



**GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK KAYISI
SINIFLANDIRILMASI (SINIFLANDIRMA YÖNTEMLERİNİN
KARŞILAŞTIRILMASI) ve LEKE ANALİZİ**

Hazırlayan: İbrahim Hakkı KADİRHANOĞULLARI

Danışman: Doç. Dr. Köksal KARADAŞ

TARIM BİLİMLERİ ANA BİLİM DALI

DOKTORA TEZİ

IĞDIR/2023

Her Hakkı Saklıdır

T.C.
IĞDIR ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK KAYISI
SINIFLANDIRILMASI (SINIFLANDIRMA YÖNTEMLERİNİN
KARŞILAŞTIRILMASI) ve LEKE ANALİZİ

İbrahim Hakkı KADİRHANOĞULLARI

TARIM BİLİMLERİ ANA BİLİM DALI

IĞDIR/2023

Her Hakkı Saklıdır

TAAHHÜTNAME

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

İbrahim Hakkı KADİRHANOĞULLARI



ÖZET

GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK KAYISI SINIFLANDIRILMASI (SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI) ve LEKE ANALİZİ

KADİRHANOĞULLARI, İbrahim Hakkı

Doktora Tezi

Tarım Bilimleri Ana Bilim Dalı

Danışman: Doç. Dr. Köksal KARADAŞ

Nisan 2023, 90 Sayfa

Meyvelerin depolanmasında ve pazara sunulmasında sınıflandırılması ve leke analizinin yapılması büyük önem taşımaktadır. Genellikle bu işlemler insan gözüyle yapıldığından emek ve zaman kaybı ile birlikte ekonomik olarak da külfet oluşturmaktadır. Teknolojinin gelişmesi ve bilgisayarlı görmenin artması ile bu sorunun üstesinden gelineceği öngörülmektedir.

Bu nedenle tez çalışmasında meyve çeşitlerinden kayısların renk ve boyut özelliklerine göre sınıflandırılması ve leke analizinin yapılması için makine öğrenmesi ve görüntü işleme yöntemleri kullanılarak bir scriptin yazılması amaçlanmıştır. Kayısı çeşitleri olarak Iğdır ilinde yetişen Ağarik, Şalak ve Teberze seçilmiştir. Kayıslar Ağarik, Şalak, Teberze ve Çürük (Ağarik, Şalak ve Teberze karışımı) olarak dört sınıfa ayrılmıştır. Her bir çeşitten 250 örnek olmak üzere toplamda 1000 örnekle çalışma yürütülmüştür. Yapay Sinir Ağları, Naïve Bayes, Destek Vektör Makinaları ve Karar Ağacı sınıflandırma algoritmaları yöntem olarak kullanılmıştır. Laplace, Average, Gaussian, Medyan, Unsharp ve Blurring resim iyileştirme filtreleri denenmiş ve en iyi sonucu veren Medyan Filtresi kullanılmıştır. LoG, Canny, Roberts, Prewitt ve Sobel özellik çıkarma filtreleri denenmiş ve çalışmaya uygunluğu için LoG filtresi seçilmiştir.

Çalışmada algoritma ölçümlerinden doğruluk, duyarlılık, özgüllük, kesinlik ve Fpuanı sonuçlarına bakılmıştır. Dört sınıf kayısının birbirinden ayrı sınıflandırılması özellikle çürüklerin sağlamlardan ayrı sınıflandırılması için algoritmaların duyarlılık sonuçları dikkate alınmıştır. Yapay sinir ağları kayısların sınıflandırılmasında %100 başarı yakalamıştır. Karar Ağacı ile Ağarik Kayısıyı %96,8 Şalak Kayısıyı %93,2 Teberze Kayısıyı %96,8 ve Çürük Kayısıyı %88,4 başarı oranıyla sınıflandırmıştır. Destek Vektör Makinaları Ağarik Kayısıyı %97,2 Şalak Kayısıyı %76,8 Teberze Kayısıyı %97,6 ve Çürük Kayısıyı %58,4 başarı oranıyla sınıflandırmıştır. Naïve Bayes Ağarik Kayısıyı %82, Şalak Kayısıyı %78,4 Teberze Kayısıyı %97,6 ve Çürük Kayısıyı %22,4 başarı oranıyla sınıflandırmıştır.

Çalışma sonuçları değerlendirildiğinde makine öğrenmesi ve görüntü işleme yöntemleri kullanılarak meyvelerde sınıflandırma ve leke analizinin başarılı bir şekilde yapılabileceği tespit edilmiştir.

Anahtar Kelimeler: Sınıflandırma, Leke analizi, Makine öğrenme, Kayısı, Iğdır ili

ABSTRACT

CLASSIFICATION OF APRICOT USING IMAGE PROCESSING TECHNIQUES (COMPARISON OF CLASSIFICATION METHODS) AND STAIN ANALYSIS

KADIRHANOGULLARI, İbrahim Hakkı

Doctoral Thesis

Department of Agricultural Sciences

Advisor: Assoc. Prof. Dr. Köksal KARADAŞ

April 2023, 90 Page

Throughout the phases of storage and marketing, classification and stain analysis of fruits are quite important. As human eyes are typically used to do these tasks, it is clear that there is a financial cost in addition to the loss of labor and time. With the advancement of technology and the spread of computer vision, it is projected that this issue will be solved.

In this thesis, it was aimed to write a script using machine learning and image processing methods to classify apricots, one of the fruit varieties, according to their color and size characteristics and to perform stain analysis. Ağırık, Şalak and Teberze grown in Iğdır province were selected as apricot varieties. Apricots were divided into four classes as Ağırık, Şalak, Teberze and Çürük (a mixture of rotten Ağırık, Şalak, and Teberze varieties). The study was carried out with a total of 1000 samples, 250 from each variety. Artificial Neural Networks, Naïve Bayes, Support Vector Machines, and Decision Tree classification algorithms were used as methods. Laplace, Average, Gaussian, Median, Unsharp, and Blurring image enhancement filters were tried, and the Median filter was used, which gave the best results. LoG, Canny, Roberts, Prewitt, and Sobel feature extraction filters were tested, and the LoG filter was chosen for its suitability to work.

In the study, the results of the algorithmic measurements were examined in terms of accuracy, sensitivity, specificity, precision, and F-score. The sensitivity results of the algorithms were considered for the classification of the four apricot classes separately from each other, especially for the classification of caries from healthy ones. Artificial neural networks have achieved 100% success in the classification of apricots. Ağırık Apricots received a success percentage of 96,8%, Şalak Apricots 93,2%, Teberze Apricots 96,8%, and Rotten Apricots 88,4% from Decision Tree. Teberze Apricots were classified by Support Vector Machines with a success rate of 97,6%, Rotten Apricots with a success rate of 58,4%, Şalak Apricots with a success rate of 76,8%, and Ağırık Apricots with a success rate of 97,2%. The success rates attributed by Naïve Bayes to Ağırık Apricots, Şalak Apricots, Teberze Apricots, and Rotten Apricots were 82%, 78,4%, 97,6% and 22,4%, respectively.

According to the study's findings, classification and stain analysis of fruits utilizing machine learning and image processing techniques can be achieved successfully.

Keywords: Classification, Stain analysis, Machine learning, Apricot, Iğdır province

ÖNSÖZ ve TEŞEKKÜR

Iğdır Üniversitesi Lisansüstü Enstitüsü Tarım Bilimleri Anabilim Dalında doktora tezi olarak hazırlanan bu çalışmada görüntü işleme teknikleri kullanarak Ağarik, Şalak, Teberze ve Çürük (Ağarik, Şalak ve Teberze karışımı) kayısların sınıflandırılması ve leke analizi yapılarak kayısların toplanması ve depolanmasında emek ve zaman kaybının önüne geçilerek ekonomik katkı sağlanması amaçlanmıştır.

Tez çalışmamda bana gösterdikleri desteklerden dolayı, çalışmalarında yardımlarını esirgemeyen danışman hocam Doç. Dr. Köksal KARADAŞ'a ve desteklerinden dolayı Dr. Öğr. Üyesi Mehmet Kazım KARA, Dr. Öğr. Üyesi Akif KURT ve Öğr. Gör. Alper GÜLBE'ye teşekkürlerimi sunarım. Beni hep destekleyen, yanımda olan ve hiçbir zaman yokluğunu hissettirmeyen sevgili eşim Dr. Öğr. Üyesi Meryem KONU KADİRHANOĞULLARI'na, kızım Hümeyraya, oğlum Abdulhamid'e sonsuz teşekkür ederim. Ayrıca eğitim yaşantım boyunca desteklerini hep kalbimde hissettiğim babam Muzaffer KADİRHANOĞULLARI'na, annem Gülcihan KADİRHANOĞULLARI'na ve kardeşlerime minnetlerimi ve sevgilerimi sunarım.

İbrahim Hakkı KADİRHANOĞULLARI

IĞDIR/2023

İÇİNDEKİLER

Sayfa No

ÖZET.....	i
ABSTRACT	ii
ÖNSÖZ ve TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	13
2.1. Görüntü işleme çalışmaları	13
2.2 Kayısı Çalışmaları.....	22
3. MATERYAL ve YÖNTEM.....	27
3.1. Materyal	27
3.2. Yöntem.....	30
3.2.1 Confusion (Çapraşıklık) Matrisi	34
3.2.2. VOSviewer programı	35
4. BULGULAR.....	36
4.1 Giriş ve Hedef Matrislerinin Oluşturulması.....	36
4.2 Kullanılan Filtrelere Ait Sonuçlar.....	39
4.2.1 İyileştirme filtrelerine ait sonuçlar	39
4.2.2 Özellik Çıkarma Filtreleri	43
4.2.3 Sınıflandırma algoritmalarına ait sonuçlar.....	43
4.2.3.1 Karar Ağacı sınıflandırmasına ait sonuçlar.....	43
4.2.3.2. Naïve Bayes sınıflandırmasına ait sonuçlar	47
4.2.3.3. Destek vektör makinaları algoritması	50
4.2.3.4. Yapay sinir ağı algoritmasına ait sonuçlar	53
4.3 Tartışma.....	59
5. SONUÇ ve ÖNERİLER.....	64

KAYNAKLAR	65
EKLER.....	77
ÖZGEÇMİŞ.....	90



SİMGELER ve KISALTMALAR DİZİNİ

\$	Dolar
%	Yüzde
AL	Robotik ve yapay zekâ
ARIMA	Otoregresif hareketli ortalamalar (autoregressive integrated moving average)
ark	arkadaşları
C	Santigrat Derece
CaRT	Sınıflandırma ve Regresyon Ağacı (Classification and Regression Tree)
CCD	Yüklenme iştirilmiş araç (Charge coupled device)
CVM	Bilgisayarlı görme yöntemi (Computer Vision Method)
Da	Dekar
FAO	Gıda ve Tarım Örgütü (Food and Agriculture Organization of the United Nations)
İHA/ UAV	İnsansız hava aracı (Unmanned Aerial Vehicles)
Kg	Kilogram
m	metre
Matlab	Matrix Laboratory
mm	milimetre
MSE	Hata karelerinin ortalaması (Mean Squared Error)
NB	(Naïve Bayes)
R²	Regresyon Karesi
RGB	Kırmızı-yeşil-mavi renk modeli (Red Green Blue)
SVM	Destek Vektör Makinaları (Secure Virtual Machine)
TÜİK	Türkiye İstatistik Kurumu
vb	ve benzeri
ve ark	ve arkadaşları
YSA/ANN	Yapay Sinir Ağları (Artificial Neural Network)

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1.1. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları	6
Şekil 1.2. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları zaman trendi.....	7
Şekil 1.3. Çalışmalarda Kullanılan Anahtar kelimeler	9
Şekil 1.4. Çalışmalarda Kullanılan Anahtar kelimelerin Zaman Trendi	10
Şekil 3.1. Materyal olarak kullanılan kayısı çeşitleri.....	27
Şekil 3.2. Kayısı toplama fotoğrafları.....	28
Şekil 3.3. Puluz 2 Üst Led Işıklı Çekim Çadırı.....	28
Şekil 3.4. Kayısı fotoğraf çekim örnekleri.....	29
Şekil 3.5. Projede kullanılan fotoğraf makinası, lens ve tripod	30
Şekil 4.1 Normalleştirme, kırpma ve küçültme işlemi uygulanan Ağırık kayısı.....	37
Şekil 4.2. Normalleştirme, kırpma ve küçültme işlemi uygulanan Şalak kayısı.....	37
Şekil 4.3. Normalleştirme, kırpma ve küçültme işlemi uygulanan Teberze kayısı.....	38
Şekil 4.4. Normalleştirme, kırpma ve küçültme işlemi uygulanan Çürük kayısı.....	38
Şekil 4.5. Ağırık iyileştirme filtrelerinin uygulama örnekleri.....	39
Şekil 4.6. Şalak iyileştirme filtrelerinin uygulama örnekleri	40
Şekil 4.7. Teberze iyileştirme filtrelerinin uygulama örnekleri	41
Şekil 4.8. Çürük iyileştirme filtrelerinin uygulama örnekleri.....	42
Şekil 4.9. CRT Çapraşıklık (Confusion) Matrisi (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük)	43
Şekil 4.10. CRT Kayısı Tanıma Grafiği	45
Şekil 4.11. CRT Saçılım (Scatter) Grafiği	46
Şekil 4.12. Naïve Bayes Sınıflandırmasına Ait Çapraşıklık (Confusion) Matrisi (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük)	47
Şekil 4.13 Naïve Naïve Bayes Sınıflandırmasına Ait Saçılım (Scatter) Grafiği	49
Şekil 4.14. Destek Vektör Makinaları Algoritmasına Ait Çapraşıklık (Confusion) Matrisi (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük).....	50
Şekil 4.15. Destek Vektör Makinaları Algoritmasına Ait Saçılım (Scatter) Grafiği	52
Şekil 4.16. Yapay Sinir Ağı Algoritmasına Ait Training Algoritma Görseli	53
Şekil 4.17. Desen tanıma ve sınıflandırmaya ait ağ diyagramı.....	54

Şekil 4.18 YSA’ya ait eğitim-performans eğrileri.....	55
Şekil 4.19. Yapay Sinir Ağları (YSA) Çapraşıklık (Confusion) Matrisleri (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük)	56
Şekil 4.20 YSA Hata Histogramı.....	57
Şekil 4.21. Oluşturulan YSA ait eğitim, doğrulama, test ve çapraşıklık matrislerinin ROC Eğrileri.....	58
Şekil 4.22. YSA eğitim durumu, training phase ve kayıplar grafiği.....	59



ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 1.1. Ülkelere göre 2021 kayısı üretim miktarı*	2
Çizelge 1.2. Ülkelere göre 2021 kayısı ithalat miktarı ve ithalat gideri*	2
Çizelge 1.3. Ülkelere göre 2021 kayısı ihracat miktarı ve ihracat geliri*	3
Çizelge 1.4. İllere göre 2022 kayısı üretimi (Türkiye)*	3
Çizelge 1.5. Türkiye 2021 kayısı ithalat ve ihracat miktarı*	4
Çizelge 1.6. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları	5
Çizelge 1.7. En çok kullanılan anahtar kelimeler	8
Çizelge 3.1. Araştırmada kullanılan fotoğraf makinasına ait teknik özellikler	29
Çizelge 3.2. Araştırmada kullanılan lense ait teknik özellikler	29
Çizelge 3.3. Araştırmada kullanılan faktörler	30
Çizelge 3.4. Araştırmada kullanılan resim iyileştirme filtreleri ve temel fonksiyonları*	31
Çizelge 3.5. Özellik çıkarma işleminde kullanılan filtreler ve temel fonksiyonları*	32
Çizelge 3.6. Yorumlama işleminde kullanılan sınıflandırıcılar ve çalışma prensipleri*	32
Çizelge 3.7. Bir Çapraşıklık Matrisinin terminolojisi ve türevleri	35
Çizelge 4.1. Karar Ağacı sınıflandırmasına ait algoritma sonuçlar	44
Çizelge 4.2. Naïve Bayes sınıflandırmasına ait algoritma sonuçları	47
Çizelge 4.3. Destek Vektör Makinaları algoritma sonuçları	50
Çizelge 4.4. Yapay Sinir Ağlarına ait algoritma sonuçları	56
Çizelge 4.5. Sınıflandırma Algoritmaların Sonuçları	60

1. GİRİŞ

İnsanoğlunun yaşamına yön veren iki önemli faktörden biri tarım diğeri ise sanayi devrimi olarak adlandırılmaktadır. Yakın zamanda bilgi çağı da bu faktörlere eklenen değişkenler arasında sayılmaktadır (Direk, 2012; Yenigül, 2016). MÖ. 8000 yılı civarında gerçekleştiği kabul edilen Tarım Devrimi, ilk zamanlarda avcı-toplayıcı ve göçebe bir hayat süren insanoğlunun yerleşik hayata başlangıcının ilk evreleri olarak kabul edilmektedir (Günay, 2002; Durukhan, 2006; Yenigül, 2016; Gül, 2021).

Yerleşik hayatta bitkilerin ve hayvanların düzenli bir şekilde ehlileştirilmesiyle birlikte (Gül, 2021), insanoğlunun bu evrelerde fazlalaşan tarımsal faaliyetleri ihtiyacından fazlasını üretmeye başladığı ilk zamanlar olarak kabul edilmektedir. İhtiyaç fazlası olan bu tarımsal ürünler değerli bir emtia karşılığında el değiştirerek ekonomik anlamda ilk gelişmelerin yaşandığı zamanlar olarak da öne çıkmaktadır (Durukhan, 2006).

