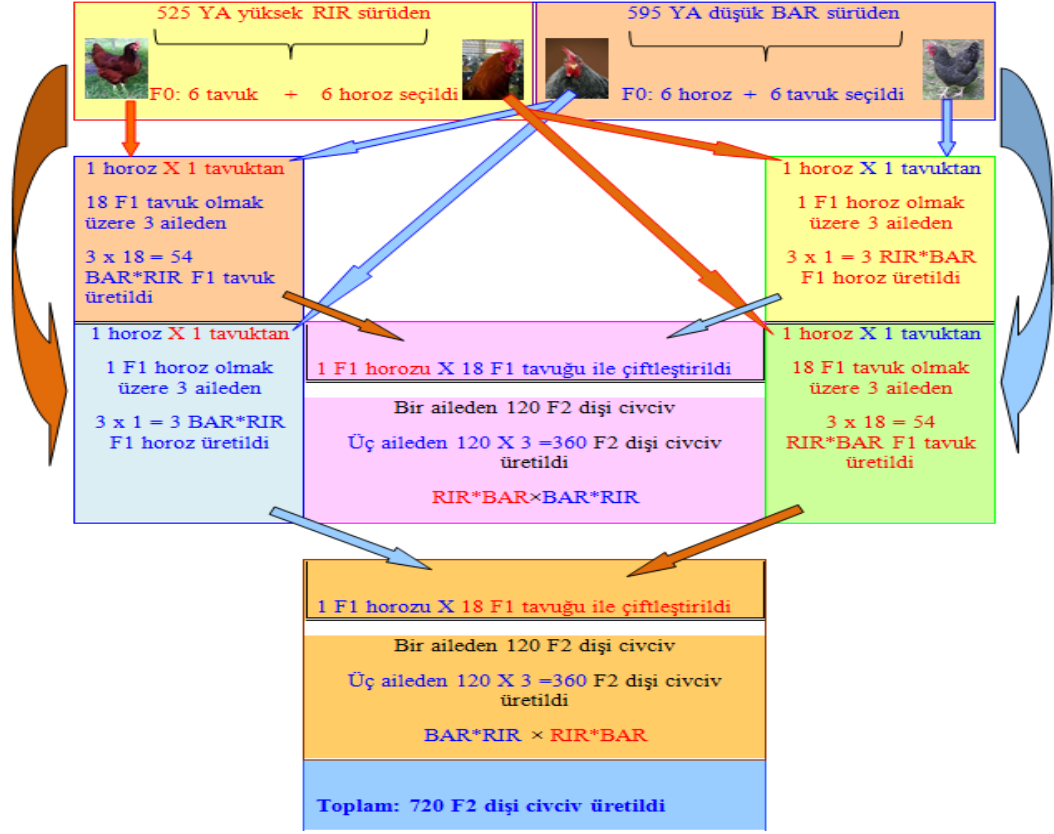


Şekil 6.1. Pedigri takibi görseli [61].

Pedigri sembolleri cinsiyet eşleştirmesi;


- □ (Kare) → Erkek
- ○ (Yuvarlak) → Kadın

Pedigri takibi, üreme melezlerini ve hayvan popülasyonlarını izlemek için kullanılmaktadır. Pedigri takibi, popülasyon yapısını ve genetik çeşitliliği görselleştirmektedir [63]. Bu çalışmada genetik çeşitliliği takip etmek ve ebeveynlik ataması için pedigri takibi yapılmıştır. Projede ele alınan aileler; Dede/Nine (F0), Baba/Anne (F1), Birey (F2) olarak oluşturulmuş ve uygulanan çiftleştirme şeması Şekil 6.2’de verilmiştir.




Şekil 6.2. Projede uygulanan çiftleştirme şeması

Bu çalışmada, saf hat olarak kabul edilen iki tavuk ırkı olan BAR ve RIR bireyleri seçilmiştir. Bu ırklar, özellikler bakımından farklılıklara sahiptir. RIR yüksek yumurta ağırlığı özelliğine sahipken, BAR yüksek yumurta verimi özelliğine sahiptir. BAR ve RIR ırkları bu özellikler düşünülerek seçilmiştir. Özellikleri determine eden genlerin farklı allelleri (Q1, Q2) Şekil 6.3'te gösterilmiştir. Bu allellerin homozigotlaşmış olmaları beklenmektedir. Benzer şekilde Single Nucleotide Polymorphism (SNP) genotipleri bakımından da farklı alleller (S1, S2) için homozigotlaşmış olmaları beklenmektedir. F1'lerin elde edildiği F0 bireyleri Şekil 6.3'te verilen genotipik yapıda olduğunda bu bireylere ait allelleri F1 (Şekil 6.4) ve F2 (Şekil 6.5) jenerasyonlarına geçerken takip etmek mümkün olmaktadır.



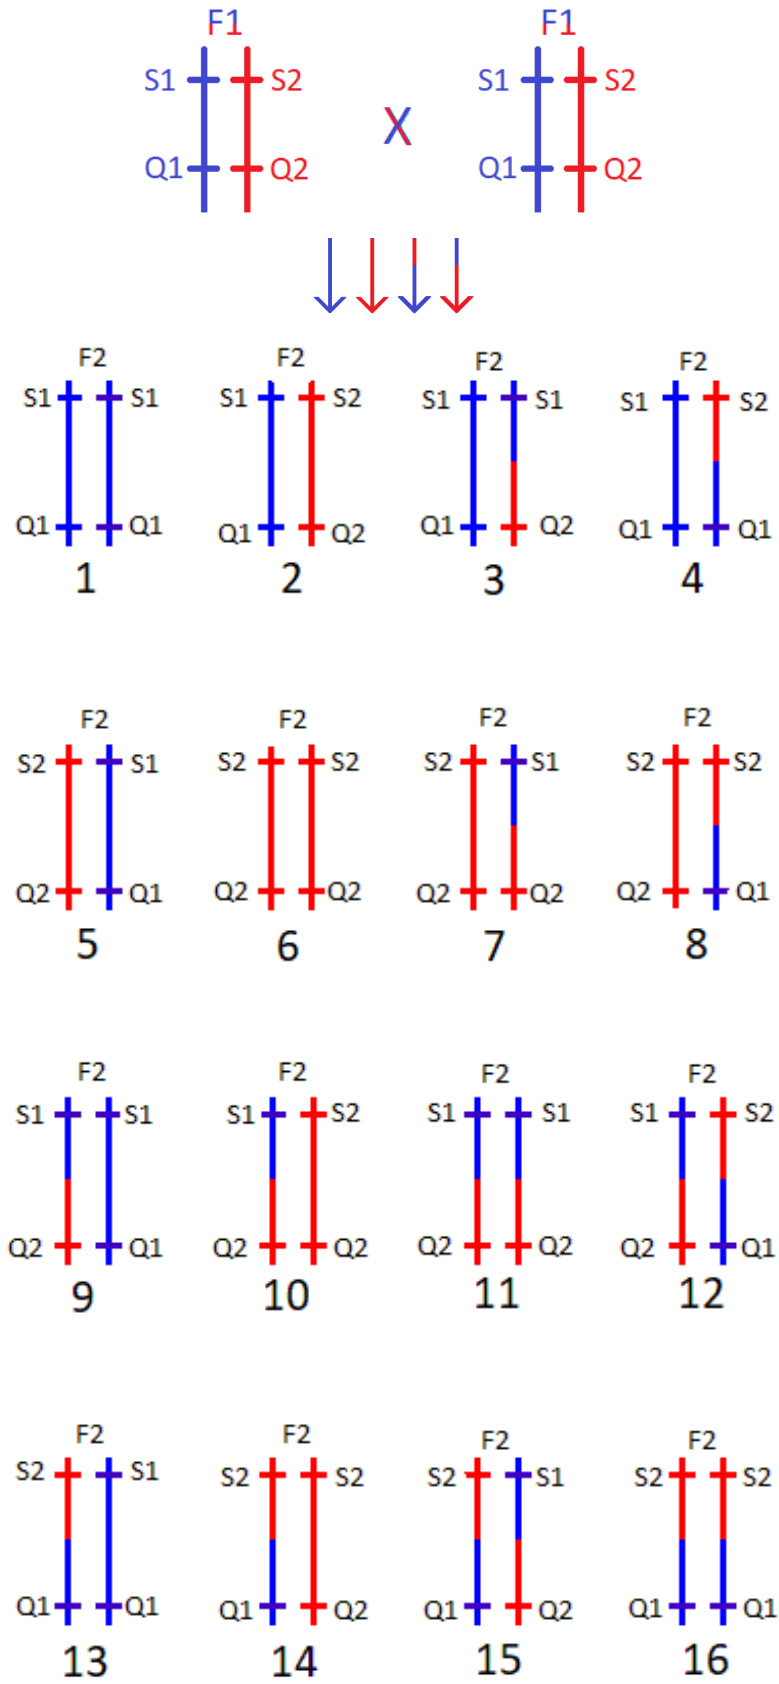
Şekil 6.3. Hat 1 (H1) ve Hat 2 (H2).

Şekil 6.3'te Hat 1 (H1) ve Hat 2 (H2)'nin herhangi bir SNP lokasyonunda varsayılan SNP allelleri (S1 ve S2) ve niceliksel özellik nükleotidi (QTN)/nicel özellik lokusları (QTL) allelleri (Q1 ve Q2) bakımından genotipleri: H1 ve H2 hatları SNP ve QTL/QTN için sırasıyla 1. ve 2. alleller için homozigot genotiplerdir.



Şekil 6.4. H1 ve H2 SNP ve QTL/QTN lokusları.

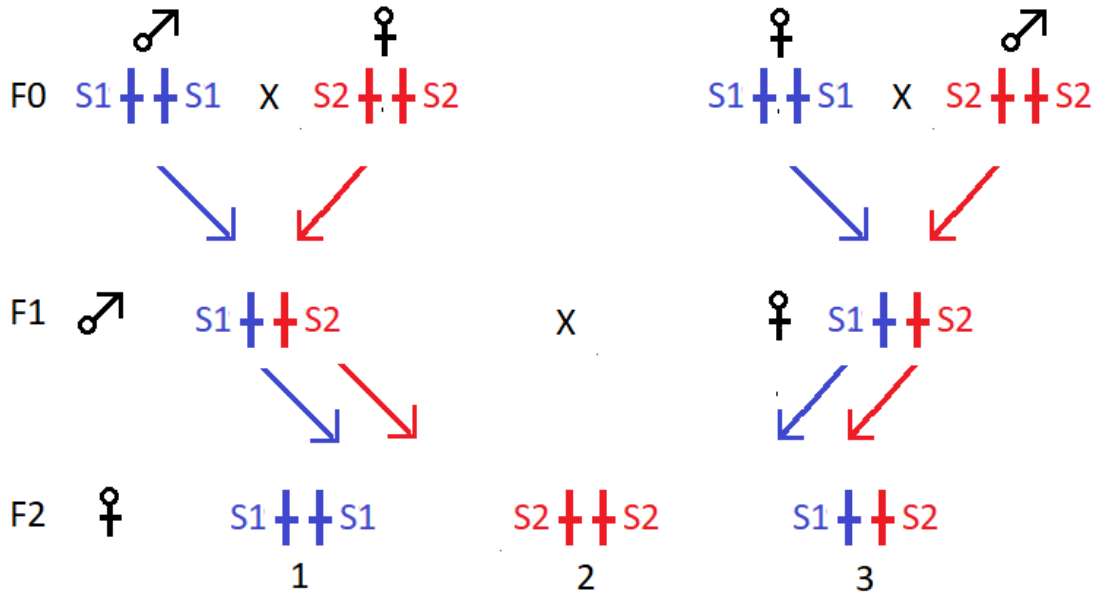
Şekil 6.4'te H1 ve H2, SNP ve QTL/QTN lokusları için homozigot genotipik yapıya sahip oldukları için tek tip gamet üretebileceklerdir. H1 ve H2 çiftleştirmelerinden elde edilen F1 jenerasyonu bireylerin heterozigot SNP ve QTL/QTN yapıya sahip olmalarını beklenmektedir.



Şekil 6.5. F1 X F1 çifletirmelerinden elde edilecek F2 jenerasyonu bireyler.

Şekil 6.5'te F2 jenerasyonu bireylerde görülebilecek SNP ve QTL/QTN genotipleri. 1, 2, 5, ve 6 nolu bireylerde crossing over (rekombinasyon, parça değişimi) yoktur. 3, 4, 7, 8, 9, 10, 13 ve 14 nolu bireylerin ebeveynlerinden sadece birisinde crossing over oluşmaktadır. 11, 12, 15, ve 16 nolu bireylerin her iki ebeveyninde de crossing over oluşmaktadır. Fakat, BAR ve RIR hatları, bütün SNP genotipleri için bu durumda olmayacaklardır. Bu çalışmada istenilen özellikleri determine eden genlerin SNP'lere çok yakın bir yerde, dolayısıyla QTL/QTN – SNP arasında mayoz bölünme aşamasında crossing over olamayacağı varsayımı ile hareket edilmektedir. Bu durumda, bazı SNP'ler bizim için bilgi verir nitelikte, bazıları kısmen bilgi verir nitelikte, bazıları ise bilgi vermez nitelikte olmaktadır.