Tarım diğer sektörlere oranla getirisi düşük, uzun vadede gelir sağlayan ve riski büyük olmasına rağmen (Noyan, 2016) beslenme için gerekli gıda maddelerini üretmesi, sermaye, istihdam ve ekonomiye döviz girdisi ve sanayiye hammadde sağlaması gibi katkılarından dolayı dünyanın hemen her yerinde özel önem verilen bir sektör haline gelmiştir (Doğan, 2009). Literatüre bakıldığında, tarım sektörü ile ekonomik büyüme arasındaki bir ilişki göze çarpmaktadır (Gallup ve ark., 1997; Thirtle, Lin ve Piesse, 2003; Awokuse, 2008; Irz ve ark., 2001; Odetola and Etumnu, 2013). Sebze ve meyve yetiştiriciliği ekonomik kalkınmaya önemli katkıları bulunan tarım sektörünün alt dallarından biri olup bu alanda kayısı üreticiliği önemli bir tarım alanı olarak görülmektedir. (Johnson, 1993; Yavuz, 2005; Anonim, 2023b)

Kayısı (*Prunus armeniaca L.*), aşılama yöntemiyle üretilen bir zerdali (yabani kayısı) türüdür (Pektekin, 1994; Gezer ve ark., 2003). İnsan beslenmesinde önemli bir yere sahip olan kayısı, taze, kurutulmuş olarak veya işlenerek değerlendirilebilmekte ve çekirdekleri yağ, benzaldehit, kozmetik, aktif karbon ve aroma parfüm üretiminde kullanılmaktadır (Yıldız, 1994)

Anavatanı Orta Asya, Batı Çin ve İran-Kafkasya olarak bilinen kayısının (*Prunus armeniaca L.*) Anadolu'nun verimli topraklarında yaklaşık 2500 yıldan beri tarımı yapılmaktadır (Asma, 2000). İnsan sağlığı ve beslenmesi bakımından önemli bir yere sahip olan kayısı, Dünyada ve Türkiye'de önemli düzeylerde talep görmektedir.

FAO 2021 yılı verilerine göre kayısı üretiminde miktar bakımından ilk sırada Türkiye (800.00 ton) verim bakımından ise Özbekistan (1.173,06 da/kg) yer almaktadırlar (Çizelge 1.1.)

Çizelge 1.1. Ülkelere göre 2021 kayısı üretim miktarı*

Ülkeler	Üretim (Ton)	Miktarı (da)	Hasat Edilen Alan (da)	Verim (da/kg)
Türkiye	800.000		1.348.790	593,12
Özbekistan	424.734		362.080	1.173,06
İran	323.019		603.070	535,63
Cezayir	189.724		271.850	697,91
İtalya	189.570		177.400	973,50
Afganistan	113.659		151.990	747,79
İspanya	114.720		194.400	590,12
Yunanistan	76.270		89.600	851,23
Dünya Toplam	3.578.412		5.518.740	648,41

*Anonim, 2022a

FAO 2021 kayısı ithalat miktarı ve ithalat giderlerine bakıldığında (Çizelge 1.2.) Rusya 2021 yılında 49.506 ton kayısı ithalat miktarı ve Almanya 111.781.000 \$ kayısı ithalat harcaması ile ilk sırada yer almıştır.

Çizelge 1.2. Ülkelere göre 2021 kayısı ithalat miktarı ve ithalat gideri*

	İthalat Miktarı (Ton)	İthalat Gideri (1000 US\$)
Rusya	49.506	55.841
Almanya	47.124	111.781
Kazakistan	34.000	23.300
Fransa	18.823	37.437
Irak	17.320	8.574
İtalya	14.315	21.323
Avusturya	11.931	26.882
İçviçre	10.371	31.397
Pakistan	10.092	2.925
Sudi Arabistan	9.138	10.302
Dünya Toplam	320.692	506.814

*Anonim, 2022a

FAO 2021 verilerine göre dünyada İspanya 89.520 ton kayısı ihracat miktarı ve 184.243.000 \$ kayısı ihracat geliri ile ilk sırada yer alırken Türkiye 69.912 ton ihracat miktarı ile 61.818.000 \$ ihracat geliri ile ikinci sırada yer almaktadır.

Çizelge 1.3. Ülkelere göre 2021 kayısı ihracat miktarı ve ihracat geliri*

	İhracat Miktarı (Ton)	İhracat Geliri (1000 US\$)
İspanya	89.520	184.243
Türkiye	69.912	61.818
İtalya	31.026	65.865
Yunanistan	15.081	18.812
Fransa	13.897	37.273
Ürdün	11.320	25.042
Afganistan	10.690	3.301
Kazakistan	9.640	1.625
Dünya Toplam	317.487	495.038

*Anonim, 2022a

TÜİK 2022 verilerine göre Türkiye’de 1.418.513 dekar arazide toplam 803.000 ton ve ortalama 42 kg/ağaç başı kayısı üretimi elde edilmiştir. 2022 yılı itibarı ile Türkiye’de kayısı üretim miktarında Malatya (303.756 ton) üretim alanında Elâzığ (105.897 dekar) ve ağaç başı verimde ise ilk sırayı (139 kg) almıştır (Çizelge 1.4.).

Çizelge 1.4. İllere göre 2022 kayısı üretimi (Türkiye)*

İller	Üretim Miktarı (Ton)	Hasat Edilen Alan (Dekar)	Kg/Meyve Veren Ağaç
Malatya	303.756	877.908	38
Mersin	164.391	100.349	62
Iğdır	40.844	40.550	139
Elâzığ	29.186	105.897	27
Isparta	29.117	26.227	50
Hatay	56.797	30.095	49
Antalya	17.380	18.240	30
Kahramanmaraş	53.992	104.632	33
Türkiye Toplam	803.000	1.418.513	42

*Anonim, 2023b

Türkiye 2020-2021 yılları üretim sezonunda (Çizelge 1.5.) 13.373 ton kayısı ithal etmiş ve bunun 5.895’ini AB ülkelerinden gerçekleştirmiştir. Aynı yıl 503.431 ton ihracat yapmış ve bu miktarın 152.105 tonunu AB ülkelerine gerçekleştirmiştir. Ayrıca Türkiye’de kişi başı kayısı tüketimi yıllık 2,3 kg olarak belirlenmiştir.

Çizelge 1.5. Türkiye 2021 kayısı ithalat ve ihracat miktarı*

	2018-2019	2019-2020	2020-2021
İthalat (Ton)	10.503	3.741	13.373
AB- İthalat (Ton)	6.770	1.953	5.895
İhracat (Ton)	546.431	533.655	503.431
AB-İhracat (Ton)	181.705	167.404	152.105
Kişi Başı Tüketim/kg	2,4	2,3	2,3


*Anonim, 2023b

Dünyanın değişik iklim koşullarında yetişebilen, besin maddelerince zengin, ihracat ve ithalatı yapılarak ekonomik gelir sağlayan kayısı; literatüre de yoğun bir şekilde konu olmaktadır. Kayısı ile ilgili akademik anlamda yapılan çalışmalar incelenirse, üretim, tüketim, ihracat, ithalat, ekonomik karlılık ve sağlıktan tutunda kozmetiğe varıncaya kadar akademik eğilimin ne tarafa olduğu bilinebilir. Böylelikle devasa verilerden kayısı ile ilgili hem bilgi birikimi elde edilir hem sonraki çalışmalara ışık tutar. Bu nedenle çalışmada kayısı ile ilgili yapılan araştırmaların incelenmesi ve eğilimlerin belirlenmesi için bibliyometrik ağ analizi yapılmıştır. Araştırmada bibliyometrik ağ analizinin kullanılmasının bir diğer nedeni de bilimsel araştırmanın belirli konular, dergiler, yazarlar, kurumlar veya ülkeler arasındaki ilişkilerin görselleştirilerek belirlenmesidir (Van Eck ve Waltman, 2010). Bu çalışmada yayınların bibliyometrik analizi için VOSviewer v.1.61 (Centre for Science and Technology Studies) programı kullanılmıştır.

İlk önce Scopus veri tabanında, başlığında kayısı kelimesi bulunan zirai ve biyolojik bilimler alanında makaleler taranmış ve toplamda 1931 adet veri indirilmiştir. Raporların ülke analizi yapılarak mekânsal dağılımı ortaya çıkarılmıştır. Elde edilen verilere göre 89 ülkenin bu alanda çalışması bulunmaktadır. Fakat asgari olarak 10 belge yayınlama kriterini 32 ülkenin sağladığı gözlemlenmiştir (Çizelge 1.6.). Otuziki ülkenin her biri için, diğer ülkelerle olan ortak yazarlık bağlantılarının toplam gücü hesaplanmıştır. Ayrıca, ülke bazında belgelerin toplam atıfları ve bağlantı güçleri verilmiştir.

Çizelge 1.6. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları


Country	Documents	Citations	Total Link Strength
China	348	3.760	1.109
Turkey	282	6.798	1.416
Spain	248	8.194	2.083
Italy	154	3.239	1.203
United States	147	3.372	1.097
France	111	3.763	1.430
India	107	1.051	497
Japan	100	1.586	208
Iran	72	954	292
Australia	61	856	199
Hungary	51	775	413
Serbia	44	407	310
Czech Republic	41	695	392
New Zealand	40	606	162
Pakistan	35	385	264
Germany	31	1108	240
Tunisia	30	456	402
Egypt	26	334	121
South Korea	25	153	39
Greece	23	687	281
Canada	20	452	62
Algeria	19	273	191
Austria	19	245	106
Morocco	19	326	403
Israel	15	359	76
Romania	14	69	55
Russian Federation	14	24	10
Slovakia	14	60	32
Switzerland	12	357	146
Poland	11	125	38
Chile	10	272	142
Iraq	10	22	11



Şekil 1.1. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları

Ülkeler düğümlerle temsil edildiği ve diğerlerine oranla büyük olan düğümlerin daha fazla sayıda yayın ürettiği Şekil 1.1’de gösterilmektedir. Düğümleri birbirine bağlayan bağlantılar ülkeler arasındaki hatları ifade etmektedir. Buna göre Çin 348 yayın ile ilk sırada, Türkiye 282 yayın ile ikinci sırada ve İspanya 248 yayın ile üçüncü sırada yer almaktadır. Atıf oranına baktığımızda İspanya 8.194 atıf ile ilk sırada, Türkiye 6.798 atıf ile ikinci sırada ve Çin 3.760 atıf ile üçüncü sırada yer almaktadır (Çizelge 1.6.).

Ülkelerin atıfları 8 küme başlığında toplanmıştır. Türkiye’nin bulunduğu küme (yeşil küme) Mısır, Hindistan, Hollanda, Pakistan, Suudi Arabistan, Birleşik Krallık, Slovakya ve Hırvatistan ile eşleştiği yani bu ülkeler ile sürekli bağ kurduğu, atıf yaptığı ve çalışmalarını yürüttüğü görülmektedir (Şekil 1.1.).



Şekil 1.2. Ortak yazarlık ve atıf alanında ülkelerin kayısı çalışmaları zaman trendi

Zaman trendine baktığımızda (Şekil 1.2.), Çin, Hindistan, İran ve Pakistan başta olmak üzere şekilde sarı renk ile gözüken diğer ülkeler 2015 yılı az öncesi ve sonrasında çalışmalara ağırlık verdiği görülmektedir. Türkiye ise açık yeşil görünümüyle 2010 yılı az öncesi ve sonrası çalışmalar yaptığı yani çalışmalarının bu yıllarda kümelendiği görülmektedir. Aslında bu bir bakıma endişe verici olabilir. Çünkü çalışmaları güncel tutmak ve güncel teknolojik kaynaklardan faydalananarak kayısı araştırmaları yapmak her bakımdan pozitif gelişim sağlayacağı aşîkârdır.

Araştırmaların kritik noktalarından biri de anahtar kelimelerdir. He (1999), anahtar kelime analizinin bir bilgi parçasıyla ilgili araştırma sınırlarının gelişimini ve ilerlemesini gösterebileceğini vurgulamıştır. Bu doğrultuda anahtar kelime analizi yapılarak çekirdek anahtar kelimeler ortaya çıkarılmıştır. Analiz ile ilgili olarak, bir anahtar kelimenin minimum tekrarı olarak 20 anahtar kelime kabul edilmiş ve toplam 3.981 anahtar kelimeden 31 anahtar kelimenin bu şartı sağladığı Çizelge 7’de gösterilmiştir. 31 anahtar kelimenin her bir anahtar kelimesi için, diğer anahtar kelimelerle birlikte oluşum bağlantılarının toplam gücü de hesaplanmıştır. Bu nedenle,


daha fazla ağ analizi için en yüksek toplam bağlantı gücüne sahip anahtar kelimeler seçilmiştir (Çizelge 1.7.). Anahtar kelime analizi için VOSviewer ile oluşturulan örnek görselleştirmeler Şekil 1.3'te gösterilmektedir.

Çizelge 1.7. En çok kullanılan anahtar kelimeler

Keyword	Occurrences	Total Link Strength
Apricot	479	326
Prunus Armeniaca	220	186
Prunus Armeniaca L.	80	54
Fruit Quality	72	106
Prunus Armeniaca L	55	34
Apricots	49	23
Japanese Apricot	45	18
Genetic Diversity	44	47
Breeding	39	59
Quality	38	43
Storage	36	37
Prunus	35	29
Ethylene	28	32
Antioxidant Activity	27	29
Dormancy	27	24
Amygdalin	25	9
Phenolic Compounds	25	32
Ripening	25	46
Yield	25	31
Carotenoids	24	31
Prunus Mume	24	7
Self-Incompatibility	24	29
Antioxidant Capacity	23	26


Color	23	34
B-Carotene	22	36
Hplc	21	31
Peach	21	25
Plum Pox Virus	21	27
Dried Apricots	20	14
Firmness	20	28
Fruit Breeding	20	35

Anahtar kelimeler düğümlerle temsil edilmekte ve diğerlerine oranla büyük olan düğümler daha fazla kullanıldığını göstermektedir. Bağlantılar anahtar kelimeleri arasındaki hatları ifade etmektedir. Buna göre Apricot (Kayısı) 479 kere kullanılmış ve 326 bağlantı gücüne sahip olarak ilk sırada yer almaktadır. Prunus Armeniaca (Ermenistan Eriği veya kayısı) olarak 220 defa kullanılarak ve 186 bağlantı gücüne sahip olarak ikinci sırada yer almaktadır (Çizelge 1.7.).



Şekil 1.3. Çalışmalarda kullanılan anahtar kelimeler

Anahtar kelimelerin birbiriyle olan bağlantıları 5 kümeden oluşmaktadır. Apricot (Kayısı) anahtar kelimesi (mavi renk) en çok kullanılan olarak görülmektedir (Şekil 1.3.). Ardından Prunus Armeniaca (Ermenistan Eriği veya kayısı) anahtar kelimesi (sarı renk) gelmektedir.



Şekil 1.4. Çalışmalarda kullanılan anahtar kelimelerin zaman trendi

Zaman trendine baktığımızda (Şekil 1.4.), Prunus Armeniaca (Ermenistan Eriği veya kayısı) anahtar kelimesi 2008 yılları civarında kullanıldığı ve sonrasında kabuk değiştiği görülmektedir. Bunun nedeni olarak kayısının anavatanının Ermenistan olduğu yanlışını düşüldüğü gösterilebilir. Fakat kayısının anavatanının Ermenistan olmadığı yazarlar tarafından ifade edilmiştir (Aubert ve Chanforan, 2007; Martinez-Mora ve ark., 2009; Asma, 2011). Apricot (Kayısı) anahtar kelimesi 2012 yılları civarında kullanıldığı görülmektedir. Fakat 2016 yılı civarı ve sonrasında artık farklı anahtar kelimeler yer almıştır. Bunlar Antioxidant Capacity (Antioksidan Kapasite), Antioxidant Activity (Antioksidan Aktivite), Phenolic Compounds (Fenolik Bileşikler) ve Carotenoids (karotenoidler) anahtar kelimeleridir. Buradan araştırmaların daha çok kimya dalına yöneldiği görülmektedir. Bununda nedeni kayısı çekirdeğinin kozmetik, aktif karbon ve aroma parfüm üretiminde kullanımı (Yıldız, 1994) söylenebilir.

Günümüzde iletişim teknolojileri ve bilginin hızla gelişmesiyle beraber toplanan verinin miktarı giderek artış göstermektedir. Böylelikle meydana çıkan devasa veriden yararlanabilmek için verilerin amaca uygun bir şekilde toplanılması ve anlamlı

kullanılabilir bilgilere dönüştürülmeleri gerekmektedir. Bu süreçte görüntü işleme algoritmaları, yapay zekâ, veri madenciliği, veri ambarı, yönetim bilişim sistemleri ve karar destek sistemleri gibi yöntemlerin kullanımı oldukça önemlidir (Sucu, 2020).

Görüntü işleme; kaydedilmiş veya ölçülmüş sayısal görüntülerden meydana gelen verilerin, dijital ortamda belli bir gayeye uygun biçimde değerlendirilebilmesini sağlayan çalışmalar bütünüdür. Görüntü işleme, var olan resim ve grafiklerin değiştirilmesi, yabancılaştırılması ya da iyileştirilmesi için yapılan bir işlemdir. (Yılmaz, 2007; Erkan, 2015)

Çalışmada kullanılan görüntü işleme yöntemi; uygulamaları kullanımına örnek olarak sağlık, tasarım, eğitim, jeolojik araştırmalar, tarım faaliyetleri vb. gösterilebilir (Santaş ve Gülesin; Solak ve Altınışik, 2011).

Bilgisayarlı görme yani görüntü işlemenin yaygınlaşması sonucunda, tarım alanında ürün kalitesinin gözlenmesi (Wu ve Sun, 2013), ürün sulama (Hof and Wolf, 2014), yabancı ot tespiti ilaçlama, hasat, ürün sınıflandırma, ürün gelişimlerinin gözlenmesi gibi çalışmalar yapılmaktadır (Latha ve ark., 2014; Solak ve Altınışik, 2018). Görüntü işleme özelliklerin belirlenmesinde sayısal görüntü analizi ve sınıflandırma gibi yöntemler kullanılarak, araştırılan nesnelerin cins, renk, boyut ya da kalite bakımından sınıflandırılması gerçekleştirilebilmektedir (Özyörük ve Güleriyüz, 1992; Muradoğlu ve ark., 2011; Altıkat ve Temiz, 2019; Domaç Yaşar, 2022).

Iğdır ili 38.540 dekar arazide 42.989 ton kayısı üretimi yaparak Türkiye kayısı üretiminde üçüncü sırada yer almaktadır. Ağaç başına verimi ise Türkiye ortalamasının (42 kg) yaklaşık dört (139 kg) katıdır (Anonim, 2023b). Türkiye ekonomisine bu derece katkı sağlayan Iğdır Kayısının en az zararla toplanması, taşınması, ihraç edilmesi veya depolanması için bilgi çağının teknolojilerinden faydalanmak gerekmektedir. Görüntü işleme, sayısal görüntü analizi ve sınıflandırma gibi yöntemlerden faydalanarak hızlı, masrafı az ve güvenilir sonuçlar elde ederek bilgi çağına ayak uydurmak kaçınılmaz hale gelmiştir. Çünkü kayısı hasat dönemi ve yöntemleri farklılık göstermektedir.