SNP'lerin bilgi içerik durumları, F2'lerden başlayarak F1'i de kullanıp F0'a kadar allel takip edildiğinde, takip edilen allelin hangi ebeveyninden geldiğini tespit edilebilmeye bağlıdır. Bir bireydeki allelin hangi ebeveyninden geldiği takip ediliyorsa bilgi içerdiğini, takip edilmiyorsa bilgi içermediğini gösterir. Bu takip işlemini açıklayan bir görsel Şekil 6.6'da sunulmuştur.




Şekil 6.6. F2 tavuklarının SNP genotip allellerinin ebeveynlerinin takipi.

Şekil 6.6'da bütün F2 tavuklarının SNP genotip allellerinin hangi ebeveynlerden geldiği takip edilebilmektedir. 1 Nolu tavuk: Her iki allel H1'den geliyor, 2 nolu

tavuk: Her iki allel H2'den geliyor, 3 nolu tavuk: allellerden birisi H1'den diğeri H2'den gelmektedir. Muhtemel F2 bireyler genotipik olarak polimorfizm gösterdiklerinden dolayı, bu bireyler ile genotip – fenotip ilişkilendirmesi (QTL/QTN analizi) mümkün olacaktır.

F2 tavuğunun SNP genotip allelinin hangi ebeveynlerden geldiği takip edilemediği durum oluşmaktadır. Bu işlemi açıklayan bir görsel Şekil 6.7'de sunulmuştur.

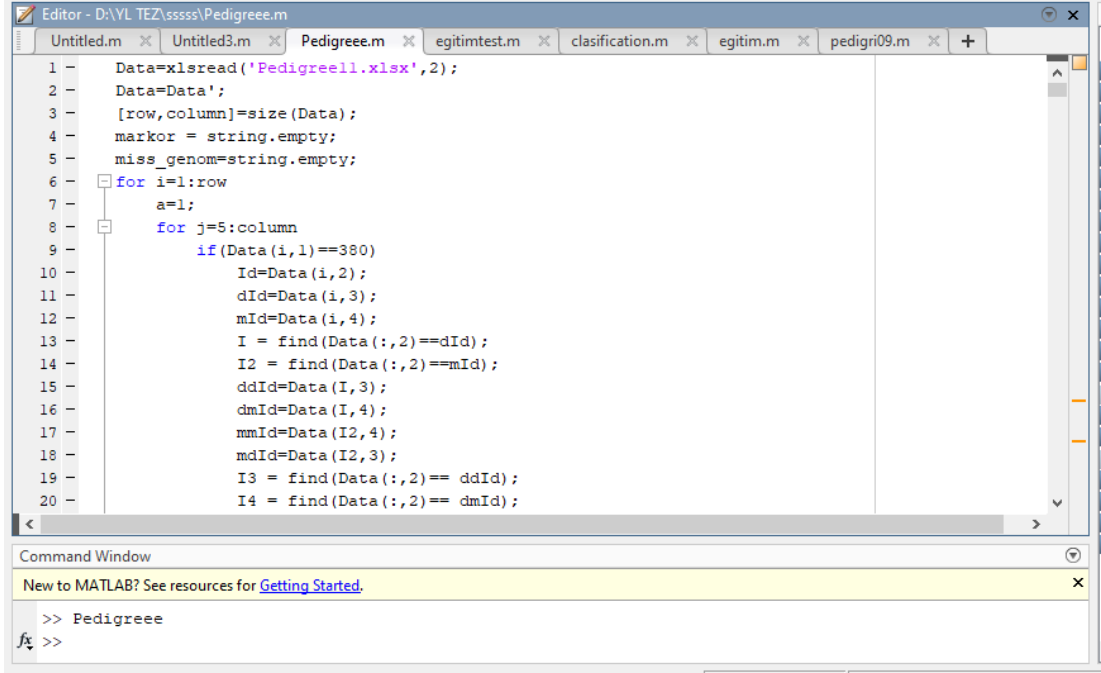


Şekil 6.7. F2 tavuklarının fenotip ilişkilendirmesi.

Şekil 6.7'de 1, 2, ve 3 nolu tavukların allel kaynakları 11, 12 ve 22 olabilir. Muhtemel F2 bireyler, genotipik olarak polimorfizm göstermelerine rağmen taşıdıkları allellerin hangi ebeveynlerden geldiğini takip etmek mümkün olmadığı için, bu bireyler ile genotip – fenotip ilişkilendirmesi mümkün olmayacaktır. F2 tavuklarda, 1 ve 2 nolu tavuk tam bilgi vermekteyken 3 nolu tavuk bilgi vermemektedir.

Polimorfik genotipik yapıya sahip olup tam bilgi içeren, hiç bilgi içermeyen ve monomorfik genotipik yapıya sahip olup bilgi içermeyen kombinasyonların anlatımını kolaylaştırmak amacıyla Şekil 6.2-6.7'de ile açıklanmıştır. Kombinasyon sayısı çok fazladır. Bu kombinasyonların bir kısmından tam, bir kısmından yarım

bilgi elde edilmektedir. Bir kısmından ise hiç bilgi elde edilememektedir. Tüm bu olasılıklar ve işlemler uygulanarak bu çalışma kapsamında bir pedigrî takibi programı geliştirmiştir. Bu programa ait görsel Şekil 6.8’de gösterilmiştir.



```
1 - Data=xlsread('Pedigreee1.xlsx',2);
2 - Data=Data';
3 - [row,column]=size(Data);
4 - markor = string.empty;
5 - miss_genom=string.empty;
6 - for i=1:row
7 -     a=1;
8 -     for j=5:column
9 -         if(Data(i,1)==380)
10 -             Id=Data(i,2);
11 -             dId=Data(i,3);
12 -             mId=Data(i,4);
13 -             I = find(Data(:,2)==dId);
14 -             I2 = find(Data(:,2)==mId);
15 -             ddId=Data(I,3);
16 -             dmId=Data(I,4);
17 -             mmId=Data(I2,4);
18 -             mdId=Data(I2,3);
19 -             I3 = find(Data(:,2)== ddId);
20 -             I4 = find(Data(:,2)== dmId);
```

Command Window

New to MATLAB? See resources for [Getting Started](#).

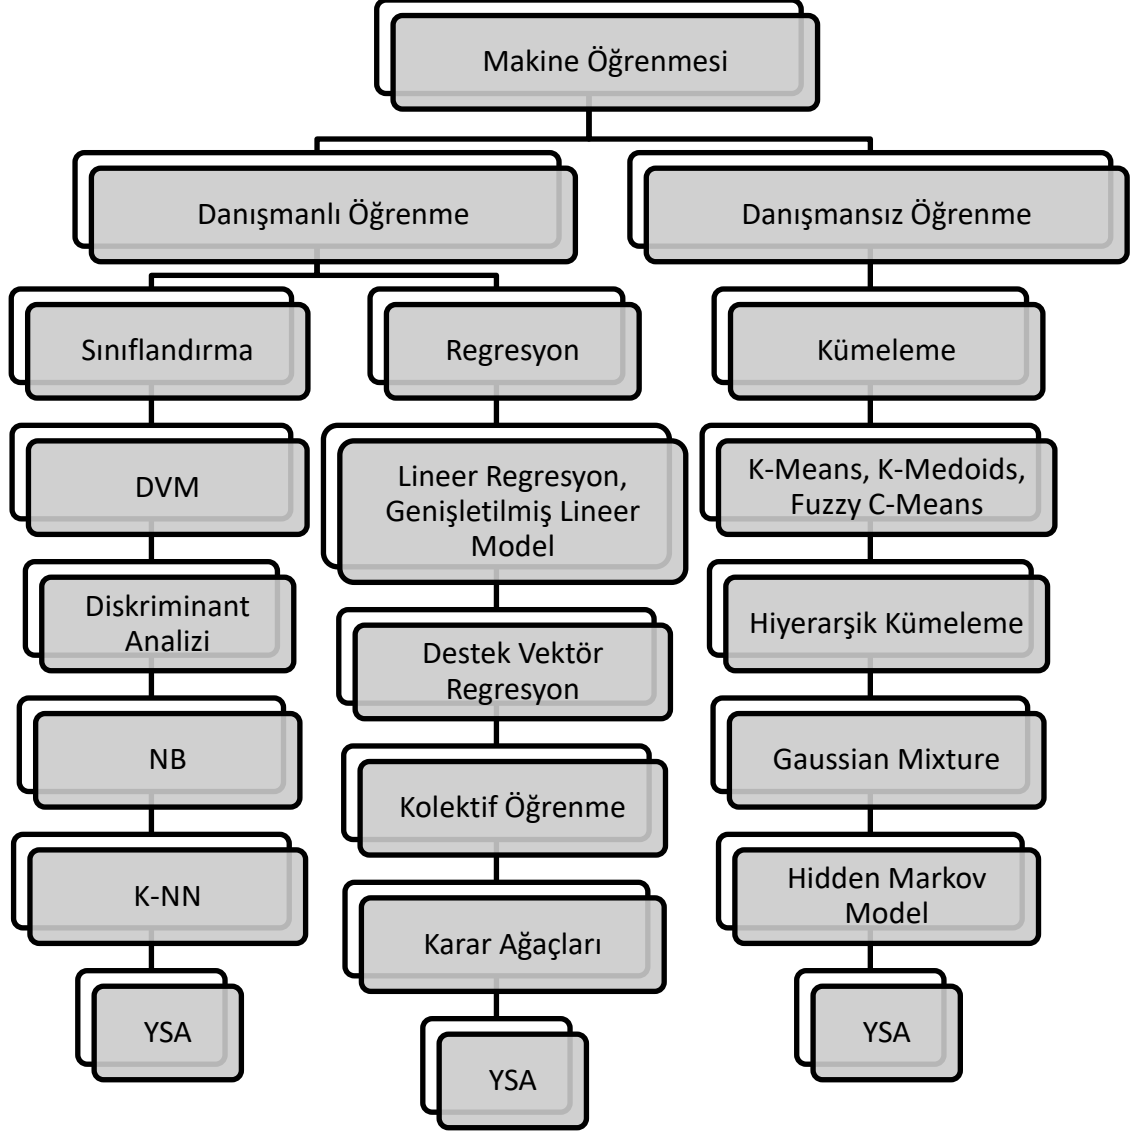
>> Pedigreee
fx >>

Şekil 6.8. F2 Pedigrî takibi programına ait görsel.

6.2. SINIFLANDIRMA ALGORİTMALARI

Makine öğrenmesi günümüzde yaygın olarak kullanılan yapay zeka yöntemleri arasında bulunmaktadır. Makine öğrenmesi, bilinen örneklerden bilinmeyen örnekleri tahmin etme yöntemi olarak tanımlanmaktadır. 1959 yılında makine öğrenmesini, Amerikan bilgisayar bilimcisi olan Arthur Samuel "bilgisayarın açıkça programlanmadan öğrenme yeteneği" olarak açıklamıştır [64]. Makine öğrenmesi modelleri verinin yapısına göre ikiye ayrılmaktadır. Bunlar; danışmanlı öğrenme algoritmaları ve danışmansız öğrenme algoritmalarıdır [65]. Danışmanlı öğrenme, sınıfları belirlenmiş olan durumlardan bir model oluşturulması ve daha sonra sınıfı belirlenmemiş verilerin sınıfını tahmin etme işlemidir. Danışmansız öğrenme, sınıfları belirlenmeyen verilerin, sınıfları belirlenen verilerin birbirleriyle olan benzerliklerinden sınıflandırılmasıdır. Sınıflandırma işleminde veriler önce eğitim ve

test setlerine ayrılır, algoritma seçilir, veriler test edilir ve sonuçlar değerlendirilir [66-67]. Makine öğrenmesi modelleri Şekil 6.9’da gösterilmiştir.




Şekil 6.9. Makine öğrenmesi modelleri [65].

Birçok makine öğrenmesi algoritmasının arkasındaki temel ilke, farklı veri kümeleri arasındaki işlevsel ilişkileri bulmaktır. Bu işlem, veriler üzerinde modelin eğitilmesi ve test edilmesiyle yapılır. Makine öğrenmesi modelleri yeni verilere uyum sağlama yeteneği, doğrusal olmayan süreçleri yakalama, kullanım kolaylığı ve hesaplama verimliliği özelliklerine sahiptir [68-71].