Kayısı için en uygun hasat yöntemi el ile yapılan hasattır. El ile yapılan hasatta meyveler kirlenmez ve zedelenmez (Anonim, 2022b). Aksi takdirde direk toprak yüzeyine düşürülerek yapılan hasatta, meyveler yere düşerken ezilip patlamakta, hızla düşen meyvelerin içerisine toprak ve taş parçaları girmektedir. Kayısı meyvelerin tümü

ağaç üzerinde aynı zamanda olgunlaşmadığından, hasat kademeli olarak da yapılmaktadır. Ağaçlarda önce üst dallardaki meyveler, sonra orta dallardaki, en son ise alt dallardaki meyveler olgunlaşır. Hasat bu olgunlaşma sırasına göre normal olarak 3 defada yapılmaktadır (Anonim, 2022c). Eğer bu yöntemler izlenmezse zedelenen ya da aşırı olgunlaşmış ve bozulmaya yüz tutmuş kayısılar sağlam kayısılar ile birlikte toplandığında zedelenen kayısılar zedelenmeyenleri de etkileyeceğinden toplama işleminde, ihracatında veya depolara aktarımında problemlere neden olmakta, kayısının kalitesini ve ekonomik değerini düşürmektedir. Kalite sınıflandırması zedelenen kayısıların zedelenmeyenlerden ayırma işlemidir. Bu çalışmada leke analizi yapılarak zedelenen kayısıları diğerlerinden ayırmak (kalite sınıflandırması) amaçlanmıştır. Leke analizi ile bozulmalar (Kayısı klimakterik -koparıldıktan sonra olgunlaşması devam eden meyve türlerinden olması (Varlı Yunusoğlu ve ark., 2021) ve çabuk bozulan bir yapıya sahip olması nedeniyle depoda bekleme süresi azalmaktadır.) erken tespit edileceğinden ekonomik olarak da büyük katkı sağlayacaktır. Ertürk ve ark., (2016) Iğdır ilinde üretilen kayısıların büyük bir kısmının yaş olarak pazarlandığını ifade etmişlerdir. Yaş olarak pazarlanan kayısıların toplanırken zedelenmiş olanların ayrılması diğer sağlam kayılara da zarar vereceğinden zedelenmiş kayısıların erken tespiti ve bu tespitin gözlem yoluyla değil de teknolojik olarak yapılması kayısıların ömrünü uzatacağından ve kayısı miktarını çok fazla düşürmeyeceğinden ekonomik faydayı optimum yapacağı tahmin edilmektedir.

Iğdır'da kayısı hasadında herhangi bir sınıflandırıcı sistemden yararlanılmamaktadır. Bu işlem tamamen gözlem yolu ile yapılmakta olup zaman ve emeğin yoğun bir şekilde kullanılmasına neden olmaktadır. Ayrıca bu şekilde yapılan sınıflandırmada hata payı da oldukça yüksektir.

Bu kapsamda Iğdır ilinde üretimi yapılmakta olan; kayısı meyvesinin Şalak, Teberze ve Ağelik çeşitlerinde zedelenme ve kalite sınıflandırması yaparak görüntü işleme konusunda filtreleme ve sınıflandırıcılardan oluşan en iyi kombinasyonları elde etmek ve kayısıların bahçelerde toplama işleminde, ihracatında veya depolara aktarımında insanlar tarafından yapılan emek ve gözlemler yerine görüntü işleme tekniği kullanılarak yapay zekâ ile daha hızlı, daha az masraflı ve daha güvenilir sonuçlar elde etmek için bir script yazılması çalışmanın amacını oluşturmaktadır.

2. KAYNAK ÖZETLERİ

2.1. Görüntü işleme çalışmaları

Babalık ve Botsalı (2010), “Yapay sinir ağı ve görüntü işleme teknikleri kullanarak durum buğdayının camsılığının belirlenmesi” adlı çalışmalarında Çeşit-1252 türü durum buğdayının camsı ve camsı olmayan danelerinin görüntü işleme teknikleri ve yapay sinir ağı kullanılarak sınıflandırılmasını amaçlamışlardır. Çalışmalarında öz düzenlemeli harita ve çok katmanlı algılayıcı sinir ağı modelleri kullanmışlar ve çalışma sonucunda üretilen sistemin hızlı ve başarılı bir sistem olduğunu ifade etmişlerdir.

Ağın ve Malaslı (2016), “Görüntü İşleme Tekniklerinin Sürdürülebilir Tarımdaki Yeri ve Önemi: Literatür Çalışması” isimli çalışmalarında görüntü işleme tekniklerinin sürdürülebilir tarım stratejileri arasındaki yeri ve öneminin değerlendirilmesini amaçlamışlar ve 2011-2016 yılları arasında sürdürülebilir tarımda görüntü işleme teknikleri ile ilgili yayınları incelemişlerdir. Çalışma sonucunda gübreleme, sulama ve ilaçlama ilk sırada gelmek üzere tarımsal girdilerde etkinliğin artırılmasında görüntü işleme tekniklerinin olanak sağlaması ve diğer alanlardaki başarılı uygulamalarıyla sürdürülebilir tarıma önemli ölçüde katkı sağlayacağını ifade etmişler, yapılan çalışmaların pratiğe aktarılması durumunda görüntü işlemenin tarıma katkısının giderek artacağını belirtmişlerdir..

Balcı ve ark. (2016), “Görüntü işleme teknikleri kullanılarak napolyon tipi kirazların sınıflandırılması” isimli çalışmalarında görüntü işleme teknikleri kullanılarak Napolyon kirazının boyutunun belirlenmesini amaçlamışlardır. Çalışmada kiraz fotoğrafları çekilerek Matlab ortamına program dili yazmışlardır. Çalışma sonucunda renk tahmini başarısı %99, cins tahmininde ise %95,52 olarak bulmuşlar. Daha sonraki çalışmalar için birçok farklı faktör denenerek (Yapay sinir ağları ile yapay zekâ metotları bir arada kullanılarak, tam olgun kiraz fotoğrafları, daha çözünürlüklü bir kamera ve daha profesyonel bir düzenek vb.) çalışmalar yapılması gerektiğini önermişlerdir.

Demir ve ark. (2016), “Görüntü İşleme Tekniği ile Yabancı Ot Renk Özelliklerinin Belirlenmesi” adlı çalışmalarında, dijital kamera görüntüleri ve renk ölçüm cihazı ile birlikte elde edilen Sirken (*Chenopodium album* L.), Yabani Marul (*Lactuca serriola*) ve Eşek marulu (*Sonchus hierrensis*) yabancı otlarına ait renk özelliklerini karşılaştırmak istemişlerdir. Çalışmada Nikon kamera ve Konica Minolta taşınabilir renk

ölçüm cihazı kullanmışlar. Elde edilen ortalama değerler incelenmiş renk ölçüm cihazına ihtiyaç kalmadan, dijital kameradan elde edilen ve görüntü işleme tekniği kullanarak yapılan uygulamaların yeterli olacağı ve gerekli bilgiyi elde etmenin mümkün olduğunu bildirmişlerdir.

Hayıt ve ark. (2018), “Gıda Sektöründe Uygulanan Görüntü İşleme Çalışmalarının ve Tekniklerinin İncelenmesi” adlı derleme çalışmalarında gıda sektöründe uygulanan bazı görüntü işleme tekniklerini incelemeyi amaçlamışlardır. Çalışma sonucundagörüntü işleme algoritmalarının ürün kalitesi ve sınıflandırması yönünden değerlendirilmesinde etkili olduğunu ve başarı ile kullanılabileceğini bildirmişlerdir.

Kamilaris ve Prenafeta-Boldu (2018) “Tarımda derin öğrenme: Bir anket” adlı çalışmalarında çeşitli tarım ve gıda üretiminde uygulanan derin öğrenme tekniklerini araştırmayı amaçlamışlardır. Çalışmalarında 40 araştırma çalışması incelenmiş ve çalışmalarda belirli tarımsal sorunlar, kullanılan belirli modeller ve çerçeveler, kullanılan verilerin kaynakları ve doğası, ön işlenmesi ve genel performansları değerlendirmişlerdir. Sınıflandırma veya regresyon performansındaki farklılıklara göre derin öğrenmenin diğer mevcut popüler tekniklerle karşılaştırmalarını incelemişlerdir. Çalışma sonucunda derin öğrenmenin daha iyi performans sunduğunu ve diğer popüler görüntü işleme tekniklerinden daha iyi performans gösterdiğini ifade etmişlerdir. Gelecekteki Derin öğrenmenin genel faydalarını, daha akıllı, daha sürdürülebilir çiftçilik ve daha güvenli gıda üretimi için daha fazla kullanılması gerektiğini önermişlerdir.

Patricio ve Rieder (2018),” Tahıl bitkileri için hassas tarımda bilgisayarlı görme ve yapay zekâ: Sistematik bir inceleme” adlı çalışmalarında dünyada en çok üretimi yapılan beş tahıl ürününün (mısır, pirinç, buğday, soya fasulyesi ve arpa) üretim aşamasında, hassas tarımda bilgisayar vizyonunun uygulanabilirliğini göstermeyi amaçlayan sistemli şekilde bir inceleme yapmışlardır. Son beş yılda seçilen 25 makaleyi farklı yaklaşımlarla incelemişlerdir. Çalışmalarında mevcut araçlar arasında, görüntülerdeki kalıpların tespitinde önemli sonuçlar elde eden yapay zekâ algoritmaları ile birleştirilmiş bilgisayarlı görme çözümlerini öne çıkarmışlardır. Tahıl üretiminin küresel ekonomide önemli bir rol oynadığını ve bu anlamda, verimli ve güvenli gıda

retim yntemlerine olan talep arttıđını belirterek bilgi teknolojileri bu amaca ynelik aralardan biri olduđunu ifade etmiřlerdir.

Solak ve Altınıřık (2018), “Grnt iřleme teknikleri ve kmeleme yntemleri kullanarak findık meyvesinin tespit ve sınıflandırılması” adlı alıřmalarında grnt iřleme tekniklerini kullanarak findıđın sınıflandırılmasını amalamıřlardır. Findıkları byk (K3), orta (K2) ve kk (K1) diye sınıflandırmaya tabi tutmuřlardır. Analiz olarak ortalama tabanlı sınıflandırma ve K-means kmeleme yntemlerini kullanmıřlardır. alıřma sonucunda findık meyvesini tespit etmede, grnt iřleme teknikleri ile %100 oranında bir bařarı yakalamıřlardır. Bylece nerdikleri yazılımın farklı nesneler kullanarak sınıflandırma iřlemlerinde bařarılı olacađı kanısına varmıřlardır.

Tin ve ark. (2018), “Grnt İřleme Tekniklerini Kullanarak Myanmar Pirin Tanesi Sınıflandırması” adlı alıřmalarında Myanmar pirin tanelerinin farklı zelliklerini ve eřitlerini grnt iřleme tekniklerini kullanarak, pirin tanesi rneklerinin otomatik olarak sınıflandırılması iin uygun algoritmalarla birleřtirilen bilgisayar grnt tabanlı bir sistemin geliřtirilmesini amalamıřlardır. alıřmada Myanmar'daki Paw San Hmwe, Lone Thwe Hmwe, Ayeyarmin, Kauk-Nyinn-Thwe ve Kauk-Nyinn-Pu gibi beř pirin eřidini ele almıřlardır. Her bir tahıl grnts n iřleme tabi tutularak tahıl grntsn geliřtirilmiř ve kenar algılama yntemleri kullanarak blmlere ayrılmıř ve beř morfolojik zellik her tane grntsnden elde etmiřlerdir. Geliřtirilen algoritmanın Myanmar'da ok nemli olduđu, nk Myanmar'ın byk pirin reticisi olduđunu ifade etmiřlerdir. Arařtırmanın byk lde arařtırmacılara, tarımcılara ve tarımsal bymenin diđer paydařlarına yardımcı olacađını belirtmiřlerdir.

Vijayashree ve Gopal (2018), “Bitkisel Tıbbi Bitki Yapraklarının Grnt İřleme Algoritması Kullanılarak Tanımlanması: İnceleme” adlı alıřmalarında otomatik yaprak tanıma sistemine dayalı olarak bitkisel tıbbi yaprakların sınıflandırılması ve tanımlanmasını amalamıřlardır. 50 farklı trden 500 yaprak ieren veri seti kullanarak, sınıflandırma, doku, řekil ve renk gibi eřitli parametreler uygulamıřlar. Testler, doku analizi, renk momenti sınıflandırması ve algoritmanın sinir ađlarında eđitilmesi gibi farklı yntemler altında gerek zamanlı Raspberry Pi iřlemci kullanarak gerekleřtirmiřler. Bitkisel řifalı yaprakların sınıflandırılmasında elde edilen dođruluk %99,2 olduđu tespit

edilmişler ve çalışmada farklı Fesleğen (Tulsi) yaprakları çeşitlerini sınıflandırma verimliliğini belirlemek için yeni bir sinir ağı algoritması önermişlerdir.

Ahmad ve ark. (2019), “Görüntü İşleme Kullanılarak Mango Şekli Olgunluk Sınıflandırması” adlı çalışmalarında Harumanis Mango'sunun şekle bağlı olarak olgunluk derecesini görüntü işleme tekniklerini kullanarak belirlemeyi amaçlamışlardır. Meyve olgunluğunu belirlemede en önemli fiziksel özelliklerin renk, şekil, boyut ve doku gibi dış özellikler olduğunu fakat Harumanis mangoları için durumun farklı olduğunu ifade etmişlerdir. Mangonun şekli olgunluk ve kalitede önemli faktör olduğundan çalışmada şekle göre sınıflandırma yapmışlardır. Çalışmada görüntü elde etme, ön işleme, segmentasyon, özellik çıkarma ve sınıflandırmayı içeren bilgisayarlı görme yöntemi (CVM) kullanmışlar ve çalışma sonucunda CVM sınıflandırmasının şekle dayalı insan görüşü ile tutarlı olduğu belirtilmiştir.

Hungilo ve ark. (2019), “Bitki Hastalıklarının Tespiti ve Sınıflandırılması için Görüntü İşleme Teknikleri – Gözden Geçirme” adlı çalışmalarında Tanzanya’da, bitki yapraklarında veya meyvelerinde hastalıkları görüntü işleme tekniği kullanarak tespit etmek ve sınıflandırmak için yapılan çalışmaları incelemeyi amaçlamışlardır. Çalışmalarında kullanılan makine öğrenimi modelinin performansını kontrol etmişlerdir. Çalışma sonucunda alanda diğer araştırmacılara ışık tutacağı kanaatine varmışlardır.

Kaymak ve ark. (2019), “Görüntü İşleme Teknolojilerinin Elma Bahçelerine Yönelik Kullanım Örneği” adlı çalışmalarında görüntü işleme teknikleri kullanılarak elma bahçesinde bulunan ağaçlar üzerindeki kırmızı renkli elmaların tespit edilmesini ve sayılmasını amaçlamışlardır. Bilgisayar ortamında bu amacı taşıyacak yazılım geliştirmişlerdir. Geliştirilen yazılımla elma nesnelerinin merkez noktaları işaretlenerek tespit edilmiş ve böylelikle elma sayımını gerçekleştirmişlerdir. Geliştirilen uygulama yazılımının, anlık çekilen görüntü, fotoğraf veya canlı video üzerinden görüntü alabileceğini vurgulamışlardır. Ağaç üzerindeki kırmızı renkli elmalar, uygulanan uygulama ile renk bakımından %78,47 başarı ile tespit ettiklerini ifade etmişlerdir. Bu durumun, görüntü işleme yöntemleri kullanılarak renk bakımından elma tespiti için başarılı sayılabileceğini belirtmişlerdir.

Shafi ve ark. (2019), “Hassas Tarım Teknikleri ve Uygulamaları: Düşüncelerden Uygulamalara” adlı çalışmalarında tarım alanındaki mahsullerin verimini artırmak için

yakın ve uzak sensör ağlarını incelemeyi amaçlamışlardır. Çalışmada kablosuz iletişim teknolojileri, sensörler ve kablosuz düğümler, ekinlerin spektral görüntülerini almak için kullanılan platformlar, spektral görüntüleri analiz etmek için kullanılan yaygın bitki örtüsü endekslerin ve tarımda kablosuz sensör ağı uygulamalarını içeren bir anket uygulaması kullanmışlardır. Sağlıklı ve sağlıksız mahsulleri sınıflandırmak için iki modülden oluşan nesnelerin interneti tabanlı bir akıllı otomasyon çözümünü önermişlerdir. Tarım alanında gerçekleştirilen araştırmaların çoğu, yalnızca Bitki Örtüsü İndekslerini yansıtan görüntüleri toplamak için uzaktan algılama platformları kullanılarak oluşturulamayacağını; bunun yerine, diğer birçok faktörün toprak özellikleri, toprak nem seviyesi, meteorolojik davranış vb. faktörlerinde bilinmesi gerektiğini savunmuşlardır. Çalışmalarının gelecek çalışmalara ışık tutacağını ifade etmişlerdir.

Thong ve ark. (2019), “Mango Sınıflandırma Sistemi Görüntü İşleme Teknolojisini ve Yapay Zeka” adlı çalışmalarında Vietnam'da mangoları renk, hacim, boyut, şekil ve meyve yoğunluğu açısından sınıflandırabilen bir sistem oluşturmayı amaçlamışlardır. Görüntü işlemeyi kullanan sınıflandırma sistemi, CCD kameralar, C dili programlama, bilgisayarla görme ve yapay sinir ağlarının kullanımı dâhil olmak üzere yapay zekâyı içeren bir sistem geliştirmişlerdir. Sistem, mango meyve yüzeyindeki kütle, hacim ve leke görüntülerini kullanmışlardır. Çalışma sonucunda, mango meyvesini paketlemeden ve piyasaya ihraç etmeden önce kalitesini kontrol etmek ve değerlendirmek için görüntü işleme teknolojisini kullanarak otomatik bir mango sınıflandırma sisteminin geliştirilmesi gerektiğini belirtmişlerdir.