Bu çalışmada, pedigrî takibi yapılarak seçilen bireylerden elde edilen yumurtalara ait özellikler TAE tarafından veritabanına girilmiş ve veriseti oluşturulmuştur. Bu veriseti üzerinden 3 ayrı sınıflandırma analizi yapılmıştır. İlk analizde, yumurta kalitesinin mükemmel ya da çok iyi olması sınıflandırılmıştır. Bu analizde, rastgele orman, lineer diskriminant analizi (LDA), lojistik regresyon (LR), naive bayes (NB), DVM, K-NN, karar ağacı ve YSA makine öğrenmesi modelleri kullanılmıştır. İkinci analizde, yumurta kalitesi hakkında bilgi veren 24. hafta HU değeri; bilgi az (0), bilgi orta (1) ve bilgi çok (2) olarak sınıflandırılmıştır. Bu analizde rastgele orman, LDA, NB, DVM, K-NN, karar ağacı ve YSA modelleri kullanılmıştır. Üçüncü analizde, yumurta kalitesi hakkında bilgi veren 32. hafta HU değeri; bilgi az (0), bilgi orta (1) ve bilgi çok (2) olarak sınıflandırılmıştır. Bu analizde de rastgele orman, LDA, NB, DVM, K-NN, karar ağacı ve YSA Makine öğrenmesi modelleri kullanılmıştır.

6.2.1 Rastgele Orman

Birçok sınıflandırma modellemelerinin birlikte kullanılması ile oluşan sistemler, topluluk öğrenme modelleri olarak tanımlanmaktadır. Rastgele orman modeli topluluk öğrenme modellerinden bir tanesidir. Rastgele orman modeli, birçok sınıflandırma algoritmasının bir arada uygulanması ile daha başarılı sonuçlar sağlamaktadır. Bagging algoritmasının temellerine dayanan ve Leo Breiman tarafından 2001 yılında oluşturulan rastgele orman modeli, tahmin oranını arttırmak amacıyla karar ağaçları modelinin n defa uygulanması ile kullanılır. Birçok karar ağacına sahiptir ve bu ağaç sayısı kullanıcı tarafından belirlenmektedir. Kullanılan ağaç sayısı arttıkça tahmin işleminin başarı oranı da artmaktadır. Bu ağaçlar en yüksek boyutta oluşturulmakta ve budama işlemi uygulanmadan geliştirilmektedir. Bunun için CART algoritması kullanılmaktadır [72,73]. Örnek bir rastgele orman modeline ait görsel Şekil 6.10'da gösterilmiştir.



Şekil 6.10. Rastgele orman algoritmasına ait görsel [74].

Rastgele orman modelinin avantajları ve dezavantajları vardır. Avantajları:

- ✓ Yüksek boyutlu verileri analiz ederken hızlıdır.
- ✓ Birçok veriyi silmeden işlemektedir.
- ✓ Sürekli ve kesikli değişkenleri birlikte kullanmaktadır.

Dezavantajları:

- ✓ Rastgele orman modelinde ağaç yapısı gösterilmemektedir.
- ✓ Birçok karar ağacına sahiptir.
- ✓ Seviyelerdeki nitelikler belirlenirken, tüm ağaçlarda bazı hesaplamalar yapılarak nitelik belirlenmektedir [75-77].

6.2.2. Lineer Diskriminant Analizi (LDA)


LDA, karmaşık problemlerde başarılı sonuçlar alındığı için çok kullanılan makine öğrenmesi modellerinden bir tanesidir. LDA, istatistiksel ölçümleri kullanarak veri kümesinin sınıflarını tanımlayan özelliklerin doğrusal bir ilişkisini bulmaktadır. LDA, yüksek boyutlu verileri düşük boyutlu bir uzayda yansıtır. Sınıf içindeki mesafeyi en düşük değere indirmeyi, sınıflar arasındaki mesafeyi en üst düzeye çıkarmayı ve sınıf farkını üst düzeye çıkarmayı amaçlamaktadır [78,79]. LDA,

diskriminant fonksiyonunun Eşitlik 6.1’de açıklanabileceği veri kümesi sınıflarının kovaryanslarını dikkate almaktadır.

$$\delta_k(x) = x^T Q^{-1} \mu_k - 1 - \frac{1}{2} \mu_k^T Q^{-1} \mu_k + \log \pi_k \quad (6.1)$$

Burada k alt indeksi her bir sınıfı, μ her sınıfın ortalama değerlerini, π bir sınıfa üyeliğin önsel olasılığını, x girdi özelliklerini içeren vektörü ve Q kovaryans matrisini temsil eder [78].

Maksimum sınıf ayrımı, verilerin varyansını ve çoklu sınıflar arasındaki farkı en üst düzeye çıkaran bileşen eksenlerini belirleyerek elde edilir. Bu fark yöntemi, grupların varyans-kovaryans matrislerinin homojenliğini gerektirir. Sınıflandırma yapılmadan önce özellik çıkarmanın zorlaştığı durumlarda veri ön işleme için uygulanır. Sınıflandırma için sınıfların dağılımını inceler ve ortalama değerler arasındaki fark bulunur. Bunlar üzerinden de özellik alt uzayları oluşturulur [80-83]. Örnek bir LDA modeline ait görsel Şekil 6.11’de gösterilmiştir.



Şekil 6.11. LDA modeline ait görsel [84].

6.2.3. Lojistik Regresyon (LR)

Raymond Pearl ve Lowell Reed tarafından 1940 yılında ortaya atılan LR, ikili sınıflandırma problemlerine çözüm bulan istatistiksel bir modeldir. LR'in amacı, en az sayıda değişken ile en iyi uyumlu bağımlı-bağımsız değişkenler arasındaki ilişkiyi tanımlayabilen kabul edilebilir bir model kurmaktır [85]. LR, logaritma boyutundaki değişiklikler gibi model parametrelerinin değerlendirilmesini kolaylaştırmak için tıbbi uygulamalarda yaygın olarak kullanılmaktadır. LR bir tür regresyon analizidir [86,87]. Eşitlik 6.2'de gösterilen yargı, değişkenler ve Eşitlik 6.3'te gösterilen sınıf sonuçlarını tahmin etmek için kullanılan bir lojistik fonksiyon ile doğrusal bir regresyon kullanır.

$$y = h(W^T X + b) \quad (6.2)$$

$$h(x) = \frac{1}{1 + e^{-x}} \quad (6.3)$$

Burada $h(x)$ bir lojistik fonksiyon olarak kullanılan sigmoid fonksiyondur, b önyargıdır, W ve X bağımsız değişkenlerdir. Veri kümesinin regresyon analiziyle, 0 veya 1 olarak iki sonuç oluşur. Verisetinde yumurta kalitesini sınıflandırmak için mükemmel ve çok iyi gibi iki olası sonucu elde etmek için LR modeli kullanılmıştır.

6.2.4. Naive Bayes (NB)

NB modeli, İngiliz bir matematikçi olan Thomas Bayes'in 18. yüzyılda geliştirilmiş olduğu makine öğrenme modellerinden bir tanesidir. Bayes teoreminden yararlanılarak oluşturulmuş sınıflandırma işlemlerinde kolay bir şekilde uygulanabilmektedir. Bu model ile bir verisetindeki hedeflenen özneliğin sınıf değerine ait olma olasılığı belirlenmektedir. Mevcut sınıflandırılmış verileri kullanarak, yeni gelen verilerin mevcut sınıf etiketlerinden biri olma olasılığını hesaplayan bir modeldir [88-90].

NB, bütün deęişkenleri bağımsız olduğunu ve nitelikler arasında bağımlılık olmadığını kabul etmektedir. Bu koşullu bağımsızlık hipotezi, gerçek uygulamalarda nadiren doğrudur. Algoritma, çeşitli kontrollü sınıflandırma problemlerinde hızlı bir şekilde öğrenmeye eğilimlidir [82]. NB algoritması, hızlı ve çok sınıflı tahmin özelliğinden dolayı kullanılmıştır. Olasılık hesaplama işlemi Eşitlik 6.4'te gösterilmiştir.

$$P\left(\frac{A}{B}\right) = \frac{P(B/A) * P(A)}{P(B)} \quad (6.4)$$

Eşitlik 6.4'te $P(A/B)$ B ifadesi A'nın gerçekleşme ihtimalini, $P(B/A)$ A ifadesi B'nin gerçekleşme ihtimalini, $P(A)$ ifadesi A'nın gerçekleşme ihtimalini, $P(B)$ B'nin gerçekleşme ihtimalini açıklamaktadır [91].

6.2.5. Destek Vektör Makineleri (DVM)

Vapnik ve arkadaşlarının 1990'lı yıllarda geliştirdikleri makine öğrenmesi modellerinden olan DVM, mühendislik, bilişim ve uzaktan algılama alanlarında yaygın olarak kullanılmaktadır. DVM danışmanlı makine öğrenmesi modellerinden bir tanesidir, DVM, bilinen sınıf etiketlerinden oluşan verilerle oluşturulan bir tahmin modeline dayalı olarak, bir bilinmeyen etiket örneğine bir sınıf etiketi atamak için kullanılmaktadır [92-94].

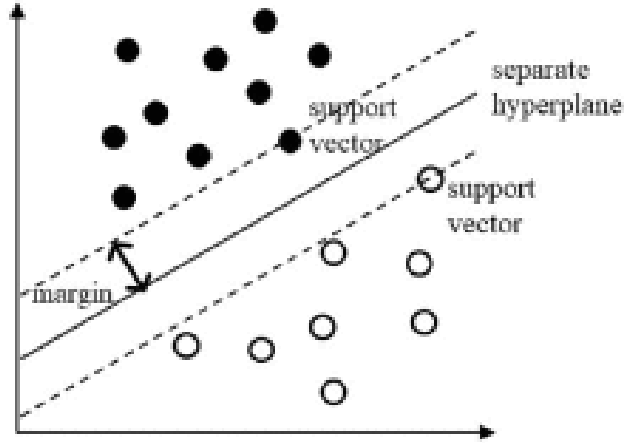
DVM modeli iki aşamadan oluşmaktadır. Bunlar eğitim ve test aşamalarıdır. Eğitim aşamasında, DVM, iki sınıfın ayrışması için bir hiperdüzlem oluşturmakta ve verileri iki sınıfa ayıran bir fonksiyon tahmin etmektedir. Farklı sınıflara ait verileri ayırmak için çok sayıda hiperdüzlem oluşturulabilmektedir. Verileri, hiperdüzleme en yakın olan veriler arasındaki maksimum mesafe ile iki alt alana bölerek hiper düzlemi bulmaya çalışmaktadır. Bu hiperdüzlem, ayrı hiperdüzlem olarak adlandırılmaktadır. Bu hiperdüzlemi ayırmak için DVM Eşitlik 6.5'de gösterilen ifadeyi küçültmektedir. Bu ifade bir sınırlı optimizasyon problemine dönüştürülerek Lagrangian Dual probleminin çözümü ele alındığında Eşitlik 6.6'te verilen optimizasyon problemine indirgenmektedir. Son olarak tanımlanan optimizasyon problemi quadratic

programlama algoritmaları ile çözülebilmektedir. Hiperdüzlem ile veri arasındaki mesafeye kenar boşluğu denir. Hiperdüzleme en yakın verilere, destek vektörleri denir. Bu durum Şekil 6.12’de gösterilmiştir [95,96].

$$\left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(w \cdot x_i - b)) \right] + \lambda \|w\|^2 \quad (6.5)$$

$$\max f(c_1 \dots c_n) = \sum_{i=1}^n c_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i c_i (x_i \cdot x_j) y_j c_j \quad (6.6)$$

göre $\sum_{i=1}^n c_i y_i = 0$, ve $0 \leq c_i \leq \frac{1}{2n\lambda}$ tüm i 'ler için.



Şekil 6.12. DVM algoritmasına ait görsel [96].

DVM modelinin avantajları ve dezavantajları vardır. Avantajları:

- ✓ Yüksek genelleme yapabilmektedir.
- ✓ DVM modeli hızlıdır.
- ✓ İyi performans sonuçları göstermektedir.
- ✓ Sınıflandırma karmaşıklığı, özellik uzayının boyutluluğuna bağlı olmadığı için, DVM'ler büyük bir model kümesi öğrenebilir ve iyi ölçeklenebilmektedir.
- ✓ DVM'ler ayrıca sınıflandırma sırasında yeni bir model olduğunda eğitim modellerini dinamik olarak güncelleme yeteneğine sahiptir.

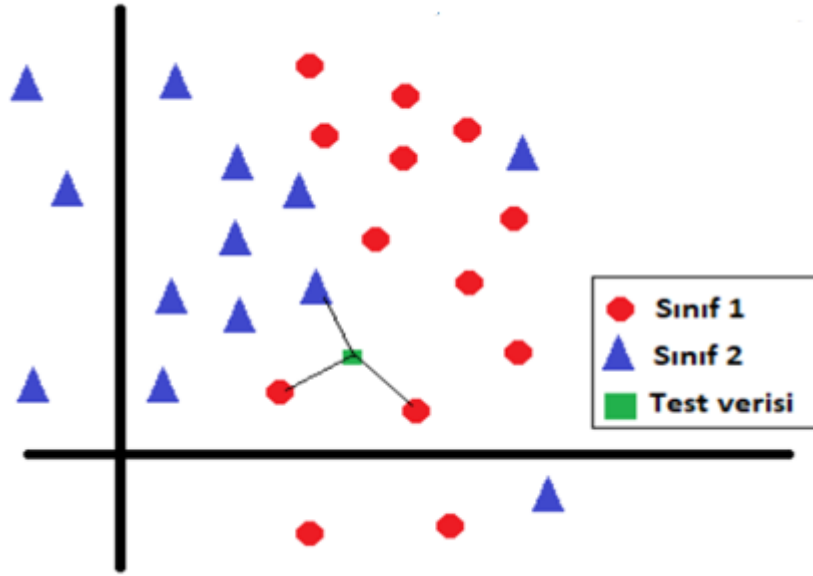
Dezavantajları:

- ✓ Yavaş çalışmaktadırlar.
- ✓ Çeşitli DVM modelleriyle çalışmak için profesyonel bir yazılım veya araç kutusu bulunmamaktadır.
- ✓ Diğer modellere göre DVM tabanlı hibrit modeller daha karmaşık oluşturulmaktadır.
- ✓ DVM yalnızca ikili sınıf sınıflandırmasını işleyebilmektedir ve buna karşılık izinsiz giriş tespiti çok sınıflı sınıflandırma gerektirmektedir [97,98].

6.2.6. K En Yakın Komşu (K-NN)

K-NN, herhangi bir eğitim süreci gerektirmeyen, parametrik olmayan, danışmanlı bir makine öğrenmesi modelidir. K-NN algoritması, var olan bütün verileri saklar ve yeni verilerle benzerlik ölçütüne göre sınıflandırır. En yakın komşuları bulmak için verisetini tek tek taramak algoritmanın performansını düşürdüğü için tembel öğrenme modeli veya durum tabanlı öğrenme modeli olarak adlandırılır [99]. K-NN modelinin kullanılacağını belirlemek için k parametresi gereklidir. K, en yakın komşu sayısını temsil eder. Sınıflandırılmamış veriler ile daha önce sınıflandırılmış diğer tüm veriler arasındaki mesafeler hesaplanır ve sınıflandırılmamış veriler, önceden sınıflandırılmış en yakın veriler arasından en yakın sınıfa yerleştirilir. Bu çalışmada k, 3 olarak seçilmiştir. Eşitlik 6.7’te gösterilen uzaklık hesabı olarak öklid uzaklığı kullanılmıştır [100]. K-NN algoritması sınıf belirleme işlemine (k=3) ait görsel Şekil 6.13’te ve K-NN algoritmasının akış şeması Çizelge 6.2’de gösterilmiştir.

$$d(D_1, D_2) = \sqrt{(X_1 - X_2)^2 + (Y_1 - Y_2)^2} \quad (6.7)$$



Şekil 6.13. K-NN algoritması sınıf belirleme işlemine ait görsel [101].

Çizelge 6.2. K-NN algoritmasının akış şeması.

K-NN iş akış kuralları	
1	k parametresi seçilir.
2	Uzaklık formülü seçilir.
3	Test verisi ile eğitim verileri arasındaki uzaklıklar hesaplanır.
4	Oylama tekniği seçilir.
5	Oylama tekniğine göre test verisi en yakın k adet veriye göre sınıflandırılır.

Etiketlenmemiş bir test verisi kullanıldığında, eğitim verisetindeki en yakın komşu veri bulunur ve onlara en uygun etiket verilir. K-NN algoritmasına göre, sınıflandırma işleminden çıkarılan özellikler göz önüne alındığında, sınıflandırılması gereken yeni birey ile önceki bireyler arasındaki tüm mesafe ölçülür. Ardından, en yakın komşu bireyin sayısı bulunur. Yeni bireye yakın komşu bireyin sınıfına göre yeni birey çoğunluğun olduğu sınıfa aktarılır. Seviyelerdeki nitelikler belirlenirken, tüm ağaçlarda bazı hesaplamalar yapılarak nitelik belirlenmektedir [102,103].

K-NN algoritmasının avantajları ve dezavantajları vardır. Avantajları:

- ✓ K-NN modelinin uygulaması kolaydır.
- ✓ Eğitim işlemi bulunmamaktadır.
- ✓ Verisetinin büyüklüğü fazla ise daha etkin sonuçlar verir.

- ✓ Gürültülü verilere karşı dirençli olmanın yanı sıra büyük orandaki verisetlerinde başarılıdır.

Dezavantajları:

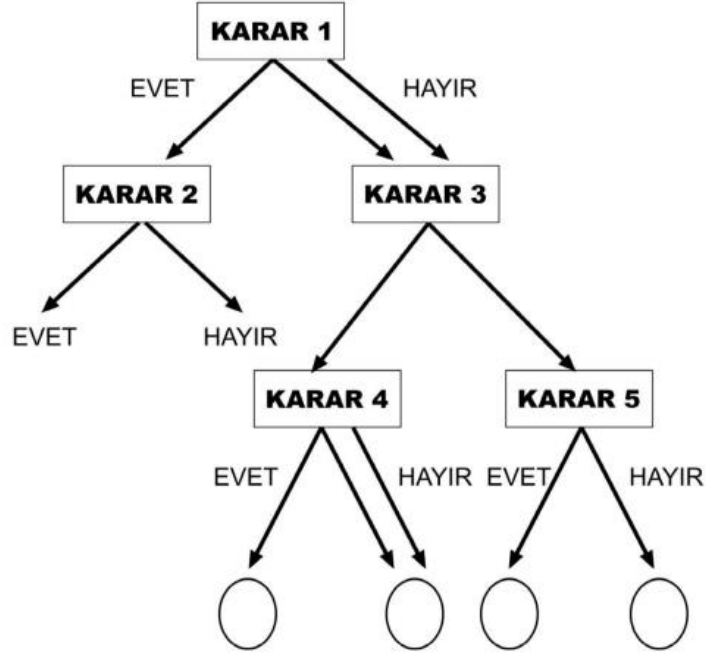
- ✓ Başlangıçta k parametresi gereklidir.
- ✓ Hesaplama maliyeti yüksektir.
- ✓ Birçok karar ağacına sahiptir.
- ✓ En iyi sonucun ulaşılabilmesi için hangi uzaklık formülünün seçileceği belli değildir [104, 105].

6.2.7. Karar Ağacı

Karar ağacı modeli, en çok tercih edilen danışmanlı öğrenme modellerinden bir tanesidir [66]. Bu model verisetindeki karmaşık yapıları basit yapılara dönüştürmeyi amaçlamaktadır. İlk olarak, verisetindeki nitelik değerleri dallanmış değerlere dönüştürülür. Ağaç, bütün verinin oluşturduğu tek bir düğümle başlar. Veri kayıtlarının bütünü aynı sınıfta değil ise bu kayıtları en iyi şekilde sınıflandıracak olan öznitelik seçilir. Veri kayıtlarının hepsi aynı sınıfa ait kayıtları sınıflandıracak öznitelik kalmamış ya da kalan özniteliklerin değerini taşıyan kayıt yok ise karar ağaçları ile sınıflandırmada işlemi sonlandırılır [106-108]. Bu işlem basamakları aşağıda verilmiştir.

- ✓ Öğrenme veriseti oluşturulur.
- ✓ Öğrenme verisetindeki örnekler için en iyi ayırıcı öznitelik belirlenir.
- ✓ Bir düğüm, en iyi ayırıcı nitelik tarafından oluşturulur. Daha sonra bu düğümün alt düğümleri oluşturulur. Alt düğüme ait verisetindeki örnekler belirlenir.
- ✓ Üçüncü adımda belirlenen her numune için,
 - ✓ tüm örnekler aynı düğüme ait ise ve
 - ✓ verisetinde ayırıcı bir öznitelik yoksa ve
 - ✓ öznitelik değerlerini taşıyan örnek yoksa işlem sonlandırılır. Değil ise, ikinci adımla devam edilir [109-112].

Örnek bir karar ağacı görseli Şekil 6.14'te gösterilmiştir.



Şekil 6.14. Karar ağacı algoritmasına ait görsel [113].

Karar ağacı algoritmasının avantajları ve dezavantajları vardır. Avantajları:

- ✓ Anlaşılabilir kurallar oluşturulmaktadır.
- ✓ Çok büyük boyutlu verilerle de çalışabilmektedir.
- ✓ Sayısal veya kategorik veriler işlenebilir.
- ✓ Modelin uygulanması kolaydır.


Dezavantajları:

- ✓ Çok karmaşık ağaçlar üretilebilir.
- ✓ Ezberleme durumu oluşabilir.
- ✓ Sayısal değişkenlerde çalışma performansı düşüktür.
- ✓ Çok sınıflı problemlerde başarısı düşebilir [107,108,114].

6.2.8. Yapay Sinir Ağları (YSA)

YSA modeli, danışmanlı makine öğrenmesi modellerinden bir tanesidir. İnsan beyninin biyolojik ve doğal davranışını taklit eden YSA, genellikle birbirine bağlı çok sayıda nörondan oluşmaktadır. İnsan beyninde yaklaşık 100 milyar nöron var. Her nöronun 1.000 ile 100.000 arasında bir bağlantı noktası vardır. İnsan beyninde bilgi dağıtılacak şekilde depolanır ve gerektiğinde bu bilginin birden fazla parçasını paralel olarak hafızada çıkarılabilmektedir. Çok katmanlı YSA’larda insan beynine benzer şekilde yerleştirilmiş nöronlar bulunmaktadır. Her nöron belirli katsayılarla diğer nöronlara bağlanmaktadır. Eğitim sırasında bu bağlantı noktalarına bilgi dağıtılarak ağı öğrenilmesi sağlanmaktadır. YSA’nın eğitilebilmesi için çok sayıda girdi ve girdilere ilişkin çıktı dizisi gerekmektedir. [115,116].

YSA bileşenleri olarak her katmanın nöronlar aracılığıyla bir sonrakine bağlandığı üç katmana sahiptir. Bunlar giriş, gizli ve çıktı katmanlarıdır. Giriş katmanı olarak adlandırılan ilk katman, girdi değişkenleri olarak ham verileri alır ve bu iki katman arasındaki bağlantı aracılığıyla gizli katmana dönüştürür. Gizli katmanda, ana hesaplamalar uygulanır ve önemli ilişkiler ve değişkenlerin bağımlılığı çıkarılır, model mevcut verilere dayalı olarak eğitilir. İki katman arasındaki bağlantılar, sağlamlık ve zayıflık açısından çeşitlilik gösterirken, her parametre veya bağlantı için ağırlık, bağlantının gücüne göre oluşur. Başka bir deyişle, en önemli değişken en yüksek ağırlığa sahiptir ve bunun tersi de geçerlidir. Son olarak, gizli katmandaki düğümler, hedef değişkenin değerini belirleyen çıkış katmanına bağlanır. Bu prosedür, belirli bir yinleme sayısı boyunca veya performans kriterleri karşılandığında devam eden tekrarlayan bir süreçtir. Normal YSA, modeli mevcut girdi ve çıktı kayıtlarına dayalı olarak eğitmek için bir geri yayılım algoritması kazanır. Genel olarak, en basit haliyle üç katmanlı bir YSA modeline ait bir görsel Şekil 6.15’te gösterilmiştir [117].



Şekil 6.15. YSA algoritmasına ait görsel [118].

YSA algoritmasının avantajları ve dezavantajları vardır. Avantajları:

- ✓ YSA, aynı anda birden fazla işi gerçekleştirebilecek sayısal güce sahiptir.
- ✓ YSA'lar, hataya karşı yüksek toleranslı bir sistem için kullanışlıdır.
- ✓ YSA eğitimi sonrasında veriler, eksik bilgilerle bile çıktı üretebilmektedir.

Dezavantajları:

- ✓ Karmaşık problemleri çözmek için çok katmanlı ve çok nöron içeren YSA modelleri gerekmektedir.
- ✓ Ağ yapısı çok sayıda düğüm ve bağlantıdan oluştuğu için eğitim biraz zaman alabilmektedir [116,119].