Arora ve ark. (2020), “Görüntü İşleme ve Makine Öğrenimi Tekniklerini Kullanarak Pirinç Tanesi Sınıflandırması” adlı çalışmalarında Pirinç Tanelerini sınıflandırmayı amaçlamışlardır. Çalışmalarında surti kolam, idli pirinci, uzun taneli basmati ve haşlanmış pirinç sınıflarını kullanmışlardır. Veri setinin toplanarak, ana eksen, küçük eksen, eksantriklik, uzunluk, genişlik gibi bireysel pirinç tanelerinin çeşitli parametrelerini çıkarmışlardır. Sistemde bu bilgi, bilgisayarı eğitmek için kullanılmış ve her pirinç tanesi veya görüntü, ilgili sınıfa ayırmışlardır. Çalışma sonucunda farklı pirinç türlerinin yönetimi ve takibinin önemli olduğu belirtilmiş ve endüstriyel bir ortamda uygun şekilde sınıflandırılması daha çok önemli hale geldiğinden, Sistemin

otomatikleştirilmesi, endüstri ihtiyaçlarına göre gerekli değişikliklere uygulanması endüstrinin gelecekteki kapsamına sahip olmasını teşvik edeceği vurgulanmıştır.

Lu ve ark. (2020), “Hiperspektral Görüntüleme Teknolojisindeki Son Gelişmeler ve Tarımda Uygulamaları” adlı derleme çalışmalarında, tarım araştırmacıları ve uygulayıcılarına yardımcı olmak için tarımsal uygulamalarda hiperspektral görüntülemenin güçlü yanlarını ve sınırlamalarını daha iyi anlamaları ve bu değerli teknolojiyi benimsemelerini teşvik etmeyi amaçlamışlardır. Hiperspektral görüntülerin elde edilmesi, işlenmesi ve analizi zorlu bir araştırma konusu olmaya devam etmesine rağmen son yıllarda hiperspektral görüntüleme, tarımsal uygulamalar için daha yaygın hale geldiğini ifade etmişlerdir. Bu amaçla hiperspektral görüntüleme teknolojisi ve tarımdaki uygulamalarda son 30 yılda yapılan yayınları incelemişlerdir. Görüntüleme platformları ve sensörler, literatürde kullanılan analitik yöntemlerle birlikte tartışılmış ve farklı uygulamalar için hiperspektral görüntüleme performanslarını (örneğin, mahsulün biyofiziksel ve biyokimyasal özelliklerinin haritalanması, toprak özellikleri ve ürün sınıflandırması) da değerlendirmişlerdir. İHA (İnsansız hava aracı) operasyonlarındaki kısa pil ömrü ve hiperspektral sensörlerin yüksek maliyeti gibi bazı sınırlamaların üstesinden gelmek için daha fazla teknolojik gelişmeye ve bu alanlarda daha fazla araştırma yapılmasına ihtiyaç olduğunu belirtmişlerdir.

Torres ve ark. (2020), “Meyve Görüntü İşlemesine Uygulanan Evrişimsel Sinir Ağının Bir İncelemesi” adlı çalışmalarında meyve sınıflandırma ve kalite kontrolü için Evrişimsel Sinir Ağının kullanımının temellerini, araçlarını, sınıflandırma, kalite kontrol ve algılama olarak iki örneğini sunmayı amaçlamışlardır. Çalışma sonucunda evrişimsel Sinir Ağının meyve tanıma için kullanımı veya yeni modeller kullanarak ya da transfer öğrenimi için önceden eğitilmiş ağlarla mükemmel sonuçlar elde etmeyi büyük ölçüde artırdığını belirtmişlerdir. Ayrıca bazı durumlarda %100'e varan mükemmel sonuçların elde edildiği belirtilmiştir. Yeni bir program yazmaktansa var olanı güncelleyip kullanmanın daha verimi olacağını önermişlerdir.

Zhang ve ark. (2020), “Tarımda Yoğun Sahne Analizi için Derin Öğrenme Uygulamaları: Bir İnceleme” adlı derlemelerinde tarımda yoğun görüntü analizi için derin öğrenme uygulamalarını araştırmayı amaçlamışlardır. Konuyu daha iyi anlatabilmek için, önce tarımdaki yoğun görüntülerin türlerini ve zorluklarını tanımlamışlardır. Ardından,

bu yoğun görüntülerde kullanılan çeşitli popüler derin sinir ağlarını tanıtmışlardır. Daha sonra, bu yapıların çeşitli tarımsal görevlerdeki uygulamaları, tanıma ve sınıflandırma, tespit, sayım ve verim tahmini de dâhil olmak üzere bu derlemede kapsamlı bir şekilde tanıtmışlardır. Son olarak, incelenen derin öğrenme uygulamaları, sınırlamaları ve tarımda yoğun görüntülerin analizi için gelecekteki yapılacak çalışmaları önermişlerdir.

Jayasinghe ve ark. (2021), “Çok yıllık çavdar bitkisinin (*Lolium perenne* L.) kalıcılığının tahmini için görüntü tabanlı yüksek verimli fenotipleme - Bir inceleme” adlı çalışmalarında mera yetiştiriciliğinde kalıcılığı tahmin etmeyi amaçlamışlardır. Bunun için hassas tarımda mevcut görüntü tabanlı yüksek verimli fenotipleme yaklaşımlarını kullanmışlardır. Sensör teknolojilerindeki ve görüntü işleme yazılımlarındaki hızlı gelişmeyle birlikte, verim tahmini, zemin örtüsü tahmini, patojen ve hastalık şiddeti tahmini, yabancı ot ayrımı ve verim ve besleyici özelliklerin tahmini gibi faktörleri keşfetmek için hassas tarımda yaygın olarak uygulandığını belirtmişlerdir. Hassas tarımda mevcut havadan ve yere dayalı görüntü tabanlı yüksek verimli fenotipleme yaklaşımları, mera fenotiplemesi için fırsatlar sunacağını ve bu yaklaşımların daha da geliştirilmesi, mera ıslahında çok yıllık çavdar otunun kalıcılığını değerlendirmek için hassas bir sensör tabanlı araç sağlayabileceğini ifade etmişlerdir.

Naik ve ark. (2021), “Yaprak bitki hastalıklarını tespit etmek, ölçmek ve sınıflandırmak için çeşitli görüntü işleme teknikleri ve makine öğrenimi modelleri üzerine bir anket” adlı çalışmalarında Hindistan’da bitki hastalıklarını tespit etmek, ölçmek ve sınıflandırmak için makine öğrenimi araçları ve çeşitli görüntü işleme teknikleri hakkında bir araştırma sunmayı amaçlamışlardır. Çalışmada yapraklarda ve gövdelerde görünür semptomları araştıran makine öğrenme modelleri kullanmışlardır. Çalışmalarının, bu önemli araştırma alanına hızlı bir genel bakış sağlayarak hem yaprakta hastalık tespiti hem de örüntü tanıma üzerinde çalışan araştırmacılara faydalı olacağını belirtmişlerdir.

Syeda ve ark. (2021), “Tarımda görüntü işleme, insansız hava aracı ve robotik ve yapay zekâ kullanan gelişmiş kontrol stratejileri: bir inceleme” adlı çalışmalarında geleneksel tarım sisteminden modern tarım sistemine geçişte kullanılabilecek teknolojileri tayin etmek için akıllı tarım sistemlerine genel bir bakış sağlamayı amaçlamışlardır. Çalışmada tarım alanında modern teknolojilerin akıllı kullanımlarına bakılarak, bitkilerin stres seviyelerinin izlenmesi ve ihtiyaçlara göre hareketlerin

gerçekleştirilmesi (sulama, haşere ilaçlama, ekinlerin izlenmesi, verim üretiminin izlenmesi vb.) için spektral görüntü işleme, yapay zekâ, insansız hava aracı (sabit ve döner) yöntemini kullanarak su veya toprak nemi, besinler ve pestisitlerin incelenebileceğini aktarmışlardır. Bilim alanındaki otonom araçların hem fabrikalar hem de tarlalardaki işçiler için zamandan tasarruf sağladığı ve sağlık açısından verimli olduğunu belirterek önümüzdeki dönemlerde dünyanın tamamen akıllı tarım sistemine geçeceğini ileri süren araştırmacılar tarım sisteminin çok daha verimli hale gelmesi için otonom araçlarının ve yapay zekâ tekniklerinin kullanılmasını önermişlerdir.

Vishnoi ve ark. (2021) “Sayısal zekâ ve görüntü işleme kullanarak bitki hastalık tespiti” adlı çalışmalarında bilgisayarla görme ve makine öğrenimi tekniklerini kullanarak bitki hastalıkları sınıflandırma ve tanımlama sistemini otomatikleştirmek için çeşitli araştırma çalışmalarının bir özetini sunmayı amaçlamışlardır. Bitkilerde meydana gelen hastalıklar, üretim miktarı ve kalitesinin düşmesine ve dolayısıyla ekonomik kayıplara sebep olan ciddi nedenler arasında gösterildiğinden, bitki hastalığını görüntü işleme ve sınıflandırma yöntemiyle otomatikleştirmeyi amaçlamışlardır. Bitki hastalık belirtileri bitkilerin çeşitli kısımlarında belirginlik gösterdiğini, enfeksiyonu tespit etmek için en yaygın olarak bitki yaprakları kullanıldığını ifade etmişlerdir. Çalışmada, görüntü elde etme, ön işleme modülü, lezyon bölütleme yaklaşımları, özellik çıkarma ve son olarak sınıflandırıcılar için kullanılan kabul edilebilir birkaç teknik sunmuşlardır. Bilgisayarla görme ve yumuşak hesaplama teknikleri, yaprak görüntülerini kullanarak bitki hastalıklarının tespitini otomatikleştirmeyi bazı araştırmacıların kullandığını bu nedenle bu tür çalışmaların çeşitli yönleri, yararları ve eksiklikleri özetlemişlerdir. Çalışmalarının, araştırmacıların bitki hastalık tespiti/sınıflandırmasında bilgisayarlı görmenin uygulanabilirliğini anlamalarına yardımcı olacağını ifade etmişlerdir.

Yaqoob ve ark. (2021), “Tarımsal sanayide görüntüleme teknikleri ve uygulamaları, bir inceleme” adlı çalışmalarında çeşitli görüntüleme tekniklerine ve bunların Tarımsal işleme endüstrisindeki uygulamalarını ele almışlardır. Gıda endüstrilerinde çoğunlukla ima edilen tarama yöntemleri, hiper-spektral, manyetik rezonans, termal ve X-ışını gibi konular hakkında bilgi vermişlerdir. Kalite kontrolün gıda işleme endüstrilerinin önemli bir parçası olması ve yeni pazar kısıtlamaları nedeniyle endişesi, güvenilir testler yapabilen ve ürün kalitesine yönelik verimli bir izleme sistemi

geliştirebilen bir teknolojiyi gerekli kıldığını, görüntüleme sisteminin hızlı, ucuz ve non-invaziv bir teknik olması bu soruna bir çözüm olabileceğini savunmuşlardır. Kusurların tespiti, yabancı maddeler, parazit enfeksiyonları, mikrobiyal kontaminasyon, mantar ve diğer birçok özelliğin tespiti gibi bir dizi uygulamalarla tüketicilerin sağlığını gıda kaynaklı patojenlerden ve tehlikelerden korumaya yardımcı olabileceğini söylemişlerdir.

Mahanti ve ark. (2021), “Meyve hasarı tespiti için ortaya çıkan tahribatsız görüntüleme teknikleri: Görüntü işleme ve analiz” adlı çalışmalarında endüstrilerin, işleme hattındaki hasarlı meyveleri ayırmak için manuel ayırma yöntemi yerine görüntü işleme teknikleri kullanılarak zaman, emek ve zahmetten kurtulmalarına olanak sağlayacağını belirtmişlerdir. Çalışmalarında X-ray görüntüleme gibi tahribatsız teknikler, hiperspektral görüntüleme ve termal görüntüleme, numune yüzeylerinin invazif olmayan testleri kullanılmışlardır. Sonuç olarak hiperspektral görüntüleme ve termal görüntüleme teknikleri, sınırlı ışık penetrasyon derinliği nedeniyle yüzey hasarlarını tespit edebileceğini ifade edilmişlerdir. Hiperspektral görüntüleme spektrumu, kusurları ve meyve kalite parametrelerini tespit etmede faydalı olacağı ve aktif termal görüntüleme meyvede küçük hasarları bile tespit edebileceği ancak endüstriyel üretim hatları için uygun olmadığı aksine X-ışını görüntüleme meyve iç hasarlarını tespit edebileceğini belirtmişlerdir. Uygun kemometrik prosedürlerle birlikte bu X-ray görüntüleme gibi tahribatsız teknikler sinerjik uygulamaları, insan müdahalesi olmadan hasarlı meyveleri tanımlamada ve işleme hattına girmelerinden kaçınmada faydalı olacağını belirtmişlerdir.

Xie ve ark. (2022), “Dijital Renkli Görüntüleme ve Makine Öğrenimi Kullanılarak Kontrollü Ortam Koşullarında Buğdayda Taç Çürüklüğü Hastalığının Tespiti” isimli araştırmalarında tahıl endüstrisinde taç çürüklüğü hastalığına görüntü işleme teknikleri kullanarak ekonomik bir çözüm bulmayı amaçlamışlardır. Çalışmalarında taç çürüklüğü hastalığı tespit etmek için akıllı telefon kamerası ve makine öğrenimi teknolojileri kullanılarak bir yöntem geliştirmişlerdir. Sonuç olarak hastalık bulaşmasından 14 gün sonra enfekte ve sağlıklı bitkileri başarıyla ayırt etmeyi görüntüleme işleme tekniklerini ve destek vektör makinesi algoritmasını kullanarak başarmışlardır. Çalışmalarının arazi koşullarında verimli ve ekonomik bir hastalık tarama yöntemi geliştirme konusunda araştırmacılara destek sağlayabileceğini bildirmişlerdir.

Zhang ve ark. (2022), “Hava ve yer tabanlı nokta bulutları kullanılarak elma bahçelerinde otomatik çiçek kümesi tahmini” adlı çalışmalarında elma bahçesinde çiçeklenme yoğunluğunu tespit etmek için insansız hava araçları ve yer tabanlı yapay görme sistemleri kullanılarak budama ve seyretme işlemlerini açıklamayı amaçlamışlardır. Denetimsiz makine öğrenimi yöntemlerine dayalı iki doğrusal regresyon modeli kullanmışlardır. Sonuç olarak önerilen yöntemler, yalnızca basit yer tabanlı yapay görme sistemleri görüntüleri ve konum verilerini kullanarak çiçek seyreltmesini yönlendirmek için yeni bir strateji sağladığını ifade etmişlerdir.

2.2 Kayısı Çalışmaları

Karhan (2011), “İmge İşleme Yöntemleri İle Kayıslarda Yaprak Delen Hastalığı Sonucu Oluşan Lekelerin Tespiti” adlı tez çalışmasında kayıslarda Yaprak Delen (Çil) Hastalığını görüntü bölütleme algoritmaları ile tespit etmeyi amaçlamıştır. Metot olarak görüntü iyileştirme ve renk tabanlı bir bölütleme işlemlerini, görüntü işleme tabanlı gerçek zamanlı çalışan bir sınıflandırma sistemi ile kullanmıştır. Sonuç olarak geliştirilen yöntem ile lekelerin tespiti ve kayısı yüzeyinde kapladığı alan sonucu kayısıda kalite sınıflandırması yapılabilir ve daha doğru fiyatlandırma belirlenebileceğini ifade etmiştir.

Varjovi ve Talu (2016), “Kayısı İçin Otomatik Rekolte Tahmin Sistemi” adlı çalışmalarında, kayısı bahçelerindeki yıllık kayısı miktarının otomatik olarak belirlenebilmesini amaçlamışlardır. Çalışmada Malatya’daki kayısı bahçeleri materyal olarak kullanılmıştır. Metot olarak Gaussian mixture modelini kullanmışlardır. Sonuç olarak önerilen yöntem ile R^2 0.77 oranında başarı elde ettiklerini belirtmişlerdir. Sonraki çalışmalarda ağaçtaki meyve yoğunluğunun ağaç kitlesine oranı ile alakalı özelliklerin de kullanılarak daha iyi sonuçların alınacağını ifade etmişlerdir.

Arı ve ark. (2019), “Derin Öznitelikler Kullanılarak Aşırı Öğrenme Makineleri ile Kayısı Yapraklarının Sınıflandırılması” adlı çalışmalarında 7 farklı kayısı türünün sınıflandırılması ile derin öğrenme katmanlarındaki öznitelik sonuçlarının anlamlı olup olmadığını bulmayı amaçlamışlardır. Yöntem olarak derin evrimsel sinir ağlarını kullanmışlardır. Çalışma sonucunda %98,8 oranıyla en yüksek başarının fc8 katmanında gerçekleştiğini belirtmişlerdir. En düşük başarı oranının %95,2 ile fc7 ve fc6 katmanlarında elde edildiği ifade etmişlerdir. Sonraki çalışmalarda kendilerinin üreteceği

veya literatürde yer alan öznitelik algoritmalarının performanslarının değerlendirilmesini hedeflediklerini belirtmişlerdir.

Hallmann ve ark. (2019), “Organik ve geleneksel çiftlik yönetiminin kayısıların (*Prunus armeniaca* L.) alerjenik gücü ve biyoaktif bileşik durumu üzerine etkisi” adlı çalışmalarında organik veya konvansiyonel uygulamaların kullanımı ile kayısıların alerjenik özellikleri ve biyoaktif bileşik içeriği arasındaki ilişkiyi amaçlamak istemişlerdir. Sonuç olarak, organik kayısı $R^2 = 0,9044$ ve geleneksel kayısı $R^2 = 0,8169$ için polifenolik bileşiklerin içeriği ile alerjenik proteinlerin içeriği arasında güçlü bir ilişki olduğunu ifade etmişlerdir.

Khojastehnazhand (2019), “Kayısının görüntü işleme tekniği kullanılarak olgunluk tespiti ve hacim tahmini” adlı çalışmalarında kayısılar üç olgunluk aşamasına (olgunlaşmamış, olgun ve aşırı olgunlaşmış) göre sınıflandırmışlar ve hacim tahmini yapmışlardır. Kayılardan alınan görüntüler, daha önce geliştirilmiş bir otomatik algoritma kullanarak işlemişlerdir. Sınıflandırıcılar, kayıları renk özelliklerine göre sırasıyla 0,904 ve 0,923 doğrulukla sınıflandırabilir olduğunu ifade etmişlerdir. Sonuç olarak algoritmanın kayısıların görüntü özelliklerini kullanarak meyveleri düzgün bir şekilde sınıflandırabildiğini belirtmişlerdir.