Bu çalışmada, çok katmanlı ileri beslemeli geri yayımlı bir sinir ağı kullanılmıştır. YSA modelinin doğruluğunu artırmak için çeşitli momentum ve öğrenme hızı değerleri empirik olarak denenmiştir. Momentum 0,4 ve öğrenme oranı 0,25 olarak belirlenmiştir. Kullanılan makine öğrenmesi modellerinin kısa bir açıklaması Çizelge 6.3'te verilmiştir.

Çizelge 6.3. Makine öğrenmesi modellerinin özellikleri ve parametreleri.

Model	Özellikleri ve Parametreleri
Karar Ağacı	C4.5 öğrenme modeli kullanılmıştır.
LDA	Parametrik olmayan LDA kullanılmıştır.
LR	Lojistik fonksiyon olarak sigmoid fonksiyonu seçilmiştir.
NB	Dağılım parametresi “Gaussian” olarak belirlenmiştir.
DVM	Çekirdek “Gaussian” olarak adlandırılmıştır.
K-NN	K, 3 olarak tanımlanmıştır ve oklid mesafesi seçilmiştir.
Rastgele Orman	Karar ağacı sayısı 100 olarak belirlenmiştir.
YSA	0,4 olarak optimize edilmiş momentum ve 0,25 olarak optimize edilmiş öğrenme oranı ile çok katmanlı ileri beslemeli geri yayılım ağı kullanılmıştır.

6.3. PERFORMANS ÖLÇÜTLERİ

Yumurtaların kalitesinin ve yumurta kalitesi hakkında bilgi veren HU değerlerinin sınıflandırılmasında, en uygun modelin belirlenmesi için confusion matrix kullanılmıştır. Confusion matrix ile modellerin tahmin ettiği değerler ile gerçek değerler karşılaştırılmıştır [120]. Confusion matrix, TP (Doğru Pozitif), TN (Doğru Negatif), FP (Yanlış Pozitif), FN (Yanlış Negatif) olarak 4 temel parametreden oluşmaktadır. Bu parametreler; TP pozitif olan durumların pozitif olarak tahmin edilmesi, TN negative olan durumların negatif olarak tahmin edilmesi, FP negatif olan durumların pozitif olarak tahmin edilmesi ve FN pozitif olan durumların negatif olarak tahmin edilmesi olarak açıklanmaktadır. Confusion matrix Çizelge 6.4’te gösterilmiştir.

Çizelge 6.4. Confusion matrix [93].

		Var Olan Durum	
		Pozitif Durum	Negatif Durum
Tahmin	Pozitif Durum	TP	FP
	Negatif Durum	FN	TN

Bu çalışmada, model performansını belirlemek için duyarlılık (sensitivity), özgüllük (specificity), doğruluk (accuracy), matthews korelasyon katsayısı (MCC), receiver operating characteristic (ROC) eğrisi ve ROC altında kalan alan değerini veren area under curve (AUC) parametreleri kullanılmıştır. Sensitivity, specificity, accuracy ve

MCC'ye ait formüller sırasıyla Eşitlik 6.8-6.11'de gösterilmiştir [121].

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (6.8)$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (6.9)$$

$$\text{Accuracy} = \frac{TP+TN}{TP+FN+TN+FP} \quad (6.10)$$

$$\text{MCC} = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (6.11)$$

ROC eğrisi, temel olarak elde edilen sınıflandırma modellerinin iyi çalışıp çalışmadığını gösteren bir ölçüdür. ROC eğrisi, duyarlılığın kesinliğe oranı ile ortaya çıkmaktadır. ROC eğrisi, AUC değerine birbirinden farklı testlerin birbirleriyle kıyaslanmasında ihtiyaç duymaktadır AUC değerinin 1'e yaklaşması analizin başarılı olarak yapıldığını göstermektedir [93,120].

BÖLÜM 7

DENEYSEL SONUÇLAR VE TARTIŞMA


Bu çalışmada, veri analizi yapılarak en verimli gen yapıları belirlenip, bunlara yönelik bireyler yetiştirilmesi sağlanmıştır. Bireylerin SNP ve markör değerlerinden, bireylerin bilgileriyle veri analizi yapılmıştır. Bireylerin SNP değerleri karşılaştırılarak, verimli yumurta veren bireyler belirlenmiş ve uygun eşleşmenin yapılması sağlanmıştır. Pedigri takibi yapılarak, bilinen F0 ve F1 bireylerinden oluşabilecek F2 bireylerinin jenerasyonlarının olasılıkları hesaplanmıştır. Moleküler tekniklerden faydalanarak damızlık seçiminde isabet derecesi artırılmış, damızlık seçiminin daha erken yaşlarda gerçekleştirilebilmesi sağlanmıştır. Damızlık seçiminde kullanılmak üzere bir SNP panelinin oluşturulması gerçekleştirilmiş ve tavuk damızlık materyal temininde dışa bağımlık azaltılarak ülke öz yeterliliği artırılması hedeflenmiştir.

Bu çalışmada yumurta kalitesi, yumurta kalitesi hakkında bilgi taşıyan 24. hafta ve 32. hafta HU değerleri, 20 karakteristik yumurta özelliğine dayalı veriseti üzerinde makine öğrenmesi modelleri kullanılarak analiz edilmiş ve sınıflandırılmıştır. Karakteristik yumurta özelliklerine dayalı olarak 803x21 boyutunda üç ayrı veriseti oluşturulmuştur. Bu verisetlerinin 21. parametreleri yumurta kalitesi (mükemmel ve çok iyi), 24. hafta ve 32. hafta HU değerleri (az bilgi, orta bilgi ve çok bilgi veren) olarak belirlenmiştir. Bu verisetleri sırasıyla %80 ve %20 oranında sırasıyla eğitim seti ve test seti olarak iki gruba ayrılmıştır. Üç verisetini analiz etmek ve sınıflandırmak için makine öğrenmesi modelleri kullanılmıştır. Yumurta kalitesini sınıflandırmak için kullanılan makine öğrenmesi modellerinin sensitivity, specificity, accuracy ve MCC sonuçları Çizelge 7.1’de sunulmuş ve kullanılan bu modellerin ROC eğrileri Şekil 7.1-7.8’de verilmiştir.


Çizelge 7.1 Makine öğrenme modelleri analiz sonuçları.

Metot	Sınıf	Sensitivity (%)	Specificity (%)	Accuracy (%)	MCC
Rastgele Orman	Mükemmel	96.4	92.3	95.1	0.88
	Çok iyi	92.3	96.4		
LDA	Mükemmel	95.6	85.8	92.7	0.83
	Çok iyi	85.8	95.6		
LR	Mükemmel	98.8	98.0	98.6	0.96
	Çok iyi	98.0	98.8		
NB	Mükemmel	89.2	79.3	86.1	0.68
	Çok iyi	79.3	89.2		
DVM	Mükemmel	98.3	89.6	95.5	0.89
	Çok iyi	89.6	98.3		
K-NN	Mükemmel	92.6	57.4	81.2	0.55
	Çok iyi	57.4	92.6		
Karar Ağacı	Mükemmel	98.3	96.1	97.6	0.94
	Çok iyi	96.1	98.3		
YSA	Mükemmel	97.6	96.5	97.3	0.93
	Çok iyi	96.5	97.6		


Çizelge 7.1’de, çalışmada kullanılan rastgele orman, LDA, LR, NB, DVM, K-NN, karar ağacı ve YSA modellerinin doğrulukları sırasıyla %97.6, %92.7, %**98.6**, %86.1, %95.5, %81.2, %95.1ve %97.3 olduğu görülmektedir. Böylece, doğruluk oranı olarak en başarılı modelin LR modeli olduğu söylenebilmektedir. En başarılı sınıflandırıcı olan LR modelinin ROC eğrisi hesaplanmış ve AUC değeri 1.00 olarak bulunmuştur.




Şekil 7.1. Yumurta kalitesini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi.




Şekil 7.2. Yumurta kalitesini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi.




Şekil 7.3. Yumurta kalitesini sınıflandırmak için kullanılan LR modelinin ROC eğrisi.




Şekil 7.4. Yumurta kalitesini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.




Şekil 7.5. Yumurta kalitesini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi.



Şekil 7.6. Yumurta kalitesini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi.



Şekil 7.7. Yumurta kalitesini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi.




Şekil 7.8. Yumurta kalitesini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi.

Bu çalışmada, yumurta kalitesi hakkında bilgi verme durumlarına göre 24. hafta HU değerleri ve 32. haftadaki HU değerleri az bilgi, orta bilgi ve çok bilgi veren olarak 3 ayrı gruba ayrılmıştır. 24. hafta HU değerleri 2. verisetine sınıf etiketi olarak dahil edilmiş ve 32. hafta HU değerleri 3. verisetine sınıf etiketi olarak dahil edilmiştir. Öznitelik olarak 20 adet karakteristik yumurta özellikleri kullanılmıştır. Bu iki veriseti kullanılarak, HU değerlerinin bilgi verme durumları makine öğrenmesi modellerine göre tam otomatik şekilde sınıflandırılmıştır. 24. hafta HU değerleri ile 32. hafta HU değerleri karşılaştırılarak hangisinin seçileceği bulunmuştur. 24. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman, LDA, LR, NB, DVM, K-NN, karar ağacı ve YSA makine öğrenmesi modellerinin sensitivity, specificity, accuracy ve MCC sonuçları Çizelge 7.2’de sunulmaktadır. En başarılı sınıflandırıcı

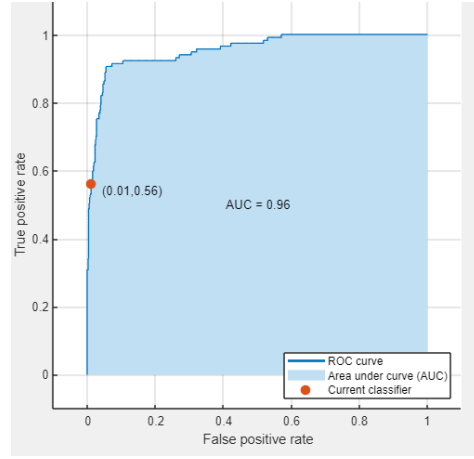
olan rastgele orman modelinin ROC eğrisi hesaplanmış ve AUC değeri 0.99 olarak bulunmuştur. 24. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin ROC eğrileri Şekil 7.9-7.15'te verilmiştir. 32. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman, LDA, LR, NB, DVM, K-NN, karar ağacı ve YSA makine öğrenmesi modellerinin sensitivity, specificity, MCC ve accuracy sonuçları Çizelge 7.3'te sunulmaktadır. En başarılı sınıflandırıcı olan rastgele orman modelinin ROC eğrisi hesaplanmış ve AUC değeri 1.00 olarak bulunmuştur. 32. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin ROC eğrileri Şekil 7.16-7.22'de verilmiştir.

Çizelge 7.2. 24. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin sonuçları.


Metot	Sınıf	Sensitivity (%)	Specificity (%)	MCC	Accuracy (%)
Rastgele Orman	Bilgi az (0)	94.0	98.5	0.91	96.8
	Bilgi orta (1)	96.6	96.8	0.93	
	Bilgi çok (2)	97.8	99.5	0.97	
LDA	Bilgi az (0)	56.4	98.7	0.67	85.3
	Bilgi orta (1)	96.0	77.0	0.72	
	Bilgi çok (2)	84.0	98.3	0.84	
NB	Bilgi az (0)	77.7	96.2	0.75	81.7
	Bilgi orta (1)	79.9	83.6	0.63	
	Bilgi çok (2)	84.9	87.7	0.72	
DVM	Bilgi az (0)	82.9	99.2	0.86	92.7
	Bilgi orta (1)	96.0	89.9	0.85	
	Bilgi çok (2)	92.4	97.9	0.91	
K-NN	Bilgi az (0)	26.4	98.7	0.41	71.1
	Bilgi orta (1)	82.2	63.4	0.45	
	Bilgi çok (2)	75.0	83.4	0.58	
Karar Ağacı	Bilgi az (0)	89.7	98.0	0.87	94.1
	Bilgi orta (1)	93.2	94.8	0.88	
	Bilgi çok (2)	96.6	97.5	0.94	
YSA	Bilgi az (0)	90.5	98.1	0.88	93.8
	Bilgi orta (1)	91.5	95.5	0.87	
	Bilgi çok (2)	97.2	95.6	0.92	




Şekil 7.9. 24. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi.




Şekil 7.10. 24. hafta HU değerlerini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi.




Şekil 7.11. 24. hafta HU değerlerini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.




Şekil 7.12. 24. hafta HU değerlerini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi.



Şekil 7.13. 24. hafta HU değerlerini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi.




Şekil 7.14. 24. hafta HU değerlerini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi.




Şekil 7.15. 24. hafta HU değerlerini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi.

Çizelge 7.3. 32. hafta HU değerlerini sınıflandırmak için kullanılan makine öğrenmesi modellerinin sonuçları


Metot	Sınıf	Sensitivity (%)	Specificity (%)	MCC	Accuracy (%)
Rastgele Orman	Bilgi az (0)	96.2	98.0	0.93	95.1
	Bilgi orta (1)	94.7	95.4	0.90	
	Bilgi çok (2)	94.7	98.4	0.93	
LDA	Bilgi az (0)	75.8	97.3	0.78	85.2
	Bilgi orta (1)	95.8	75.5	0.72	
	Bilgi çok (2)	75.2	99.6	0.81	
NB	Bilgi az (0)	76.7	92.1	0.69	78.8
	Bilgi orta (1)	78.7	79.0	0.57	
	Bilgi çok (2)	80.9	91.6	0.72	
DVM	Bilgi az (0)	90.5	99.1	0.91	94.0
	Bilgi orta (1)	97.9	90.4	0.88	
	Bilgi çok (2)	90.4	99.4	0.92	
K-NN	Bilgi az (0)	55.9	87.5	0.45	67.0
	Bilgi orta (1)	74.8	60.4	0.35	
	Bilgi çok (2)	63.8	90.9	0.57	
Karar Ağacı	Bilgi az (0)	92.4	96.8	0.88	92.5
	Bilgi orta (1)	92.4	92.6	0.85	
	Bilgi çok (2)	92.8	98.0	0.91	
YSA	Bilgi az (0)	93.8	98.0	0.92	94.3
	Bilgi orta (1)	94.5	94.0	0.88	
	Bilgi çok (2)	94.2	98.2	0.92	




Şekil 7.16. 32. hafta HU değerlerini sınıflandırmak için kullanılan rastgele orman modelinin ROC eğrisi.




Şekil 7.17. 32. hafta HU değerlerini sınıflandırmak için kullanılan LDA modelinin ROC eğrisi.




Şekil 7.18. 32. hafta HU değerlerini sınıflandırmak için kullanılan NB modelinin ROC eğrisi.




Şekil 7.19. 32. hafta HU değerlerini sınıflandırmak için kullanılan DVM modelinin ROC eğrisi.



Şekil 7.20. 32. hafta HU değerlerini sınıflandırmak için kullanılan K-NN modelinin ROC eğrisi.



Şekil 7.21. 32. hafta HU değerlerini sınıflandırmak için kullanılan karar ağacı modelinin ROC eğrisi.



Şekil 7.22. 32. hafta HU değerlerini sınıflandırmak için kullanılan YSA modelinin ROC eğrisi.

Sınıflandırma işlemleri için farklı makine öğrenmesi modelleri kullanılmış ve sonuçlar karşılaştırılmıştır. Elde edilen sonuçlara göre, ilk sınıflandırma işlemi için LR modelinde 98.6% accuracy, ikinci sınıflandırma işlemi için rastgele orman modelinde 96.8% accuracy ve üçüncü sınıflandırma işlemi için rastgele orman modelinde 95.1% accuracy değerine ulaşılmıştır. Bu sonuçlara bakılarak ikinci ve üçüncü sınıflandırma işlemleri karşılaştırıldığında, %1.7 daha yüksek accuracy oranına ikinci sınıflandırma işlemi ile ulaşıldığı görülmektedir. Bu yüzden, yumurta kalitesi hakkında daha çok bilgi veren parametrenin 24. hafta HU değeri olduğu saptanmıştır. Ancak üçüncü sınıflandırma işleminde elde edilen daha düşük accuracy değeri %95.1 sonucu da oldukça başarılıdır. Bu sonuç da 32. hafta HU değerinin yumurta kalitesi hakkında oldukça fazla bilgi içerdiğini göstermektedir.

Yumurta kalitesinin sınıflandırılmasında, yüksek başarı oranları elde etmek için bu alanda yapılması gereken çalışmalara ihtiyaç vardır. Bunun üzerine, TAE’de saf hat bireyler üzerinde incelemeler yapılmış, onların sahip olduğu yumurtalar üzerinde yumurta kalitesi parametreleri hesaplanmış ve veritabanında tutulmuştur. Bu çalışmada, TAE veritabanında tutulan yumurtalara ait kalite parametrelerine dayalı üç ayrı veriseti (%80 eğitim, %20 test) oluşturulmuş ve bu verisetleri üç ayrı sınıflandırma işlemi için kullanılmıştır. İlk sınıflandırma işleminde kullanılan veriseti, yumurta kalitesi analizi yapmak için kullanılmıştır. Makine öğrenmesi modellerinin kullanılmasıyla yumurtalar mükemmel ve çok iyi kalite sınıflarına ayrılmıştır. İkinci sınıflandırma işleminde kullanılan veriseti, 24. hafta HU değerleri

hakkında bilgi verme durumlarının analizi yapılmak için kullanılmıştır. Makine öğrenmesi modellerinin kullanılmasıyla yumurtaların bilgi verme durumları az bilgi (0), orta bilgi (1) ve çok bilgi (2) olarak sınıflarına ayrılmıştır. Üçüncü sınıflandırma işleminde kullanılan veriseti, 32. hafta HU değerleri hakkında bilgi verme durumlarının analizi yapılmak için kullanılmıştır. Makine öğrenmesi modellerinin kullanılmasıyla yumurtaların bilgi verme durumları az bilgi (0), orta bilgi (1) ve çok bilgi (2) olarak sınıflarına ayrılmıştır.

Cruz ve arkadaşlarının çalışmasında 660 adet yumurta kullanılmış ve verisetinde sadece yumurtalara ait HU parametresi bulunmaktadır. PLS-DA ve SVM-C metotları ile yumurta kalitesini taze ve bayat olarak sınıflandırmışlardır. Cruz ve arkadaşlarından farklı olarak, bu çalışmada 803 adet yumurta kullanılmış ve verisetinde 21 adet parametre bulunmaktadır. Verisetine kötü kalite yumurtalar dahil edilmemiştir. İyi kalite yumurtalar da mükemmel ve çok iyi olarak verisetine eklenmiştir. 8 adet makine öğrenmesi modeli kullanılıp karşılaştırılarak yumurtalar, mükemmel ve çok iyi olarak sınıflandırılmıştır. Cruz ve arkadaşlarının accuracy değeri %87.0 iken, bu çalışmada %98.6 accuracy ile daha yüksek bir sınıflandırma sonucuna ulaşılmıştır. Bu çalışmada yüksek accuracy elde edilmesi sonucu, yumurta kalitesi sınıflandırmasında daha güvenilir sonuçlara ulaşılmış, sınıflandırmadaki yüksek accuracy başarısının parametre çeşitliliği ve farklı makine öğrenmesi modellerinin kıyaslanması sonucu LR modeli tarafından sağlandığı saptanmıştır. Fakat, bu çalışmadaki kullanılan verisetinde yer alan 21 parametrenin elde edilmesi aşaması zaman almakta olup maliyeti de daha yüksek tutmaktadır.

Zhang ve arkadaşlarının çalışmasında 645 adet yumurta kullanılmıştır. Bir spektral aralık kullanarak yumurta tazeliğini sınıflandırılması için dalga boyu ve HU değeri parametreler olarak seçilmiş ve SPA-SVC yöntemi sınıflandırıcı olarak kullanılmıştır. Zhang ve arkadaşlarından farklı olarak, bu çalışmada 803 adet yumurta kullanılmış ve verisetinde 21 adet parametre bulunmaktadır. 8 adet makine öğrenmesi modeli kullanılmış ve bu modellerin sonuçları karşılaştırılarak yumurtalar, mükemmel ve çok iyi olarak sınıflandırılmıştır. Zhang ve arkadaşlarının yumurta kalitesini ayırt etmede accuracy değeri %84.0 iken, bu çalışmada accuracy değeri %98.6 olarak elde edilmiş ve daha yüksek bir sınıflandırma sonucuna ulaşılmıştır.

Zhao ve arkadaşlarının çalışmasında 101 adet yumurta kullanılmıştır. Taze ve taze olmayan yumurtaları sınıflandırmak için HU değeri parametre olarak seçilmiş ve PLS-DA, K-NN, YSA, SVM ve SVDD yöntemleri sınıflandırıcı olarak kullanılmıştır. Zhang ve arkadaşlarından farklı olarak, bu çalışmada 803 adet yumurta kullanılmış ve verisetinde 21 adet parametre bulunmaktadır. 8 adet makine öğrenmesi metodu kullanılıp karşılaştırılarak yumurtalar, mükemmel ve çok iyi olarak sınıflandırılmıştır. Zhao ve arkadaşlarının accuracy değeri %93.3 iken, bu çalışmada accuracy değeri %98.6 olarak elde edilmiş ve daha yüksek bir sınıflandırma sonucuna ulaşılmıştır. Literatürde yapılan bu çalışmaların, mevcut çalışmanın sonuçları ile karşılaştırılması Çizelge 7.4'te gösterilmiştir.

Çizelge 7.4. Literatürdeki çalışmaların karşılaştırılması.

Yazar	Yumurta Sayısı	Parametre Sayısı	Model	Accuracy (%)
Cruz vd.	660	1 (HU)	PLS-DA	87.0
Zhang vd.	645	1 (HU)	SPA-SVC	84.0
Zhao vd.	101	1 (HU)	SVDD	93.3
Çalışma	803	21	LR	98.6

Çizelge 7.4'te, bu çalışmanın literatürde bulunan son çalışmalardan daha yüksek accuracy değeri elde ettiği görülmektedir. Bu çalışmada kullanılan verisetinde daha fazla yumurta kullanılmakta ve farklı bir analiz yaklaşımı sunmaktadır. Bu çalışmada kullanılan verisetinde karakteristik yumurta özellikleri kullanılırken, literatürde yer alan son çalışmalarda sadece HU değerleri öznitelik olarak kullanılmaktadır. Ayrıca, HU değerlerinin bazı durumlarda diğer yumurta türleri için yararlı olmadığı gözlemlenmiştir [122]. Alternatif olarak, bu çalışma yumurta kalite sınıflandırması için karakteristik yumurta özelliklerinin sağlamlığını ön plana çıkarmaktadır. HU değerlerine karşı karakteristik yumurta özelliklerinin verisetinde kullanılmasının dezavantajı, sayı olarak fazla olmaları ve ölçüm sırasında zaman alıcı ve maliyetli olmasıdır.

Bu alıřma, HU'nun 24. hafta ve 32. Hafta yumurta kalitesi hakkındaki bilgi dzeyini dřk, orta ve yksek olarak analiz ederek zgn bir yaklařım sunmaktadır. Bunun yapılmasındaki ama literatrde yer alan son alıřmaarın znelik olarak sadece HU deęerini kullanmasıdır. Bu alıřmada grlmektedir ki, karakteristik yumurta zellikleri HU deęeri iin yksek accuracy deęeri elde edilerek bilgi verici olmuřtur. Fakat, yumurta kalitesi hakkında daha bařarılı olduęu gzlemlenmiřtir.

Bu alıřmada yapılan yumurta kalitesi analizi sonucunda, mkemmel kalitedeki yumurtalara sahip saf hat yumurtacı bireyler belirlenmiřtir. Bylece gelecekte oluřacak yumurtaların bu bireylerden kaliteli olacaęı dřnlmektedir. Bu bireylerin SNP deęerleri zerinde TAE tarafından alıřılmalar devam etmektedir.

KAYNAKLAR

1. Aydın, D., Rashid, S. ve Aydın, R., "Tavuk yumurtası ve kolesterol gerçeği", **KSÜ Doğa Bilimleri Dergisi**, 17 (3): 26-29 (2014).
2. Kamanlı, S. ve Türkoğlu, M., "Tavukçuluk araştırma enstitüsünde bulunan beyaz yumurtacı saf hatlar ve melezlerinin yumurta iç ve dış kalite özelliklerinin belirlenmesi", **Tavukçuluk Araştırma Dergisi**, 15 (1): 23-28 (2018).
3. Baysal A, "Genel Beslenme", **Hatipoğlu Yayın Evi**, Ankara, 9-18 (2007).
4. Sarıca, M. ve Erensayın, "Tavukçuluk Ürünleri", **Bey Ofset Matbaacılık**, Ankara, 89-91 (2014).
5. Çopur, G., Duru, M. ve Şahin, A., "Düşük kolesterolü yumurta üretimi yönündeyapılan çalışmalar", **4. Ulusal Zootekni Bilim Kongresi**, Isparta (2004).
6. Çelebi, Ş. ve Karaca, H., "Yumurtanın besin değeri, kolesterol içeriği ve yumurtayı n-3 yağ asitleri bakımından zenginleştirmeye yönelik çalışmalar", **Atatürk Üniversitesi Ziraat Fakültesi Dergisi**, 37 (2): 257-265 (2006).
7. Çiçekgil, Z., "Kümes Hayvancılığı Ürün Raporu", **TEPGE Yayınları** (2014).
8. İnternet: Food and Agriculture Organization of the ünitiednations(FAO), <http://www.fao.org/faostat/en/#data/QL> (2021).
9. İnternet: Türkiye İstatistik Kurumu (TÜİK), "Hayvansal Üretim İstatistikleri", <https://biruni.tuik.gov.tr/medas/?kn=80&locale=tr> (2021).
10. Keyvan, E. ve Yurdakul, Ö., "Kuş gribi ve insan sağlığı üzerine etkileri", **Lalahan Hayvancılık Araştırma Enstitüsü Dergisi**, 56 (2): 70-77 (2016).
11. İnternet: Sağlıkım, "Avian İnfluenza (Kuş Gribi)", <https://sagligim.gov.tr/bulasici-hastaliklar/liste/686-avian-influenza-ku%C5%9Fgribi.html> (2021).
12. İnternet: Et ve Süt Kurumu, "Rhode Island Red", <https://www.esk.gov.tr/tr/11080/Rhode-Island-Red> (2021).
13. İnternet: Nabel Co Ltd., "Digital egg tester Det-6000.", <https://digitaleggtester.com/en>. (2022).