Tresson ve ark. (2019), “Güney Fransa'da iklim değişikliği altında kayısı çiçeği yanıklığının gelecekteki gelişimi” adlı çalışmalarında iklim değişikliğinin kayısı çiçek ve dal yanıklığı (*Monilinia laxa*) üzerindeki sonuçlarını, iklim değişikliğinin çeşit ve rakıma bağlı olarak farklı etkilerini ortaya koymayı amaçlamışlardır. Kümülatif Yanıklık Riski İklim İndeksi, çiçeklenme dönemi boyunca çiçek yanıklığı insidansının ağırlıklı toplamını elde etmek için oluşturmuşlardır. Sonuç olarak, Kayısı ağaçları iklim değişikliği altında daha erken çiçek açtığından (1950 ile 2100 arasında 50 gün farka kadar) çiçeklenme dönemindeki bu kaymaların ve değişen iklim koşullarının birleşik etkileri altında, Bergarouge gibi geç çeşitler, daha sıcak fakat daha kuru çiçeklenme dönemleri nedeniyle çiçek yanıklığı riskinde (%31'e kadar) bir azalma görülebileceği ifade etmişlerdir. Diğer çeşitler (örneğin: Bergeron), çiçeklenme döneminin en yüksek rakımlarda daha yağışlı koşullara kaymasıyla bu riskte %27'ye kadar bir artış yaşayabileceğini belirtmişlerdir. Çalışmanın gelecekteki değişiklikleri tahmin etmek için

kullanılabilir ve ayrıca řu anda çiftçiler için bir karar destek aracı olabileceđi ifade etmişlerdir.

Dođru Çokran (2020). “Aras Havzasında yetiřtirilen řalak (Aprikoz) kayısı çeřidinde klon seleksiyonu” adlı tez çalışmasında Kars ili Kağızman ilçesi ile Iğdır ili Merkez ve Tuzluca ilçesinde 2015-2018 yılları arasında fenolojik, pomolojik, morfolojik yönden řalak kayısı klonları incelemiřtir. Sonuç olarak moleküler karakterizasyon bakımından çeřitlilik gösteren ve Fitokimyasal açısından zengin olan 76 TU 29, 36 KZ 13, 76 TU 09 nolu klonlar çeřidin genel özelliklerini taşıdığını, moleküler çalışmalar sonucunda polimorfizm oranı yüksek bulunduđunu, řalak kayısı çeřidinin en büyük sorunu meyvesini sulu ve çok iri olmasından dolayı yola dayanımının ve raf ömrünün az olmasından ambalajlama ve paketleme paketlerin 4-5 kg’lık olması ezilme gibi nedenlerden dolayı hasarın en aza indirilmesini sağlayacağını ifade etmiştir. Seleksiyonun 2. Ařamasını Iğdır üniversitesi Tarımsal Uygulama ve Arařtırma Merkezinin bahçesine dikilip çalışmaya devam edileceđini belirtmiştir.

řenel (2020), “Makine Öğrenmesi Algoritmaları Kullanılarak Kayısı İç Çekirdeklerinin Sınıflandırılması” adlı çalışmasında kayısı iç çekirdeklerinin tatlı veya acı diye sınıflandırılmasını amaçlamıştır. Metot olarak Destek Vektör Makinesi, k En Yakın Komřu, Rasgele Orman, Karar Ağacı, Gaussian NaiveBayes, Adaptive Boosting ve Çok Katmanlı Algılayıcı algoritmaları kullanmıştır. Sonuç olarak yeterli sayıda öznitelik ile sınıflandırma işleminde %100 başarıyı algoritmaların yarıdan fazlası ile elde edebileceđi ve Rasgele Orman algoritması en az sayıda öznitelik kullanarak en iyi başarıyı verdiđini ifade etmiştir.

Türkođlu ve ark. (2020) “Derin Evriřimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması” adlı çalışmalarında kayısı hastalıklarının tespitini amaçlamışlardır. Metot olarak Evriřim, Relu, Normalizasyon, Havuzlama ve tam bađlı katmanlarından oluřan Derin Evriřimsel Sinir Ağlarını (DESA) kullanmışlardır. Sonuç olarak, kayısı hastalıklarının tespitinde önerilen derin ağ modelinin, diđer geleneksel görüntü tanımlayıcı modellerine nazaran daha yüksek sınıflandırma başarısına sahip olduđunu ifade etmişlerdir.

Uçar ve ark. (2021), “Türkiye’de Kayısı Üretiminin ARIMA Modeli ile Tahmini” adlı çalışmalarında TUİK ve FAO 1970-2019 dönemi verilerinden faydalanarak

önümüzdeki 4 yıllık taze kayısı üretim tahmininin belirlenmesi amaçlamışlardır. Çalışmalarında metot olarak ARIMA (Box-Jenks) modeli kullanmışlardır. Çalışma sonucundamodel sonuçlarına göre, Türkiye kayısı üretmenin 2020 yılında 769.426 ton, 2021 yılında 761.686 ton, 2022 yılında 754.236 ton, 2023 yılında 747.052 ton olacağını tahmin ettiklerini belirtmişlerdir. Kayısı üretiminde karşılaşılan en önemli riskler girdi fiyatları yüksekliği ve don riski olduğunu ifade etmişlerdir. Bu nedenle kayısı üretimine yönelik destekler arttırılması gerektiğini tarım sigortası yaptırılması ve ürün satışlarının zaman dilimine yayılması konusunda üreticilerin yönlendirilmeleri gerektiğini beyan etmişlerdir. Dona dayanıklı kayısı çeşitlerinin geliştirilmesi için gerekli çalışmalar yapılmalı ve bu çalışmaların desteklenmesi gerektiğini ifade etmişlerdir.

Korzin ve ark. (2021), “Güney Rusya'daki hava koşullarının kayısı üretici tomurcuklarının dona dayanıklılığına etkisi” adlı çalışmalarında kayısı toplama-üreme plantasyonlarını incelemek ve ticari ve üreme kullanımı için umut vaat eden dona dayanıklı genotipleri seçmeyi amaçlamışlardır. 50 kayısı çeşidindeki üretici tomurcukların dona dayanıklılıkları ve çeşitli kökenlere sahip üreme biçimleri, dalların bir iklim odasında dondurulmasıyla incelemişlerdir. Çek çeşidi 'Leala' dona karşı en iyi direnci nedeniyle seçilmiş 2020-2021 kış sonlarında, üretken tomurcukların %41,8 ila %65,9'unu canlı tutan altı çeşit ve üreme formu, tanımlamışlardır. Bu genotipler, herhangi bir olumsuz donma sıcaklığı etkisini önleyen yavaş bir gelişme ile karakterize etmişlerdir. Sonuç olarak kayısı bitkilerinde adaptasyon mekanizmalarının morfogenez oranlarına ve abiyotik faktör baskılarına bağımlılığını doğrulandığı ifade etmişlerdir.

Koçyiğit (2022). “Malatya halk kültüründe kayısı” adlı tez çalışmasında şehirdeki halk kültürü öğeleri üzerinde kayısının etkileri ele alınmış; adlandırmalarda, halk mutfağında, oyunlarda, halkın içinde doğup halk tarafından yaşatılan çeşitli inanış, uygulama ve geleneklerde, halk edebiyatı ürünlerinde kayısının izinin araştırılmasını amaçlamıştır. Böylelikle Malatya ve ilçelerinde derleme, araştırma ve inceleme faaliyetleri yapmış, yazılı ve sözlü kaynaklardan elde edilen halk kültürü ürünlerinde kayısının etkisi örneklerle sunulmaya çalışmıştır.

Şahin Demirel (2022), “Türkiye'deki Kayısı Üreticilerine Zaman Serileri Analizine Bağlı Ekonomik Bir Tavsiye” adlı çalışmasında üreticilere ekonomik tavsiye vermek amacıyla Türkiye’ de bulunan kayısı üreticileri için makine ve iş gücü

maliyetlerinin ekonomik olarak karşılaştırması yapmıştır. Zaman serisinde Kuadratik ve Yarı Logaritmik analiz metodları uygulanarak 2020-2024 yılları arası trend tahminleri gerçekleştirmiştir. Sonuç olarak üreticinin makine alımına ayıracağı sermayeyi 1 yıllık işçi ücreti ile amorti edebileceği ve bu vesile ile bir ömür kullanılacak makine alımını gerçekleştireceğini savunmuştur. Ayrıca makine + işgücü kullanımı ile makineye ayrılan sermaye 2 yıl içinde karşılanabileceğini ifade etmiştir. Böylelikle basit makine gücünün kullanımı ile özellikle Covid-19 sürecinde Türkiye çapında tüm kayısı üreticilerinin hem sağlık hem maddi hem de zaman açısından kar etmesini sağlayabileceğini ifade etmiştir.

Zhaoshuai ve ark. (2022), “Kayısı Çekirdeği Kabuğu Kırma Makinesi Tasarımı ve Testleri” adlı çalışmalarında kayısı çekirdeği kırma makinesi tasarlanmış ve bir kabuk kırma makinesi ile kayısı çekirdeğinin mekanik özellikleri analiz edilmiş ve kabuk kırma makinesinin temel çalışan parçaları tasarlanmış ve test faktörleri olarak kabuk kırılma açıklığı, besleme hızı ve silindirlerin diferansiyel hız oranı ve değerlendirme göstergeleri olarak kabuk kırılma oranı ve badem hasar oranı kullanılarak kabuk kırılmasının etkisini araştırmışlardır. Sonuç olarak kabuk kırma açıklığı 8,5 mm, besleme hızı 350 kg/saat ve diferansiyel hız oranı 1,75 olduğunda kabuk kırma oranı %99,04 ve badem hasar oranı %2,28 ile daha iyi bir kabuk kırma performansı ve iş verimliliği elde edildiğini ifade etmişlerdir.

3. MATERYAL ve YÖNTEM

3.1. Materyal

Araştırma materyalini Iğdır ilinde yaygın şekilde üretimi yapılmakta olan kayısı çeşitleri (Teberze, Şalak ve Ağarik) oluşturmuştur. 2022 yılı Haziran ve Temmuz aylarında materyal temini sağlanmıştır. Kullanılan kayısı çeşitlerinin fotoğrafları Şekil 3.1’de, kayısı örneklerinin alınması fotoğrafları Şekil 3.2’de verilmiştir.



Şalak sağlam kayısı



Şalak çürük kayısı



Ağarik sağlam kayısı



Ağarik çürük kayısı



Teberze sağlam kayısı



Teberze çürük kayısı

Şekil 3.1. Materyal olarak kullanılan kayısı çeşitleri



Şekil 3.2. Kayısı örneklerinin alınma fotoğrafları

Kayısı fotoğrafları puluz marka beyaz led ışıklı ürün çekim çadırında karanlık ortamda gerçekleştirilmiştir. Çekim çadırı ön ve arka tepesinde 20'şer 2 üst led ışık panellerinden oluşmaktadır (Şekil 3.3.).



Şekil 3.3. Puluz 2 üst led ışıklı çekim çadırı



Şekil 3.4. Kayısı fotoğraf çekim örnekleri

Çalışmada görüntünün yakalanması için Çizelge 3.1 ve Çizelge 3.2’de teknik özellikleri verilen yüksek çözünürlüklü fotoğraf makinesi ve farklı büyütme özelliklerine sahip lenslerden yararlanılmıştır (Çizelge 3.1.).

Çizelge 3.1. Araştırmada kullanılan fotoğraf makinasına ait teknik özellikler

Tip	AF/AE dâhili flaşlı lens kaydırmalı kamera
Çözünürlük	Efektif: yaklaşık 16.0 Megapiksel Toplam: yaklaşık 16.6 Megapiksel
Renk sistemi	RGB

Çizelge 3.2. Araştırmada kullanılan lense ait teknik özellikler

Canon EF-S 24-720mm f/3.4-5.8	
Odak ayarı	Dâhili odaklama sistemi
En yakın odaklanma mesafesi	0 cm
Odak uzunluğu	24-720mm



Şekil 3.5. Projede kullanılan fotoğraf makinası ve tripod

3.2. Yöntem

Araştırmada yöntem olarak görüntü işleme ve yapay sinir ağları yardımıyla sınıflandırma ve leke analizi kullanılmıştır (Altıkat ve ark., 2016). Iğdır ilinde yaygın şekilde üretimi yapılmakta olan kayısı çeşitlerinin (Teberze, Şalak ve Ağarik) görüntü işleme analizi ve sınıflandırma metotlarından yararlanılarak Matlab 2022b Programında sınıflandırma ve leke tespiti yapılmıştır. Araştırmada kullanılan faktörler Çizelge 3.3'te verilmiştir.

Çizelge 3.3. Araştırmada kullanılan faktörler

Faktörler	Tekerrürler, faktör sayıları ve işlem sayıları
4 çeşit faktör	Her meyve 5 çekim, her çeşit 50 tekerrür (5*50*4)
Sınıflandırıcı	4 farklı sınıflandırıcı
Özellik çıkarma filtresi	5 farklı özellik çıkarma filtresi
İyileştirme filtresi	6 farklı iyileştirme filtresi

Elde edilen görüntünün sayısal piksel değerlerinin tanımayı kolaylaştıracak biçimde değiştirilip düzenlenmesi görüntü işlemede işlem sırasını takip eden adımları içinde yer almaktadır (Çan, 2021). Görüntünün detaylarının kaybedilmesi (veri kaybı) ve görünümün düşmesinin sebebi gürültülerdir. Çevrenin karanlık oluşu veya kameranın sallanması gibi sebeplerle gürültü söz konusu olabilir. Gürültülerin temizlenmesinde,

görüntü işleme algoritmalarına başvurulmaktadır. Literatürdeki çalışmalar; farklı gürültü tipleri için farklı yöntemlerin uygulanabileceğini göstermektedir. Görüntü işleme, resimsel bilgilerin geliştirilmesi amacıyla, bir görüntünün doğasının değiştirilmesi ya da otonom makine algısına daha uygun hale getirilmesidir. Göselleştirme, görüntünün keskinleştirilmesi, görüntünün iyileştirilmesi, gürültülerin temizlenmesi, görüntünün tanınması gibi amaçlarla görüntü işleme teknolojilerinden faydalanılabilir (Aksoy, 2022).

Görüntüyü yakalamada ve sıralamada iyi bir cihaz kullanımı yapılacak işlemleri en aza taşıyabilir. Yine de görüntüyü iyileştirme için farklı filtrelerin uygulanması gerekir. Araştırmada görüntünün iyileştirilmesi ve özellik çıkarımının yapılabilmesi için Çizelge 3.4'te belirtilen filtrelerden yararlanılmıştır.

Çizelge 3.4. Araştırmada kullanılan resim iyileştirme filtreleri ve temel fonksiyonları*

Filtreler	Temel fonksiyonları
Laplace Filtresi	Laplace filtresi her yöndeki keskinleştirme yapmaya olanak sağlar
Average Filtresi	Resimde gri düzeyler arasındaki keskin geçişleri azaltmak için, resimdeki her bir piksel değerini kendisinin ve komşularının da içinde yer aldığı ortalama değer ile değiştirerek tekrar hesaplama yapmayı sağlar
Gaussian Filtresi	Gauss filtreleme işlemi ile sonsuz bir transfer fonksiyonuna bedel mekânsal alanda sonlu bir pencerede (tarama penceresi) filtreleme yapılabilmeyi sağlamaktadır. Böylece filtrelemenin ana problemini daha kolay çözülebilir şekle getirmektedir. Avantaj olarak da filtreleme önce yatay ardından çıkan sonuçla düşey ekseninde gerçekleştirilebilmektedir. Yani düzleştirme işlemi yapmaktadır.
Medyan Filtresi	Medyan filtreleme yönteminde, orijinal sıralanmış piksel değeri komşu piksel değerlerinin ortalaması ile değiştirmek yerine (mean filtresi), komşu pikselleri sıralayıp sıranın ortasındaki değeri alır, resimde bulunan keskin geçişlerin yok edilmesini ve resimdeki gürültüyü azaltmayı amaçlar.
Unsharp Filtresi	Resimdeki keskin geçişleri ve ayrıntıları, belirginleştirmek, bulanıklaştırılmış

Blurring Filtresi	görüntülerdeki ayrıntıları yeniden ortaya çıkarmak yani netleştirmek için kullanılan bir filtredir. Resimdeki gürültüyü azaltmak ya da daha az pikseli bir görüntü oluşturmak için kullanılan görüntü bulanıklaştırma yöntemine denir.
--------------------------	---

*Anonim, 2022d

Özellik çıkarma (kenar belirleme) yöntemi görüntü tanıma işlemine giren görüntüden elde edilen özellikleri modelin özellikleriyle eşleştirme işlemine denir. Görüntüdeki belli özellikler ve bu özelliklere bağlı olarak belli noktalar belirlenir ve gruplandırılır. Özellik çıkarma filtresi tek renkle dolu olan alanların içini boşaltmak ve yatay, dikey ve diyagonal kenarları belirginleştirmek için kullanılır. Böylelikle nesnenin, lekelerin ve dokuların dış hatları ortaya çıkmış olacaktır (Sert, 2010).

Çizelge 3.5. Özellik çıkarma işleminde kullanılan filtreler ve temel fonksiyonları*

Filtreler	Temel fonksiyonları
LoG Filtresi	Bu filtreye Marr-Hildreth (Laplacian of Gaussian – LoG) algoritması da denir. Gaussian filtresine Laplası alınarak işlem yapar. Görüntülerde hızlı değişim (kenar) alanlarını bulmak için kullanılan türev filtresidir.
Canny Filtresi	Kenar algılamada çok etkin bir algoritmadır.
Roberts Filtresi	Bu filtre diagonal olarak kenar tarar.
Prewitt Filtresi	Bu filtrede sobel filtresi gibi düşey ve yatay keskinlik yakalar.
Sobel Filtresi	Sobel operatörü yatay ve düşey yönde keskinlikleri yakalar.

* Anonim, 2022d

Görüntü iyileştirme ve özellik çıkarma filtrelerinin kullanımından sonra elde edilen görüntülerin anlamlandırılıp tanımlanması amacıyla yorumlama adımına geçilmiştir. Bu adımda, bir önceki adımdan gelen veriler göz önünde bulundurularak örnek üzerindeki lekeler ve hasar durumu belirlenip örnek boyut bulunmuş ve ürünün kalite sınıfı sınıflandırma algoritmaları kullanılarak elde edilmiştir. Araştırmada kullanılan sınıflandırma algoritmaları Çizelge 3.6’da verilmiştir.

Çizelge 3.6. Yorumlama işleminde kullanılan sınıflandırıcılar ve çalışma prensipleri*

Sınıflandırıcılar	Çalışma prensipleri
Karar Ağacı	Regresyon ağacı ve karar ağacı ya da sınıflandırma ağacı olarak adlandırılır. Ağaç şeklinde kök düğümden yaprak düğüme kadar grafik ya da model kullanarak bir yanıtı ve onların olası sonuçlarını açıklayan karar destek aracıdır. Algoritma olarak tek yönlüdür. Makinaların öğrenmesinde ve yöneylem araştırmalarında bir hedefe varmak için en yakın stratejiyi bulmada kullanılan bir yöntemdir.
Naïve Bayes	Makul bir derecede eğitilmiş sınıfı belli verinin sisteme yüklenmesinden sonra sistemin veriler üzerinde yürütülen olasılık işlemleri, sisteme yüklenen yeni test verilerini, daha önce elde edilmiş olasılık değerlerine göre yürütür ve verilen test verisinin hangi sınıfa ait olduğunu olasılık ilkeleri ile tespit etmeye çalışan sınıflandırıcıdır.
Destek Vektör Makineleri	İleri beslemeli iki katmanlı yapay sinir ağına sahip olan sistem, bir sınıfın veri noktalarını diğer sınıfın veri noktalarından maksimum şekilde ayırarak bir hiperdüzlem bulmaya yarar. Eğitim kümesindeki tüm örnekler benzer ve bağımsız bir şekilde dağıtılır. Türetilen yapısal risk minimizasyonunu sağlamak için veri kümesindeki ortalama hata karesini mümkün olduğu kadar aşağı indirerek çalışır.
Yapay Sinir Ağları	İnsan beynindeki sinir hücrelerinin işlevini modelleyerek sınıflandırmada kullanılan akıllı insan davranışının bir simülasyonudur. Birbiriyle bağlantılı katmanlardan meydana gelmekte ve katmanlarda nöronlardan oluşmaktadır. Nöronların değeri Katmanlar arasındaki bağlantıların ağırlığına ve eşik değerine bağlı olarak değişim gösterebilmektedir. Yapay sinir ağlarında mevcut ve daha önce denenmemiş örneklerden girdi ve çıktılar arasındaki ilişkiler öğrenim ve çağrışım yoluyla çözülebilir.

* Anonim, 2022d

3.2.1 Confusion (Çapraşıklık) Matrisi

Bir algoritmanın kullanımında performansının görselleştirilmesine izin veren özel bir Çizelge şekline (Çizelge 3.7.), Confusion (Çapraşıklık) matrisi denir (Fawcett, 2006; Piryonesi and El-Diraby, 2020; Powers, 2011; Brooks ve ark., 2015; D. Chicco and G. Jurman, 2020,2021; Tharwat, 2018; Balayla, 2020).

Gerçek pozitif (TP)

Bir koşulun veya özelliğin varlığını doğru bir şekilde gösteren bir test sonucu.

Gerçek negatif (TN)

Bir koşulun veya özelliğin olmadığını doğru bir şekilde gösteren bir test sonucu.

Yanlış pozitif (FP)

Belirli bir koşulun veya özelliğin mevcut olduğunu yanlış bir şekilde gösteren bir test sonucu.

Yanlış negatif (FN)

Yanlış bir şekilde belirli bir koşulun veya özelliğin bulunmadığını gösteren bir test sonucu.

Doğruluk (ACC)

Doğru tahmin oranına denir. Doğru olarak bulun tahmin değerlerin tüm tahmin değerlere bölünmesiyle elde edilir.

F1 Puanı

Duyarlılık ve kesinliğin harmonik ortalamasıdır.

Çizelge 3.7. Bir Çapraşıklık Matrisinin terminolojisi ve türevleri

$Duyarlılık - Gerçek Pozitif Oranu (TPR) = \frac{TP}{P} = \frac{TP}{TP + FN}$
$Özgüllük - Gerçek Negatif Oranu (TNR) = \frac{TN}{N} = \frac{TN}{TN + FP}$
$Kesinlik - Pozitif Tahmin Oranu (PPV) = \frac{TP}{TP + FP}$
$Doğruluk (ACC) = \frac{TP + TN}{P + N} = \frac{TP + TN}{TP + TN + FP + FN}$
$F1 \text{ puanı} (F1) = \frac{PPV \times TPR}{PPV + TPR} = \frac{2TP}{2TP + FP + FN}$

3.2.2. VOSviewer programı

Bu programda nitel araştırma yöntemlerinden bibliyometrik araştırma yöntemi kullanılmaktadır. Bibliyometri, bilimsel yayınların bibliyografik öğelerinden toplanan bilgilerin sayısal analizler ve istatistikler yardımıyla araştırılması olarak ifade edilmektedir. Bibliyometrik analizler belirli bir zaman diliminde yayımlanan makale sayısının belirlenmesi tarzında açıklayıcı meziyetinde olabileceği gibi, ya da bir makalenin kendisinden sonra ortaya çıkan araştırmaları ne şekilde yönlendirdiğini görmek amacıyla değerlendirici nitelikte de olabilmektedir (Kulak, 2018; Çelik ve ark., 2021).

VOSviewer, bibliyometrik ağların görselleştirilmesinde kullanılmak amacıyla tasarlanmış bir bilimsel haritalama programıdır. Anahtar kelime, eş-bulunma analizi ve eş-yazarlılık analizleri ile birlikte atıf ağlarının görselleştirilmesi gibi çoğu bibliyometrik ağ analizini gerçekleştirebilmektedir. VOSviewer, uzaklık temelli görselleştirme yaklaşımına benimseyerek bibliyometrik ağları görselleştirmektedir. VOSviewer bilgi görselleştirmesinde program için özel olarak geliştirilmiş olan VOS (Visualization of Similarities) algoritmasını kullanmaktadır. Böylelikle bibliyometrik veri setleri içinde oluşturduğu belirlenen parametrelere bağlı olarak küme ve kümeler arasında bağlantıları ile ağ ve yoğunluk haritaları (heat map) oluşturmaktadır. Bilimsel haritalama için Web of Science, Scopus ve Pubmed veri setlerinin yanı sıra Pajek ağ dosyalarını da kullanabilmektedir (Anonim, 2023a).

4. BULGULAR

4.1 Giriş ve Hedef Matrislerinin Oluşturulması

Araştırmada Iğdır ilinde yaygın şekilde üretimi yapılmakta olan kayısı çeşitleri (Teberze, Şalak ve Ağarik) üreticilerinden her çeşit kayısıdan 250 adet olmak üzere 750 sağlam kayısı ve her çeşitten karışık olmak üzere 250 adet çürük kayısı toplamda 1000 adet örnek sayısı ile toplanmıştır. Bu sağlam kayısı örneklerin her çeşidinde 75 adedi şansa bağlı bloklar deneme desenine göre modeli test etmek için, geri kalan 175 adedi ise kayısının sınıflandırılma işlemini yapabilmek için model oluşturmada kullanılmıştır.

Araştırmanın ilk adımı olarak 16 Megapiksel çözünürlükte fotoğraflar donanımsal veya yazılımsal hiçbir filtre (özellik çıkarma, iyileştirme ve sınıflandırma) kullanılmadan çekilmiştir. Fotoğrafın renk paleti yayılarak histogram normalleştirilmiştir. Başlangıçta 3456*4068 piksel olan fotoğrafın köşelerdeki gölgeleri yok etmek için fotoğraf kırpılmış ve kırpmadan sonraki fotoğrafın çözünürlüğü 2000*2000 piksel olmuş ve fotoğraf üzerindeki gölge etkisi ortadan kaldırılmıştır. Daha sonra en-boy oranı korunarak 224*224 piksel boyutunda fotoğraf küçültülmüştür. Üzerinde aritmetik işlemler yapabilmek için resmi oluşturan piksel değerleri tam sayıdan çift hassasiyetli ondalık sayılara çevrilmiştir. Üç boyutlu resim ((R, G, B (Red, Green, Blu, kırmızı katman ortalaması, yeşil katman ortalaması, mavi katman ortalaması)) matrisi vektöre dönüştürülmüş ve daha sonra bu vektör yapay sinir ağlarını oluşturmak için kullanılan giriş matrisinin ilgili sütununa kaydedilmiştir. Örnek resmin ait olduğu tür hedef matrisinin ilgili sütununa tanıtılmıştır. Bu işlem her bir sınıftan tüm 175 kayısı örneği için de tekrar edilmiştir.


Yukarıda bahsi geçen normalleştirme, kırpma ve küçültme işlemlerinden önce ve sonra kayısı örneklerine ait fotoğrafların durumları Şekil 4.1 ilâ 4.4'te verilmiştir.



Şekil 4.1. Normalleştirme, kırpma ve küçültme işlemi uygulanan Ağırık Kayısı



Şekil 4.2. Normalleştirme, kırpma ve küçültme işlemi uygulanan Şalak Kayısı



Şekil 4.3. Normalleştirme, kırpma ve küçültme işlemi uygulanan Teberze Kayısı




Şekil 4.4. Normalleştirme, kırpma ve küçültme işlemi uygulanan Çürük Kayısı


4.2 Kullanılan Filtrelere Ait Sonuçlar

4.2.1 İyileştirme filtrelerine ait sonuçlar





Bütün sınıflandırma modelleri oluşturma ve eğitme başlığı altında yapılan işlemler her bir filtre için tekrarlanmış ve ham veriler (resimler) iyileştirme filtrelerinden geçirilerek algoritmalara test edilmek üzere gönderilmiştir. Örneklere ait detaylı resimler Şekil 4.5 ilâ 4.8’de verilmiştir.




Şekil 4.5. Ağırık Kayısı iyileştirme filtrelerinin uygulama örnekleri



Şekil 4.6. Şalak Kayısı iyileştirme filtrelerinin uygulama örnekleri

Average 	Blurring 
Gaussian 	Gri Tonlama 
Laplacian 	Median 
Unsharpen 	

Şekil 4.7. Teberze Kayısı iyileştirme filtrelerinin uygulama örnekleri




Şekil 4.8. Çürük Kayısı iyileştirme filtrelerinin uygulama örnekleri

4.2.2 Özellik Çıkarma Filtreleri

Yapay Sinir Ağları (ANN, Artificial Neural Networks), Destek Vektör Makinaları (SVM, Support Vector Machine), NB (Naïve Bayes), Sınıflandırma ve Regresyon Ağacı (CaRT, Classification and Regression Trees), için resmin dört farklı parametreyi R, G, B (Red, Green, Blu, kırmızı katman ortalaması, yeşil katman ortalaması, mavi katman ortalaması) ve Rhinithaa ve ark., (2018)’de belirtilen hesaplamalara göre yuvarlaklık bilgileri yukarıda bahsi geçen sınıflandırma yöntemlerinin veri setini oluşturmak amacıyla kullanmıştır.

4.2.3 Sınıflandırma algoritmalarına ait sonuçlar

4.2.3.1 Karar Ağacı sınıflandırmasına ait sonuçlar



Şekil 4.9. Karar Ağacı çapraşıklık (confusion) matrisi (1: Ağarik, 2:Şalak, 3: Teberze 4: Çürük)

Çizelge 4.1. Karar Ağacı sınıflandırmasına ait algoritma sonuçlar

	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Fpuanı
	Accuracy	Sensitivity	Specificity	Precision	Fscore
1 (Ağrik)	0,979	0,968	0,983	0,949	0,958
2 (Şalak)	0,967	0,932	0,979	0,936	0,934
3(Teberze)	0,984	0,968	0,989	0,968	0,968
4 (Çürük)	0,946	0,884	0,967	0,898	0,891
Ortalama	0,938	0,938	0,979	0,938	0,938


Oluşturulan Sınıflandırma ve Karar Ağacı çapraşıklık matrisi Şekil 4.9’da verilmiştir. Mavi kareler verilen örnekleri tanıma yüzdeleri, beyaz kareler doğru negatif, pembeler ise yanlış tanıma oranlarını temsil etmektedir.

Şekil 4.9 ve Çizelge 4.1’e bakıldığında Karar Ağacı sınıflandırma algoritması; Ağrik kayısını temsil eden 1 numarada, 250 adet Ağrik kayısından 242 tanesini Ağrik kayısı olarak doğru sınıflandırmış, geriye kalan 8 adet Ağrik Kayısından 1 tanesini Şalak kayısı, 1 tanesini Teberze kayısı ve 6 tanesini de Çürük kayısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %96,8 olarak bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 9 adedi ve Şalak kayısı sınıfından da 4 adedi Ağrik kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %94,9 oranında bulmuştur. Ağrik kayısı sınıflandırmasında özgüllük değeri %98,3 test doğruluk değeri %97,9 ve Fpuan değeri %95,8 olarak bulunmuştur.

Şalak kayısını temsil eden 2 numarada, 250 adet Şalak kayısından 233 tanesini Şalak kayısı olarak doğru sınıflandırmış, 4 tanesini Ağrik kayısı, 1 tanesini Teberze kayısı ve 12 tanesini Çürük kayısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %93,2 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 14 adedi, Ağrik kayısı sınıfından 1 adedi ve Teberze kayısı sınıfından da 1 adedi Şalak kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %93,6 oranında bulmuştur. Şalak kayısı sınıflandırmasında özgüllük değeri %97,9 test doğruluk değeri %96,7 ve Fpuan değeri %93,4 olarak bulunmuştur.

Teberze kayısısını temsil eden 3 numarada 250 Teberze kayısından 242 tanesini Teberze kayısısı olarak doğru sınıflandırmış, 1 tanesini Şalak kayısısı ve 7 tanesini Çürük kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %96,8 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 6 adedi, Ağırık kayısı sınıfından 1 adedi ve Şalak kayısı sınıfından da 1 adedi Teberze kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %96,8 oranında bulmuştur. Teberze kayısı sınıflandırmasında özgüllük değeri %98,9 test doğruluk değeri %98,4 ve Fpuan değeri %96,8 olarak bulunmuştur.


Çürük kayısısını temsil eden 4 numarada, 250 Çürük kayısından 221 adedini Çürük kayısısı olarak doğru sınıflandırmış, 9 tanesini Ağırık kayısısı, 14 tanesini Şalak kayısısı ve 6 tanesini Teberze kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %88,4 bulmuştur. Diğer taraftan algoritma Teberze kayısı sınıfından 7 adedi, Ağırık kayısı sınıfından 6 adedi ve Şalak kayısı sınıfından da 12 adedi Çürük kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %89,8 oranında bulmuştur. Çürük kayısı sınıflandırmasında özgüllük değeri %96,7 test doğruluk değeri %94,6 ve Fpuan değeri %89,1 olarak bulunmuştur.



Şekil 4.10. CRT kayısı tanıma grafiği (X1: Kırmızılık, X2: yeşillik, X3: mavilik, X4: yuvarlaklık) ; (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük).

Karar ağacı algoritması, mavi katman değeri (x_3), 5,13157 değerinden küçük, büyük veya eşit olmak üzere iki dala ayrılmaktadır. Mavi katman değeri (x_3), 5,13157 değerinden küçük olduğunda kırmızı katman değeri (x_1), 8,20497 değerinden küçük, büyük veya eşit olmak üzere ikiye ayrılıyor. Kırmızı katman değeri (x_1), 8,20497 değerinden büyük olduğunda algoritma örnek resmin Teberze kayısısı olduğuna karar vermektedir. Kırmızı katman değeri (x_1), 8,20497 değerinden küçük olduğunda yuvarlaklık değeri (x_4) 0,962742 değerinden küçük ve büyük olmak üzere ikiye ayrılmaktadır. Yuvarlaklık değeri (x_4) 0,962742 değerinden küçük olduğunda örnek resmin çürük kayısı olduğuna karar vermektedir. Yuvarlaklık değeri (x_4) 0,962742 değerinden büyük olduğunda örnek resmin Şalak kayısısı olduğuna karar vermektedir. Bu dal böylelikle devam etmektedir.


Karar ağacı algoritması, mavi katman değeri (x_3), 5,13157 değerinden büyük olduğunda mavi katman değeri (x_3), 12,898 değerinden küçük ve büyük veya eşit olarak iki dala ayrılmaktadır. Mavi katman değeri (x_3), 12,898 değerinden büyük veya eşit olduğunda kırmızı katman değeri (x_1) 32,6746 değerinden küçük ya da büyük veya eşit olmak üzere ikiye ayrılmaktadır. Kırmızı katman değeri (x_1) 32,6746 değerinden küçük olduğunda algoritma örnek resmin Ağırık kayısısı olduğuna karar verirken, kırmızı katman değeri (x_1) 32,6746 değerinden büyük veya eşit olduğunda ise algoritma örnek resmin Çürük kayısısı olduğuna karar vermektedir. Bu dallanma şekil 4.10'da görüldüğü gibi devam edip gitmektedir.



Şekil 4.11. CRT saçılım (scatter) grafiği

Karar ağacı algoritması saçılım grafiğinde yuvarlak mavi şekiller Ağırık Kayısı, artı pembe şekiller Şalak Kayısı, yuvarlak koyu kırmızı şekiller Teberze Kayısı ve siyah x şekiller de Çürük Kayıları temsil etmektedir.

4.2.3.2. Naïve Bayes sınıflandırmasına ait sonuçlar



Şekil 4.12. Naïve Bayes sınıflandırmasına ait çapraşıklık (Confusion) Matrisi (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük)

Çizelge 4.2. Naïve Bayes sınıflandırmasına ait algoritma sonuçları

	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Fpuanı
	Accuracy	Sensitivity	Specificity	Precision	Fscore
1 (Ağırık)	0,895	0,820	0,920	0,774	0,796
2 (Şalak)	0,795	0,784	0,799	0,565	0,657
3(Teberze)	0,923	0,976	0,905	0,775	0,864
4 (Çürük)	0,789	0,224	0,977	0,767	0,347
Ortalama	0,851	0,701	0,900	0,720	0,666

Oluşturulan Sınıflandırma ve Naïve Bayes çapraşıklık matrisi Şekil 4.12’de verilmiştir. Mavi kareler verilen örnekleri tanıma yüzdeleri, beyaz kareler doğru negatif, pembeler ise yanlış tanıma oranlarını temsil etmektedir.