14. Chilur Omkarappa, V. ve Fairoze, M.N., "Study of retail egg supply chain for quality in relation to level of sanitization and farm of origin", **Turkish Journal of Veterinary and Animal Sci**, 43: 800-807 (2019).
15. Karakoyun, M. ve Hacibeyođlu, M., "Biyomedikal veri kümeleri ile makine öğrenmesi sınıflandırma algoritmalarının istatistiksel olarak karşılaştırılması", **Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi**, 16 (48): 30-42 (2014).
16. Umut, K., YILMAZ, A. ve Dikmen, Y., "Sađlık alanında kullanılan derin öğrenme yöntemleri", **Avrupa Bilim ve Teknoloji Dergisi**, (16): 792-808 (2019).
17. Kalaycı, T. E., "Kimlik hırsız web sitelerinin sınıflandırılması için Makine öğrenmesi modelleri nin karşılaştırılması", **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 24 (5): 870-878 (2018).
18. Öztemel, E., "Yapay Sinir Ağları", **Papatya Yayıncılık** (2012).
19. Badem, H., "Parkinson hastalığının ses sinyalleri üzerinden makine öğrenmesi teknikleri ile tanımlanması", **Niđe Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, 8 (2): 630-637 (2019).
20. Sundar, A. ve Das, C., "MATLAB analysis of EEG signals for diagnosis of epileptic seizures" <https://www.researchgate.net/publication/280091833> (2015).
21. Shoeibi, A., Ghassemi, N., Khodatars, M., Moridian, P., Alizadehsani, R., Zare, A., ... ve Gorriz, J. M., "Detection of epileptic seizures on EEG signals using ANFIS classifier, autoencoders and fuzzy entropies", **Biomedical Signal Processing and Control**, 73, 103417 (2022).
22. Webster R. G., "Influenza: an emerging disease", **Emerging infectious diseases**, 4 (3): 436-441, <https://doi.org/10.3201/eid0403.980325> (1998).
23. Crawford, P. C., Dubovi, E. J., Castleman, W. L., Stephenson, I., Gibbs, E. P. J., Chen, L., ve Donis, R. O., "Transmission of equine influenza virus to dogs", **Science**, 310 (5747): 482-485 (2005).
24. Dayiođlu, H., Özyurt, M.S., Helvacı, M.R. ve Solak, C.N., "Türkiye’de tavuk vebası (kuş gribi)", **Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, (10): (2006).
25. Dündar, N., "Küresel salgınların makroekonomik etkileri üzerine bir araştırma", **Journal of Social and Humanities Sciences Research**, 7(52): 837-852 (2020).

26. Yılmaz A.Y. ve Mutlu, İ. S., “Salgın sonrası dünyada, küreselleşme ve ulus devlet tartışmaları”, **Üçüncü Sektör Sosyal Ekonomi Dergisi**, 55(3): 1965-1976 (2020).
27. İnternet: HND, “Kuş Gribi Yayılıyor! 500 Binden Fazla Tavuk İtlaf Edildi...”, <https://www.habernediyor.com/dunya/kus-gribi-yayiliyor-500-binden-fazla-tavuk-itlaf-edildi-h49893.html> (2021).
28. Akan, M., “Kümes hayvanlarında kuş gribi”, **Ankara Üniversitesi Veteriner Fakültesi**, 12 (1): 14-21 (2007).
29. İnternet: Uluslararası Ekonomik Sorunlar Dergisi XXII., “Avian Influenza (Kuş Gribi) Hastalığının Türk Ekonomisi Üzerindeki Etkileri”, https://www.mfa.gov.tr/avian-influenza-_kus-gribi_-hastaliginin-turk-ekonomisi-uzerindeki-etkileri-.tr.mfa (2021).
30. Ketrez, G., Şirin, H. ve Hasde, M., “Geçmişten günümüze türkiye’de salgınlar”, **Türkiye Sağlık Okuryazarlığı Dergisi**, 1(2): 98-106 (2020).
31. Pandemik İnfluenza Ulusal Hazırlık Planı, **T.C. Sağlık Bakanlığı Halk Sağlığı Genel Müdürlüğü** (2019).
32. Gülşen, K. ve Kaplan, G., “Crises in the Turkish egg sector and the effect of avian influenza on the sector”, **Journal of Animal Science and Products (JASP)**, 4 (1):1-9 (2021).
33. İnternet: Vargonen Blog, “Python Nedir?”, <https://www.vargonen.com/blog/python-nedir/> (2021).
34. İnternet: TIOBE (the software quality company), “TIOBE Index for September 2018”, www.tiobe.com/tiobe-index_(2021).
35. İnternet: Academy Peak, “Python nedir? Ne işe yarar?”, <https://www.academypeak.com/blog/python-nedir-ne-ise-yarar-17> (2021).
36. İnternet: Bilginç IT Academy, “Python Nedir? Python Hakkında Her Şey”, https://bilginc.com/tr/blog/158/python-nedir-python-hakkinda-hersey_(2021).
37. İnternet: Python, “What is Python? Execute Summary”, <https://www.python.org/doc/essays/blurb/> (2021).
38. İnternet: Kodcular, “Python Neden Bu Kadar Popüler?”, <https://medium.com/kodcular/python-neden-bu-kadar-pop%C3%BCler-d7f0f6819de5> (2021).

39. İnternet: Kerokod, “Python Nedir, Python İle Neler Yapılabilir?”, <https://www.kerokod.com/python-nedir-python-ile-neler-yapilabilir/> (2021).
40. Khoirom, S., Sonia, M., Laikhuram, B., Laishram, J., ve Singh, T. D., " Comparative analysis of Python and Java for beginners", **Int. Res. J. Eng. Technol**, 7(8): 4384-4407 (2020).
41. Kubat, C., “Matlab yapay zeka ve mühendislik uygulamaları”, **Pusula** (2014).
42. Uzunoğlu, M., Kızıl A. ve Onar, Ö.Ç., “Her yönü ile matlab “, **Türkmen Kitabevi** (2003).
43. Yayla, G., “Matlab”, **Kodlab** (2019).
44. Dal, D., “Matlab İle Programlama“, **Ekin Basın Yayın Dağıtım** (2012).
45. Çiçekgil, Z. ve Yazıcı, E., “Türkiye’de tavuk yumurtası mevcut durumu ve üretim öngörüsü “, **Tarım Ekonomisi Araştırmaları Dergisi**, 2 (2): 26-34 (2016).
46. Göger, H., Demirtaş, Ş.E., Yurtoğulları, Ş., Koçanaoğulları, S. ve Akman, N., “Tavukçuluk araştırma enstitüsü’ndeki yumurtacı saf hatların ıslahı ve bunlardan ebeveyn ve hibrit elde etme çalışmaları”, **Tavukçuluk Araştırma Enstitüsü Müdürlüğü** (2016).
47. Eren,A.S. ve Gün,M.S., “Topsis yöntemi ile yeni kurulması planlanan tavuk çiftliği için bazı tavuk ırklarından uygun olanın belirlenmesi: Kahramanmaraş’ta bir alan çalışması”, **Social Sciences Studies Journal**, 2 (2): 1-11 (2016).
48. Cruz-Tirado, J.P., Silva Medeiros, M. L. ve Barbin, D.F., “On-line monitoring of egg freshness using a portable NIR spectrometer in tandem with machine learning”, **Journal of Food Engineering**, 306, 110643 (2021).
49. Zhang, W.,Pan, L., Tu, S., Zhan, G. ve Tu, K., “Non-destructive internal quality assessment of eggs using a synthesis of hyperspectral imaging and multivariate analysis”, **Journal of Food Engineering**, 157: 41-48 (2015).
50. Zhao, J., Lin, H., Chen, Q., Huan, X., Sun, Z. ve Zhou, F., “Identification of egg’s freshness using NIR and support vector data description”, **Journal of Food Engineering**, 98: 408–414 (2010).
51. Avşar, A.A. ve Akpınar, G.Ç., “Sarı tüy rengindeki (Coturnix japonica) bıldırcınlarda farklı yaş ve depolama sürelerinin yumurta kalite özellikleri

- üzerine etkisi”, **Mustafa Kemal Üniversitesi Tarım Bilimleri Dergisi**, 25 (2): 198-210 (2020).
52. Cebeci, Z. ve Yıldız, F., “Unsupervised discretization of continuous variables in a chicken egg quality traits dataset”, **Turkish Journal of Agriculture-Food Science and Technology**, 5 (4): 315-320 (2017).
53. Akkuş, B., "Beyaz ve kahverengi ticari yumurtacı tavuklarda, tavuk yaşı ve kafes katının yumurta iç ve dış kalite parametrelerine etkileri", **Zootekni Anabilim Dalı**, 7 (2): 211-218 (2016).
54. Omkarappa, V.C., Fairoze, M.N., Benakabhat, M.C., Bhave, K. ve Karabasanavar, N., “Study of retail egg supply chain for quality in relation to level of sanitization and farm of origin”, **Turkish Journal of Veterinary and Animal Sciences**, 43: 800-807 (2019).
55. Şentürk, E. ve Aktan, S., “Bıldırcınlarda yumurta ağırlığı ile ak yüksekliği arasındaki ilişkiler ve yaygın kullanılan kalite özelliklerindeki ön kabullerin çeşitli koşullar altındaki geçerliliklerinin araştırılması”, **Journal of Poultry Research**, 17 (2): 80-86 (2020).
56. Karoui, R., Kemps, B., Bamelis, F., De Ketelaere, B., Decuyper, E. ve De Baerdemaeker, J., “Methods to evaluate egg freshness in research and industry: A riview”, **European Food Research and Technology**, 222: 727-732 (2006).
57. Yurtseven, E.P., Şekeroğlu, A., Tainika, B., Duman, M. ve Şentürk, Y.E., “Effect of production system and age on egg quality parameters: a case of niğde province çamardı district, Turkey”, **Turkish Journal of Agriculture - Food Science and Technology**, 9(8): 1407-1412 (2021).
58. Çelikyürek, H., Karakuş, K. ve Kara, M., “Storing and evaluation of the records of livestock enterprises in database”, **Turkish Journal of Agriculture - Food Science and Technology**, 7 (12): 2089-2094 (2019).
59. Abaylı, F. N., “Çiftlik hayvanlarında markör destekli seleksiyon”, **Black Sea Journal of Agriculture** , 1 (3): 94-101 (2018).
60. Daş, H., “Qtl tespiti için hayvanlarda kullanılan populasyonlar ve istatistiksel metodlar”, **Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi**, 4 (2): 270-291 (2015).
61. İnternet: Bilim ve Tekno, “Pedigri Nedir?”, <https://www.bilimvetekno.com/pedigri-nedir/> (2022).
62. Çitli, Ş. ve Ayaz, A., “Pedigri çizimi ve pedigri analizinde temel prensipler”, **Tıbbi Genetik Derneği** (2016).