Şekil 4.12 ve Çizelge 4.2’Ye bakıldığında Naïve Bayes sınıflandırma algoritması; Ağırık kayısısını temsil eden 1 numarada, 250 adet Ağırık kayısısından 205 tanesini Ağırık kayısısı olarak doğru sınıflandırmış, geriye kalan 45 adet Ağırık Kayısısından 34 tanesini Şalak kayısısı, 6 tanesini Teberze kayısısı ve 5 tanesini de Çürük kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %82,0 olarak bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 36 adedi ve Şalak kayısı sınıfından da 24 adedi Ağırık kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %77,4 oranında bulmuştur. Ağırık kayısı sınıflandırmasında özgüllük değeri %92,0 test doğruluk değeri %89,5 ve Fpuan değeri %79,6 olarak bulunmuştur.

Şalak kayısısını temsil eden 2 numarada, 250 adet Şalak kayısısından 196 tanesini Şalak kayısısı olarak doğru sınıflandırmış, 24 tanesini Ağırık kayısısı, 18 tanesini Teberze kayısısı ve 12 tanesini Çürük kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %78,4 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 111 adedi, Ağırık kayısı sınıfından 34 adedi ve Teberze kayısı sınıfından da 6 adedi Şalak kayısı olarak yanlış sınıflandırmış ve kesinlik değerini %56,5 oranında bulmuştur. Şalak kayısı sınıflandırmasında özgüllük değeri %99,9 test doğruluk değeri %99,5 ve Fpuan değeri %65,7 olarak bulunmuştur.

Teberze kayısısını temsil eden 3 numarada 250 Teberze kayısıdan 244 tanesini Teberze kayısısı olarak doğru sınıflandırmış, 6 tanesini Şalak olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %97,6 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 47 adedi, Ağırık kayısı sınıfından 6 adedi ve Şalak kayısı sınıfından da 18 adedi Teberze kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %77,5 oranında bulmuştur. Teberze kayısı sınıflandırmasında özgüllük değeri %90,5 test doğruluk değeri %92,3 ve Fpuan değeri %86,4 olarak bulunmuştur.

Çürük kayısısını temsil eden 4 numarada, 250 Çürük kayısıdan 56 adedini Çürük kayısısı olarak doğru sınıflandırmış, 36 tanesini Ağırık kayısısı, 111 tanesini Şalak kayısısı ve 47 tanesini Teberze kayısısı olarak yanlış sınıflandırmıştır. Test duyarlılık oranını %22,4 bulmuştur. Diğer taraftan algoritma Ağırık kayısı sınıfından 5 adedi ve


Şalak kayısı sınıfından da 12 adedi Çürük kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %76,7 oranında bulmuştur. Çürük kayısı sınıflandırmasında özgüllük değeri %97,7 test doğruluk değeri %78,9 ve Fpuan değeri %34,7 olarak bulunmuştur.



Şekil 4.13. Naïve Bayes sınıflandırmasına ait saçılım (scatter) grafiği

Naive Bayes algoritması scatter grafiğinde yuvarlak mavi şekiller Ağırık, artı pembe şekiller Şalak, yuvarlak koyu kırmızı şekiller Teberze ve siyah x şekiller de Çürük kayısıları temsil etmektedir.

4.2.3.3. Destek vektör makinaları algoritması



Şekil 4.14. Destek Vektör Makinaları algoritmasına ait çapraşıklık (confusion) matrisi
(1: Ağelik, 2:Şalak, 3: Teberze 4: Çürük)

Çizelge 4.3. Destek Vektör Makinaları algoritma sonuçları

	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Fpuanı
	Accuracy	Sensitivity	Specificity	Precision	Fscore
1 (Ağelik)	0,985	0,972	0,989	0,968	0,970
2 (Şalak)	0,880	0,768	0,917	0,756	0,762
3(Teberze)	0,956	0,976	0,949	0,865	0,917
4 (Çürük)	0,829	0,584	0,911	0,685	0,631
Ortalama	0,985	0,972	0,989	0,968	0,970

Oluşturulan Destek Vektör Makinaları Algoritma çapraşıklık matrisi şekil 4.14'te verilmiştir. Mavi kareler verilen örnekleri tanıma yüzdeleri, beyaz kareler doğru negatif, pembeler ise yanlış tanıma oranlarını temsil etmektedir.


Şekil 4.14 ve Çizelge 4.3'e bakıldığında Destek Vektör Makinaları sınıflandırma algoritması; Ağırık kayısısını temsil eden 1 numarada, 250 adet Ağırık kayısısından 243 tanesini Ağırık kayısısı olarak doğru sınıflandırmış, geriye kalan 7 adedi de Çürük kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %97,2 olarak bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 7 adedi ve Şalak kayısı sınıfından da 1 adedi Ağırık kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %96,8 oranında bulmuştur. Ağırık kayısı sınıflandırmasında özgüllük değeri %98,9 test doğruluk değeri %98,5 ve Fpuan değeri %97,0 olarak bulunmuştur.

Şalak kayısısını temsil eden 2 numarada, 250 adet Şalak kayısısından 192 tanesini Şalak kayısısı olarak doğru sınıflandırmış, 1 tanesini Ağırık kayısısı, 2 tanesini Teberze kayısısı ve 55 tanesini Çürük kayısısı olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %76,8 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 61 adedi ve Teberze kayısı sınıfından da 1 adedi Şalak kayısı olarak yanlış sınıflandırmış ve kesinlik değerini %75,6 oranında bulmuştur. Şalak kayısı sınıflandırmasında özgüllük değeri %91,7 test doğruluk değeri %88,0 ve Fpuan değeri %76,2 olarak bulunmuştur.

Teberze kayısısını temsil eden 3 numarada 250 Teberze kayısıdan 244 tanesini Teberze kayısısı olarak doğru sınıflandırmış, 1 tanesini Şalak olarak ve 5 tanesini de Çürük olarak yanlış sınıflandırmıştır. Buna rağmen duyarlılık oranını %97,6 bulmuştur. Diğer taraftan algoritma Çürük kayısı sınıfından 36 adedi ve Şalak kayısı sınıfından da 2 adedi Teberze kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %86,5 oranında bulmuştur. Teberze kayısı sınıflandırmasında özgüllük değeri %94,9 test doğruluk değeri %95,6 ve Fpuan değeri %91,7 olarak bulunmuştur.

Çürük kayısısını temsil eden 4 numarada, 250 Çürük kayısıdan 146 adedini Çürük kayısısı olarak doğru sınıflandırmış, 7 tanesini Ağırık kayısısı, 61 tanesini Şalak kayısısı ve 36 tanesini Teberze kayısısı olarak yanlış sınıflandırmıştır. Test duyarlılık oranını %58,4 bulmuştur. Diğer taraftan algoritma Ağırık kayısı sınıfından 7 adedi, Teberze kayısı sınıfından 5 adedi ve Şalak kayısı sınıfından da 55 adedi Çürük kayısı olarak yanlış sınıflandırmasına rağmen kesinlik değerini %68,5 oranında bulmuştur. Çürük kayısı


sınıflandırmasında özgülük değeri %91,1 test doğruluk değeri %82,9 ve Fpuan değeri %63,1 olarak bulunmuştur.



Şekil 4.15. Destek Vektör Makinaları algoritmasına ait saçılım (scatter) grafiği


Destek Vektör Makinaları algoritması saçılım (scatter) grafiğinde yuvarlak mavi şekiller Ağarik, artı pembe şekiller Şalak, yuvarlak koyu kırmızı şekiller Teberze ve siyah x şekiller de Çürük kayısıları temsil etmektedir.

4.2.3.4. Yapay sinir ağı algoritmasına ait sonuçlar



Şekil 4.16. Yapay Sinir Ağı algoritmasına ait training algoritma görseli


Yapay Sinir Ağı Algoritmasına Ait Training Algoritma Görseli Şekil 4.16’da görüldüğü üzere Eğitim Fonksiyonu Scaled Conjugate Gradient, Transfer Fonksiyonu (gizli katman) Tangent Sigmoid, Aktivasyon Fonksiyonu (çıkış katmanı) Softmax ve Performans Fonksiyonu: Cross Entropy olarak ayarlanmıştır.



Şekil 4.17. Desen tanıma ve sınıflandırmaya ait ağ diyagramı

Elde edilen 1000 kayısı örneğine ait matrisler yapay sinir ağları'nda (YSA) kullanılmak üzere desen tanıma ve sınıflandırma (pattern recognition and classification) uygulamasına tabi tutulmuştur. Gizli katman boyutu 10 nörona olmaktadır. Tüm kayısı çeşitlerine ait 1000 kayısı örneğinin %70'i eğitim verisi, %15'i doğrulama verisi ve %15'i test verisi olarak kullanılmıştır. Ağın performansı %0.001'in altına düşüne


kadar ağ eğitimi tekrarlanmıştır. Ağ istenen performansa ulaştıktan sonra 1000 kayısı örneğinin tamamı eğitilen ağa tabi tutularak sınıflandırılmıştır. Oluşturulan yapay sinir ağına ait blok diyagramı Şekil 4.17’de verilmiştir. İnpıt (50176) değeri 224*224 piksele küçültülen resim boyutunun tek bir sütun haline getirilmesinden elde edilen satır bilgisidir. Hidden başlığı altındaki 10 değeri ise gizli katman sayısıdır. Yapay sinir ağlarında öğrenimi genelleştirme kabiliyetini artırmak ve aşırı öğrenmeyi (overfitting) engellemek için düşük sayıda nöron ve gizli katman sayılarından başlanarak en uygun ağ yapısı bulunana dek eğitim sürmüştür.



Şekil 4.18. YSA’ya ait eğitim-performans eğrileri

Oluşturulan yapay sinir ağına ait eğitim-performans şeması Şekil 4.18’de verilmiştir. Grafikte verilen eğrilerin üzerindeki her bir kırık çizgi bir eğitimi ifade eder ve toplam 19 epochs (eğitim) sonucunda Cross-entropy (bilgi yitimi) %0.001 düzeyine indirilmiştir. (Yeşil doğrulama, kırmızı test etme ve mavi eğitim çizgisi). Ağ eğitimine ait performans eğrilerine baktığımızda yeşil sürekli çizgiyle gösterilen doğrulama eğrisinin ve kırmızı sürekli çizgiyle gösterilen test eğrisinin eğitim yinelemeleri (epochs/iteration) boyunca benzer bir hata (MSE) seyri izledikleri görülmektedir. Bu

durum, ağ eğitiminde istenmeyen bir durum olan aşırı öğrenme (overfitting)'nin gerçekleşmediğini göstermektedir.




Şekil 4.19. Yapay Sinir Ağları (YSA) çapraşıklık (confusion) matrisleri (1: Ağırık, 2:Şalak, 3: Teberze 4: Çürük)

Çizelge 4.4. Yapay Sinir Ağlarına ait algoritma sonuçları

	Doğruluk Accuracy	Duyarlılık Sensitivity	Özgüllük Specificity	Kesinlik Precision	Fpuanı Fscore
1 (Ağırık)	1	1	1	1	1
2 (Şalak)	1	1	1	1	1
3(Teberze)	1	1	1	1	1
4 (Çürük)	1	1	1	1	1
Ortalama	1	1	1	1	1


Şekil 4.19 ve Çizelge 4.4'e bakıldığında Yapay Sinir Ağları sınıflandırma algoritması; Ağarik, Şalak, Teberze ve Çürük kayısıları %100 doğru olarak sınıflandırdığından, Doğruluk, Duyarlılık, Özgüllük, Kesinlik ve Fpuanı test sonuçlarını 1 olarak bulmuştur.

Oluşturulan yapay sinir ağına ait eğitim, doğrulama, test ve çapraşıklık matrisleri Şekil 4.19'da verilmiştir. Yeşil kısımlar verilen örnekleri tanıma yüzdeleri, kırmızı kareler yanlış tanıma oranlarını, beyaz kısımlar örneği tanımama oranlarını ve gri kısımlar ise bu üçünün toplamındaki doğru ve yanlış sınıflandırmayı sembolize etmektedir.




Şekil 4.20. Yapay Sinir Ağları hata histogramı

Oluşturulan yapay sinir ağına ait eğitim, doğrulama, test ve çapraşıklık matrisleri hata histogramı şekil 4.20'de görüldüğü üzere normal dağılım sergilemektedir. Doğrulama, test ve eğitim çizgileri içerisinde geçen çizgi hatanın sıfır olduğu noktadır. Dolayısıyla YSA algoritmasının hata oranının 0.001 oranında neredeyse sıfır olduğunu söylenebilir.



Şekil 4.21. Oluşturulan Yapay Sinir Ağlarına ait eğitim, doğrulama, test ve çapraşıklık matrislerinin ROC Eğrileri

Herhangi bir sınıflandırma modelinin performansını kontrol etmek için en önemli değerlendirme ölçütlerinden biri ROC eğrisidir. Genellikle, başarılı modeller arsanın sol üst kısmına eğilen eğriler ile temsil edilir. Kullandığımız yapay sinir ağları modelinin ROC eğrisi Şekil 4.21’de görüldüğü üzere %100 başarı ile sonuçlanmıştır.



Şekil 4.22. Yapay Sinir Ağları eğitim durumu, training phase ve kayıplar grafiği

Kayıp değerler grafiğine baktığımızda (Şekil 4.22) grafikte hızlı bir düşüş görülmüş ve kayıp değerler grafiğın alt bölümüne paralel olmaya başladığı zaman kullanılan mimarinin optimum seviyeye geldiği söylenebilir.

4.3 Tartışma

Bu bölümde araştırmaya ait bulgular sunularak tartışılmıştır. Buna göre; bu tez çalışması kapsamında dört farklı kayısı çeşidinin (Ağırık Kayısı, Şalak Kayısı, Teberze Kayısı, Çürük Kayısı) sınıflandırma işlemlerinin başarı oranları Çizelge 4.5'te paylaşılmıştır.

Çizelge 4.5. Sınıflandırma Algoritmalarının Sonuçları

		Doğruluk	Duyarlılık	Özgüllük	Kesinlik	Fpuanı
		Accuracy	Sensitivity	Specificity	Precision	Fscore
YSA	Ağerik	1	1	1	1	1
	Şalak	1	1	1	1	1
	Teberze	1	1	1	1	1
	Çürük	1	1	1	1	1
	Ortalama	1	1	1	1	1
CART	Ağerik	0,979	0,968	0,983	0,949	0,958
	Şalak	0,967	0,932	0,979	0,936	0,934
	Teberze	0,984	0,968	0,989	0,968	0,968
	Çürük	0,946	0,884	0,967	0,898	0,891
	Ortalama	0,969	0,938	0,980	0,938	0,938
DVM	Ağerik	0,985	0,972	0,989	0,968	0,970
	Şalak	0,880	0,768	0,917	0,756	0,762
	Teberze	0,956	0,976	0,949	0,865	0,917
	Çürük	0,829	0,584	0,911	0,685	0,631
	Ortalama	0,913	0,825	0,942	0,819	0,820
NB	Ağerik	0,895	0,820	0,920	0,774	0,796
	Şalak	0,795	0,784	0,799	0,565	0,657
	Teberze	0,923	0,976	0,905	0,775	0,864
	Çürük	0,789	0,224	0,977	0,767	0,347
	Ortalama	0,851	0,701	0,900	0,720	0,666

Araştırma bulguları Çizelge 4.5'te toplu olarak verilmiştir. Analizler içerisinde duyarlılık faktörü araştırmamız için son derece önemlidir. Çünkü dört sınıf kayısının (Ağerik, Şalak, Teberze ve Çürük) her birinin birbirinden ayrılması ve özellikle çürük ve

sağlam olarak ayrılması çok önemlidir. Bundan dolayı duyarlılık analizi esas olarak ele alınmıştır.

Araştırma bulgularına bakıldığında Ağarik, Şalak, Teberze ve Çürük kayısılarında en iyi sınıflandırma sonucunu yapay sinir ağlarının (% 100) bulduğu görülmektedir. Yapay sinir ağları örüntü tanıma ve sınıflandırma işlemlerinde son derece iyi sonuçlar veren ve çok tercih edilen bir algoritmadır. Nitekim literatürde de benzer yorumlar yapılmaktadır. Örneğin, Yapay sinir ağları insan beyninin en temel özelliği olan öğrenme fonksiyonunu oluşturan (Korkmaz, 2022) ve insan beyninin olaylar karşısında verdiği tepkileri örnek alarak, başka olaylar karşısında vereceği tepkileri belirleyen bilgisayar sistemlerinden oluştuğu ifade edilmiş (Öztemel, 2006) ve böylelikle diğer algoritmalarından farklılığı açık bir şekilde ortaya konulmuştur. Literatüre baktığımızda araştırma bulgularımıza benzerlik gösteren çalışmalar mevcuttur. Örneğin, Yılmaz Kızılboğa (2021), veri sayısı artıkça yapay sinir ağları zaman ve başarı açısından destek vektör makinaları ve k-en yakın komşu (k-NN) algoritmasına göre daha iyi sonuçlar verdiğini ifade etmiştir. Parpinello ve ark., (2007), kayısı kalite kontrolünde yapay sinir ağlarının %90 oranında başarı sağladığını ifade etmişlerdir. Ayaz ve ark., (2017), 7 farklı kayısı ağaçlarının yapraklarını sınıflandırmada yapay sinir ağlarının %98,6 oranında başarı gösterdiğini belirtmişlerdir. Mozaffari ve ark., (2022) kayısı olgunluk seviyesini yapay sinir ağları %97,4 ile kısmi en küçük kareler regresyonu ve temel bileşen analizi sınıflandırmalarına oranla daha iyi bulduğunu ifade etmişlerdir. Büyükarıkan ve Ülker (2020), evrimsel sinir ağları algoritması ile meyve sınıflandırma işlemlerinde %100 başarı yakalamışlardır. Yıldız ve ark. (2015), 50°C, 60°C ve 70°C muz kurutma işlemlerinde tüm veriler için R^2 değerini 0,9985, Khazaei ve ark. (2013) üzüm kurutma nem oranının R^2 değerini 0,9995, Motevali ve ark. (2013) dereotu kurutma işleminde R^2 değerini 0,9990 Kurtulmuş ve ark. (2020) kayısı kurutma işleminde R^2 değerini 0,96 olarak yapay sinir ağları ile elde ettiğini belirtmişlerdir. Şalvarcı ve Ayten (2019), yapay sinir ağları ile yumurta ve portakal ağırlık tahminlerinde %98'in üzerinde başarı yakaladıklarını ifade etmişlerdir. Kurtulmuş (2012), yaptığı çalışmada yapay sinir ağları, karar ağacı, naive bayes ve destek vektör makinaları arasında en iyi sonucun yapay sinir ağları tarafından bulunduğunu belirtmiştir. Ramos (2003), meyvelerin ağırlığı, çapı ve desen özellikleri bakımından sınıflandırılmasında yapay sinir ağlarının istenilen

sonuçları verebileceğini belirtmiştir. Azizi ve ark., (2016), yapay sinir ağları kullanarak 10 çeşit patates sınıflandırılmasında %100 başarı yakaladığını belirtmişlerdir.