63. Egan, L. M., Hofmann, R., Barrett, B. A., Ghamkhar, K. ve Hoyos-Villegas, V., "Identification of founding accessions and patterns of relatedness and inbreeding derived from historical pedigree data in a White clover Germplasm collection in New Zealand ", **Lincoln University** (2019).
64. Samuel, A. L., "Some studies in machine learning using the game of checkers", **IBM Journal of research and development**, 3 (3): 210-229 (1959).
65. İnternet: MathWorks, "Machine learning in MATLAB", **<https://www.mathworks.com/help/stats/machine-learning-in-matlab.html>** (2022).
66. Yıldız B. F., "Applying decision tree techniques to classify european football teams", **Journal of Soft Computing and Artificial Intelligence**, 1(2): 86-91 (2020).
67. Kaya, D., Türk, M. ve Kaya., T., "Examining the effect of dimension reduction on eeg signals by knearest neighbors algorithm", **El-Cezerî Journal of Science and Engineering**, 5 (2); 591-595 (2018).
68. Lange, H. ve Sippel, S., "Machine Learning Applications in Hydrology", **Forest-Water Interactions**, 233–257, **https://doi.org/10.1007/978-3-030-26086-6_10** (2020).
69. Boehmke, B. ve Greenwell, B., "Hands-On Machine Learning with R". **In Hands-On Machine Learning with R**, **<https://doi.org/10.1201/9780367816377>** (2019).
70. Cheng, M., Fang, F., Kinouchi, T., Navon, I. M., ve Pain, C. C., "Long leadtime daily and monthly streamflow forecasting using machine learning methods", **Journal of Hydrology**, 125376, **<https://doi.org/10.1016/j.jhydrol.2020.125376>** (2020).
71. Loganathan, P., ve Mahindrakar, A. B., "Intercomparing the robustness of machine learning models in simulation and forecasting of streamflow.", **Journal of Water and Climate Change**, 1-14, **<https://doi.org/10.2166/wcc.2020.365>** (2020).
72. Breiman, L., "Bagging predictors", **Machine learning**, 24 (2): 123-140 (1996).
73. Chen, Y., Zheng, W., Li, W. ve Huang, Y., "Large group activity security risk assessment and risk early warning based on random forest algorithm", **Pattern Recognition Letters**, 144: 1-5 (2021).

74. İnternet: Miraç ÖZTÜRK Business Intelligence Specialist, “Python ile Sınıflandırma Analizleri – Rastgele Orman (Random Forest) Algoritması”, <https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi/> (2020).
75. Akın, P. ve Terzi, Y., “Dengesiz verisetli sağkalım verilerinde cox regresyon ve rastgele orman yöntemlerin karşılaştırılması”, **Veri Bilimi Dergisi**, 3 (1): 21-25 (2020).
76. Şirin, S., “Rastgele orman algoritmaları ile otel özellikleri analizi”, **Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi**, 4 (2): 123-132 (2020).
77. Göktaş, M.E. ve Yağanoğlu, M., “Veri bilimi uygulamalarının hastalık teşhisinde kullanılması: Kalp krizi örneği”, **Journal of Information Systems and Management Research**, 2 (2): 26-32 (2020).
78. Gökçen, A., ve Yeşil, B., “Zero flow rate detection of ultrasonic water meter using machine learning techniques”, **European Journal of Science and Technology**, 26, 477-481 (2021). <https://doi.org/10.31590/ejosat.961090>.
79. Selçuk, H. “Prediction of post-treatment survival expectancy in head & neck cancers by machine learning methods”, **The Journal of Cognitive Systems**, 5 (1): 5-9 (2020).
80. Akyol, K. ve Atila, Ü., "Comparing the effect of under-sampling and over-sampling on traditional machine learning algorithms for epileptic seizure detection", **Academic Platform Journal of Engineering and Science**, 8 (2): 279-285 (2020).
81. Nazman E. Olmuş H., ve Erbaş, S., “Investigating some classification methods to evaluate efficiency results: a case study by using conjoint analysis” **Politeknik Dergisi**, 22 (3): 687-694 (2019).
82. Erdem E. ve Bozkurt F., “A comparison of various supervised machine learning techniques for prostate cancer prediction”, **European Journal of Science and Technology**, (21): 610-620 (2021).
83. Şahingöz, O.K., Çebi, C.B., Bulut, F.S., Fırat, H. ve Karataş, G., “Saldırı tespit sistemlerinde makine öğrenmesi modellerinin karşılaştırılması”, **Erzincan University Journal of Science and Technology**, 12 (3): 1513-1525 (2019).
84. İnternet: Vivek Salunkhe, “Linear Discriminant Analysis”, <https://medium.com/@viveksalunkhe80/linear-discriminant-analysis-2b7bfc409f9b> (2021).

85. Kaya, S. ve Yağanoğlu, M., “Denetimli makine öğrenme algoritmalarının pca ve lda uygulanmasından önce ve sonra performans karşılaştırması için bir örnek: göğüs kanseri tespiti”, **Adiyaman Üniversitesi** (2020).
86. Pearl R., Reed L.J., K. J. F., “The Logistic Curve and the Consensus Count of 1940”, **Science**, 14: 895:901 (1940).
87. Sağbaşı, E.A. ve Ballı, S., “Akıllı telefon sensör verileri ile eylem tanımda lojistik regresyon ve K-NN yöntemlerinin karşılaştırılması”, **International Conference on Engineering Technology and Applied Sciences** (2016).
88. David Dolan Lewis. “Representation and learning in information retrieval”, Doktora Tezi, **University of Massachusetts**, USA. Order Number: UMI Order No. GAX92-19460, <https://dl.acm.org/doi/book/10.5555/143044> (1992)
89. Kaynar, O. Tuna, M. F., Görmez, Y., ve Deveci, M. A., “Makine öğrenmesi modelleriyle müşteri kaybı analizi”, **Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 18 (1): 1-14 (2017).
90. Özdemir, R. ve Turanlı, M., “Comparison of machine learning classification algorithms for purchasing forecast”, **Journal of Life Economics**, 8 (1): 59-68 (2021).
91. Yavuz, Ö.Ç. ve Karaman, E., “Astronomik gözlem kalitesi tahmininde makine öğrenmesi algoritmalarının kullanımı”, **Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi**, 5 (1): 12-19 (2021).
92. Konakoğlu, B., “Çok Katmanlı Algılayıcı Yapay Sinir Ağı ile Jeodezik Elipsoidal Koordinatların (ϕ , λ , h) 3 Boyutlu Global Kartezyen Koordinatlara (X, Y, Z) Dönüşümü”, **Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 10 (3): 702–710 (2020). doi: 10.17714/gumusfenbil.712100.
93. Selvi, O., “Göğüs kanseri teşhisinde farklı makine öğrenmesi tekniklerinin performans karşılaştırılması”, **Avrupa Bilim ve Teknoloji Dergisi**, (16): 176-185 (2019). doi: 10.31590/ejosat.553549.
94. Burukanlı, M., Çıbuk, M. ve Budak Ü., “Saldırı tespiti için makine öğrenme yöntemlerinin karşılaştırmalı analizi”, **Bitlis Eren Üniversitesi Fen Bilimleri Dergisi**, 10 (2): 613-624 (2021).
95. Hussain, H., Benkrid, K. ve Şeker, H., “Novel dynamic partial reconfiguration implementations of the support vector machine classifier on FPGA”, **Turkish Journal of Electrical Engineering & Computer Sciences**, 24 (5): 3371–3387 (2016).

96. Nakagawa, S., Hochin, T., Nomiya, H., Nakanishi, H. ve Shoji, M., "Prediction of unusual plasma discharge by using support vector machine", **Fusion Engineering and Design**, 167: 112360 (2021).
97. Danėnas, P., ve Garšva, G., "Support vector machines and their application in credit risk evaluation process", **Vilnius University** (2010).
98. Peddabachigari, S., Abraham, A., ve Thomas, J. "Intrusion detection systems using decision trees and support vector machines" **International Journal of Applied Science and Computations**, 11(3): 118-134 (2004).
99. Tosunoğlu, F., Hanay, S., Çintaş, E. ve Özyer, B., "Monthly streamflow forecasting using machine learning", **Erzincan University Journal of Science and Technology**, 13 (3): 1242-1251 (2020).
100. Güvenç, E. Çetin, G., ve Koçak, H., "Comparison of K-NN and dnn classifiers performance in predicting mobile phone price ranges", **Advances in Artificial Intelligence Research**, 1 (1): 19-28 (2021).
101. Çavuşoğlu, Ü., Kaçar, S., "Anormal Trafik Tespiti için Veri Madenciliği Algoritmalarının Performans Analizi", **Academic Platform Journal of Engineering and Science**, 7 (2): 205-216 (2019).
102. Meral, B. "Breast cancer data classification using svm, nb and K-NN algorithms", Yüksek Lisans Tezi, **Istanbul Technical University Graduate School of Science**, İstanbul (2019).
103. Sabancı, K. ve Köklü, M., "The classification of eye state by using K-NN and MLP classification models according to the EEG signals", **International Journal of Intelligent Systems and Applications in Engineering**, 3 (4): 127-130 (2015).
104. Çelik, Ö., "A research on machine learning methods and its applications", **Journal of Educational Technology and Online Learning**, 1 (3): 25-40 (2018).
105. Erenler, A., "K-NN ve yapay sinir ağları kullanarak sistem etkinliği ve kalite kaybı tahmini", Yüksek Lisans Tezi, **Çukurova Üniversitesi Fen Bilimleri Enstitüsü**, Adana (2019).
106. Kasım, Ö. "Malicious XSS code detection with decision tree", **Politeknik Dergisi**, 23 (1): 67-72 (2020).
107. Çetinkaya, Z. ve Horasan, F., "Decision trees in large data sets ", **International Journal of Engineering Research and Development**, 13 (1): 140-151 (2021).

108. Ç. Kaya ve O. Yildiz. (2014). "Makine Öğrenmesi Teknikleriyle Saldırı Tespiti: Karşılaştırmalı Analiz", **Marmara Fen Bilimleri. Dergisi.**, c. 3, ss. 89–104, doi: 10.7240/mufbed.24684.
109. Upadyhay, A., Shetty, A., Singh, S. K., ve Siddiqui, Z., "Land use and land cover classification of LISS-III satellite image using KNN and decision tree", **IEEE 3rd International Conference on Computing for Sustainable Global Development**, 1277-1280 (2016).
110. Esmeir, S., ve Markovitch, S., "Anytime learning of decision trees", **Journal of Machine Learning Research**, 8: 891-933 (2007).
111. Utgoff, P. E., "Incremental induction of decision trees", **Machine learning**, 4 (2): 161-186 (1989).
112. Russell, S., and Norvig, P., "Learning decision trees", *Artificial intelligence: A modern approach*, 3rd ed., **Pearson**, New Jersey, 693-706 (2010).
113. Yücesoy, U., "Firmaların finansal kararlarında uyguladıkları finansal karar yöntemleri ve karar ağacı uygulaması", Yüksek Lisans Tezi, **Haliç Üniversitesi Sosyal Bilimler Enstitüsü**, İstanbul, (2014).
114. Ü. Sezer., "Karar Ağaçlarının Birliktelik Kuralları ile İyileştirilmesi", **Kocaeli Üniversitesi** (2008).
115. Haglin, J.M., Jimenez, G. ve Eltorai, A.E.M., "Artificial neural networks in medicine", **Health and Technol**, 9 (1): 1–6 (2019).
116. Mijwel, M.M., "Artificial neural networks advantages and disadvantages", **Computer science, college of science** (2018).
117. Shamshirband, S., Mosavi, A., Rabczuk, T., Nabipour, N. ve Chau, K., "Prediction of significant wave height; comparison between nested grid numerical model, and machine learning models of artificial neural networks, extreme learning and support vector machines", **Engineering Applications Of Computational Fluid Mechanics**, 14 (1): 805-817 (2020).
118. İnternet: Elif YILMAZ, "Yapay Sinir Ağları ile Araç Satışlarının Tahmin Edilmesi", <https://www.veribilimiokulu.com/yapay-sinir-aglari-ile-arac-satislarinin-tahmin-edilmesi/> (2019).
119. Chen, W., Pourghasemi, H. R., Kornejady, A. ve Zhang, N., " Landslide spatial modeling: Introducing new ensembles of ANN, MaxEnt, and SVM machine learning techniques", **Geoderma**, 305: 314-327 (2017).

120. Ateş İ. ve Bilgin, T.T., “The investigation of the success of different machine learning methods in breast cancer diagnosis”, **Konuralp Medical Journal**, 13(2): 347-356 (2021).
121. Cihan, P., Kalıpsız, O. ve Gökçe, E., ”Yeni doğan kuzularda bilgisayar destekli tanı”, **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 26 (2): 385-391 (2020).
122. Brasil, Y. L., Cruz-Tirado, J. P. ve Barbin, D. F., “Fast online estimation of quail eggs freshness using portable NIR spectrometer and machine learning”, **Food Control**, 131 (2022). <https://doi.org/10.1016/j.foodcont.2021.108418>.

ÖZGEÇMİŞ

Kübra ARSLAN ilk ve orta öğrenimini aynı şehirde tamamladı. Lise öğrenimini Adıyaman Bilgi Anadolu Lisesi'nde tamamladı. 2014 yılında Karabük Üniversitesi Mühendislik Fakültesi Biyomedikal Mühendisliği Bölümü'nde öğrenime başlayıp 2019 yılında iyi derece ile mezun oldu.