Genel olarak algoritmaların kayısı tanıma işleminde Teberze Kayısını yapay sinir ağları (%100), destek vektör makinaları ve naive bayes (%97,6), karar ağacı (%96,8) tanıma oranlarıyla sınıflar içinde diğerlerine nispeten en yüksek derecede bulmuşlardır. Bunun nedeni olarak Teberze Kayısının Şalak ve Ağelik Kayısından boyut olarak farklılığı (Şalak ve Ağelik Kayısına oranla biraz küçük olması) söylenebilir. Ayrıca Ağelik Kayısını yapay sinir ağları (%100), destek vektör makinaları (%97,2), karar ağacı (%96,8), naive bayes (%82) tanıma oranlarıyla ve Şalak Kayısını yapay sinir ağları (%100), karar ağacı (%93,8), naive bayes (%78,4), destek vektör makinaları (%76,8) oranıyla tanımıştır. Bunun nedeni Ağelik Kayısının Şalak Kayısına oranla renginin açık olması söylenebilir. Nitekim literatüre bakıldığında kayısı çeşitleri arasında renk, en, boy kalınlık ve geometrik ortalama çap değerlerinin farklılık gösterdiği ifade edilmiştir (Özyörük ve Güleriyüz, 1992; Muradoğlu ve ark., 2011; Altıkat ve Temiz, 2019; Domaç Yaşar, 2022). Boyut ve renk farklılığından dolayı algoritmalar Teberze, Ağelik ve Şalak kayısıları sınıflandırmada genel olarak başarı yakaladığı söylenebilir.

Fakat Çürük Kayısı sınıflandırma oranına bakıldığında naive bayes algoritması (%22,4) ve destek vektör makinaları algoritması (%58,6) dört algortmadan en düşük performansı sergiledikleri görülmüştür. Çünkü çürük olarak seçilen 250 kayısının içerisinde abartı derecede çürük kayısıların olmaması ve sağlam kayısılarla az derecede göze çarpacak farklılığın bulunmasından kaynaklanabilir. Nitekim toplandığı yerden pazara sürülen ya da depolanan kayısı lüks denilen birinci sınıf kayısılardır. Yani kayısı üzerinde ezik, çizik, çürük vb. kusurların olmaması gerekmektedir. Böylelikle lüks kayısılar gerek yurtiçi ve gerek yurtdışı pazarına ulaşımını ve depolamasında ki ekonomik ömrünü uzatacağı ve daha yüksek fiyata alıcı bulacağı bilinmektedir. Bunun içindir ki çürük olarak seçilen kayısılar arasında birinci sınıf lüks kayısı olmayanlarda bulunduğundan naive bayes ve destek vektör makinaları algoritmalarının performanslarını etkilediği söylenebilir. Üstüner ve şanlı (2019), kullanılan sınıflandırma algoritmalarının karakteristiğine bağlı olarak, aynı eğitim veri seti kullanılmasına rağmen farklı sonuçlar elde edilebileceğinin bir kanıtı olabileceğini ifade etmişlerdir. Ayrıca literatüre baktığımızda çalışmamıza benzerlik gösteren çalışmalar mevcuttur. Örneğin Kurtulmuş

(2012), öznitelikler arasındaki karmaşık interaksiyonlarla başa çıkmadaki yetersizliğinden dolayı özellikle naive bayes sınıflandırıcısının diğer danışmanlı öğrenme yöntemlerine göre daha az doğru sonuçlar verdiği bilinen bir gerçek olduğunu ve sınıflandırma performansını garanti edemediğini belirtmiştir. Üstüner ve Şanlı (2019), destek vektör makinaları algoritmasının yem bitkisi sınıfında diğer algoritmalarla oranla en düşük değerleri verdiğini ifade etmiştir. Azarmdel ve ark., (2020), beyaz ve kırmızı dut meyvesini olgunlaşmamış, olgunlaşmış ve fazla olgunlaşmış düzeyini sınıflandırırken destek vektör makinalarının yapay sinir ağlarına oranla daha düşük sınıflandırma başarısı yakaladığını belirtmişlerdir. Syazwani ve ark., (2022), ananas meyvesinin tanımı ve sayımı için yaptıkları çalışmada yapay sinir ağlarının destek vektör makinaları ve K-en yakın komşuya oranla daha iyi sonuç bulduğunu, destek vektör makinaları ve K-en yakın komşu naive bayese oranla daha iyi sonuç bulduğunu ve naive beyes de karar ağacı ve rastgele ormana oranla daha iyi sonuç bulduğunu belirtmişlerdir.

Araştırmamızdan farklı olan sonuçlarda literatürde mevcuttur. Örneğin, Yang ve ark. (2019), Çin/Sincan eyaletinde 4 çeşit kayısı (Yinxiangbai (YXB), Yangmei (YM), Meyvelerden Tao (TAO) ve Shushanggan (SSG)) sınıflandırmasında naive bayes, yapay sinir ağları, karar ağacı, K-en yakın komşu, lineer diskriminant analizi ve destek vektör makinaları kullandığı algoritmalarından en iyi sonucu destek vektör makinaları %90.7 ile bulduklarını ve bu sonucun kayısıların şekillerinin oldukça birbirinden farklı olmasından kaynaklanabileceğini ifade etmişlerdir.

5. SONUÇ ve ÖNERİLER

Ağırık Kayısı, Şalak Kayısı, Teberze Kayısı ve Çürük Kayısı sınıflandırılması kayısının depolanmasında ve pazara sunulmasında büyük önem taşımaktadır. Genellikle bu işlemler insan gözüyle yapıldığından emek ve zaman kaybı ile birlikte ekonomik olarak da külfet olduğu, teknolojinin gelişmesi ve bilgisayarlı görmenin artması ile bu sorunun üstesinden gelineceği açık şekilde görülmektedir. Bu sebeple mevcut çalışmanın sektöre zaman, emek ve ekonomik olarak büyük katkı sağlayacağı düşünülmektedir. Geliştirilen script ile yeni yöntem ve eski yöntem arasındaki farkın anlaşılacağı ve gözlem yoluyla yapılan hataları minimize edileceği tahmin edilmektedir. Gelecekte kullanılan algoritmaların geliştirilmesi ile birlikte daha az zaman ve emek harcanarak daha ekonomik kazanımların sağlanması kaçınılmaz olacaktır. Böylelikle üç boyutlu kameralar ile bu işlem daha hızlı ve daha yaygın olarak kullanılabilir. Geliştirilen script ile gerek kayısı toplama aşamasında gerek kayıların sepetlenmesinde ve gerek depolanma aşamasında kayıların sınıflandırılmasında çalışan işçi sayısı azaltılacağından ekonomik olarak büyük katkı sağlayacağı ve en önemlisi çürüklerin sağlam kayılardan ayrılmasında önemli bir rol oynayacağı aşikârdır. Böylelikle çürük kayıların sağlam kayıları bozması engellenmiş olacak ve pazarda fiyat düşüşüne gerek kalmayacağı, kayısı üreticisinin daha fazla kazanç elde edeceği tahmin edilmektedir. Literatürden edinilen bilgiler ve araştırmadan edinilen sonuçlara bakıldığında geliştirilen öneriler aşağıdaki gibi sırayla belirlenmiştir.

1. Daha fazla materyal elde ederek çalışmalar yapılabilir
2. Kayısı örnekleri seçilirken sadece lüks kayısı sınıfı değil ikinci ve üçüncü kalite kayıların seçilerek sınıflandırmalar yapılabilir.
3. Farklı illerde yetişen farklı kayısı tipleri ve farklı algortimalar ile denemeler yapılabilir.
4. Kayıların bant üzerinde ayrımı yapılacağı düşünüldüğünden önerilen bantta yüzeyin beyaz olması algoritmanın tanıma oranını artıracaktır tahmin edilmektedir.
5. Farklı meyve türlerinde algoritmalar denenerek sınıflandırma çalışmaları yapılabilir.
6. Kayıların ağırlığını ölçmek için çalışması yapılabilir.

KAYNAKLAR

- Ağın, O. ve Malaslı, M. Z., (2016). **Görüntü işleme tekniklerinin sürdürülebilir tarımdaki yeri ve önemi: Literatür çalışması.** Tarım Makinaları Bilimi Dergisi, 12(3), 199-206.
- Ahmad, K.A.B, Othman, M., Abdullah, S.L.S., Ali, N.R. ve Dawam, S.R.M., (2019). **Mango Shape Maturity Classification Using Image Processing.** In 2019 4th International Conference and Workshops on Recent Advances and Innovations in Engineering (ICRAIE) (pp. 1-5). IEEE.
- Aksoy, O, E., (2022). **Görüntü İşleme Tabanlı Yüz İfadelerinden Duygu Analizi.** Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara. 86.
- Altıkat, S. ve Temiz, Ş., (2019). **Iğdır İli Kayısı Çeşitlerinin Fiziko-Mekanik ve Bazı Kimyasal Özellikleri.** Yüzüncü Yıl University Journal of Agricultural Sciences, 29(3), 373-381.
- Altıkat, S., Gülsoy, E., Küçükdem, H.K., Gülbe, A. (2016). Görüntü işleme ve yapay sinir ağları yardımıyla elma sınıflandırılması ve leke analizi, **BAP Projesi** (2016-FBE-B03). Iğdır
- Anonim, (2022a). **Food and Agriculture Organization** [FAO]. <https://www.fao.org/faostat/en/#home> Erişim Tarihi (19.12.2022).
- Anonim, (2022b). **Malatya Kayısı.** <http://www.malatya.gov.tr/kayisi-hasadi-kurutulmasi-ve-pazarlamasi>. Erişim Tarihi (20.01.2020).
- Anonim, (2022d). **Mathworks.** <https://www.mathworks.com/> Erişim Tarihi (24.10.2022).
- Anonim, (2023b). **Türkiye İstatistik Kurumu.** <https://data.tuik.gov.tr/> Erişim Tarihi (11.05.2023).
- Anonim,(2022c).Chromeextension://efaidnbmnnnibpcajpcglclefindmkaj/viewer.html?pdfurl=https%3A%2F%2Farastirma.tarimorman.gov.tr%2Fmarem%2FBelgeler%2FYeti%25C5%259Ftiricilik%2520Bilgileri%2FKay%25C4%25B1s%25C4

%25B1%2520Yeti%25C5%259Ftiricili%25C4%259Fi.pdf&cflen=2237047.

Eriřim Tarihi (20.01.2020).

Anonim,(2023a).<https://uzgoru.ikcu.edu.tr/S/15018/vosviewer#:~:text=VOSviewer%2C%20bibliyometrik%20a%C4%9Flar%C4%B1n%20g%C3%B6rselle%C5%9Ftirilmesi%20i%C3%A7in,bir%C3%A7ok%20bibliyometrik%20a%C4%9F%20analizini%20ger%C3%A7ekle%C5%9Ftirebilmektedir> Eriřim Tarihi (24.10.2022).

Arı, B., Arı, A., řengür, A. ve Tuncer, S.A., (2019). ***Classification of apricot leaves with extreme learning machines using deep features.*** In 2019 1st International Informatics and Software Engineering Conference (UBMYK) (pp. 1-5). IEEE.

Arora, B., Bhagat, N., Saritha, L. R. ve Arcot, S. (2020). ***Rice Grain Classification using Image Processing & Machine Learning Techniques.*** In 2020 International Conference on Inventive Computation Technologies (ICICT) (pp. 205-208). IEEE.

Asma, B.M., (2000). ***Kayıt Yetiřtiricilięi.*** Evin Ofset. Malatya. 243s.

Asma, B.M., (2011). ***Her yönüyle kayısı.*** Uyum Ajans, Ankara, 78-79.

Aubert, C. ve Chanforan, C., (2007). ***Postharvest changes in physicochemical properties and volatile constituents of apricot (Prunus armeniaca L.) Characterization of 28 cultivars.*** Journal Agricultural Food Chemistry, 55(8), 3074-3082.

Awokuse, T., (2008). ***Does Agriculture Really Matter for Economic Growth in Developing Countries?*** American Agricultural Economics Association Annual Meeting. Milwaukee, WI. 63(1), 77-99

Ayaz, F., Ari, A., & Hanbay, D. (2017, September). Leaf recognition based on artificial neural network. ***In 2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*** (pp. 1-5). IEEE.

Azarmdel, H., Jahanbakhshi, A., Mohtasebi, S. S. ve Muñoz, A. R., (2020). ***Evaluation of image processing technique as an expert system in mulberry fruit grading based on ripeness level using artificial neural networks (ANNs) and support vector machine (SVM).*** Postharvest Biology and Technology, 166, 111201.

- Azizi, A., Abbaspour-Gilandeh, Y., Nooshyar, M., & Afkari-Sayah, A. (2016). ***Identifying potato varieties using machine vision and artificial neural networks***. International Journal of Food Properties, 19(3), 618-635.
- Babalık, A. ve Botsalı, F. M., (2010). ***Yapay Sinir Ağı ve Görüntü İşleme Teknikleri Kullanarak Durum Buğdayının Camsılığının Belirlenmesi***. Selcuk University Journal of Engineering Sciences, 9(2), 163-174.
- Balayla, J., (2020). ***Prevalence threshold (ϕ e) and the geometry of screening curves***. Plos one, 15(10), e0240215.
- Balcı, M., Altun, A. A. ve Taşdemir, Ş., (2016). ***Görüntü işleme teknikleri kullanılarak Napolyon tipi kirazların sınıflandırılması***. Selçuk-Teknik Dergisi, 15(3), 221-237.
- Brooks, H., Brown, B., Ebert, B., Ferro, C., Jolliffe, I., Koh, T. Y. ve Stephenson, D., (2015). ***WWRP/WGNE Joint Working Group on Forecast Verification Research. Collaboration for Australian Weather and Climate Research***. World Meteorological Organisation.
- Büyükarıkan, B. ve Ülker, E. (2020). ***Aydınlatma Özniteliği Kullanılarak Evrimsel Sinir Ağı Modelleri İle Meyve Sınıflandırma***. Uludağ University Journal of The Faculty of Engineering, 25(1), 81-100.
- Chicco, D. ve Jurman, G., (2020). ***The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation***. BMC Genomics, 21(6).
- Çan, Z., (2021). ***Otomasyon sistemlerinde görüntü işleme tekniklerini kullanan ürün tanımı uygulaması***. Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya. 149.
- Çelik, E., Durmus, A., Adizel, O. ve Nergiz Uyar, H., (2021). ***A bibliometric analysis: what do we know about metals (loids) accumulation in wild birds?*** Environmental Science and Pollution Research, 28(8), 10302-10334.

- Demir, B., Çetin, N. ve Kuş, Z.A., (2016). **Görüntü İşleme Tekniği İle Yabancı Ot Renk Özelliklerinin Belirlenmesi**. Alinteri Journal of Agriculture Sciences, 31(2). 59-64
- Direk, M., (2012). **Tarım tarihi ve deontoloji**. Eğitim Yayınevi, Konya, 215
- Doğan, A., (2009). **Ekonomik Gelişme Sürecine Tarımın Katkısı: Türkiye Örneği**. Sosyal Ekonomik Araştırmalar Dergisi, 9(17), 365-392.
- Doğru Çokran, B. (2020). Aras Havzasında yetiştirilen Şalak (Aprikoz) kayısı çeşidinde klon seleksiyonu. Doktora Tezi, Ordu Üniversitesi Fen Bilimleri Enstitüsü, Ordu. 240.
- Domaç Yaşar, Y., (2022). **Türkiye’de Coğrafi İşaret Sistemi: Iğdır Kayısı Örneği**. Iğdır Üniversitesi Sosyal Bilimler Dergisi, (31), 220-242.
- Durukan, T., (2006). **Dünden bugüne girişimcilik ve 21.yüzyılda girişimciliğin önemi**. Girişimcilik ve Kalkınma Dergisi, 1(2), 25-37.
- Erkan, E., (2015). **Görüntü işleme tekniği kullanan bilgisayar destekli güvenlik sistemi tasarımı**. Yüksek Lisan Tezi, Kahramanmaraş Sütçü İmam Üniversitesi. Fen Bilimleri Enstitüsü, Kahramanmaraş. 93.
- Ertürk, Y.E., Geçer, M.K. ve Karadaş, K., (2016). **Iğdır ilinde kayısı üretimi ve pazarlaması**. Meyve Bilimi, 1, 44-49.
- Fawcett, T., (2006). **Introduction to receiver operator curves**. Pattern Recognit. Lett, 27, 861-874.
- Gallup, J., Radelet, S. ve Warner, A., (1997). **Economic Growth and the Income of the Poor**. CAER II Discussion Paper No. 36. Harvard Institute for International Development, Boston, MA.
- Gezer, I., Acaroğlu, M. ve Haciseferoğulları, H., (2003). **Use of energy and labour in apricot agriculture in Turkey**. Biomass and Bioenergy, 24(3), 215-219.
- Gül, H., (2021). **Antik çağ muhasebe sistemleri**. Duvar Yayınları, İzmir, 231-251.
- Günay, D., (2002). **Sanayi ve sanayi tarihi**. Mimar ve Mühendis Dergisi, 31, 8-14.

- Hallmann, E., Rozpara, E., Słowianek, M. ve Leszczyńska, J., (2019). ***The effect of organic and conventional farm management on the allergenic potency and bioactive compounds status of apricots (Prunus armeniaca L.)***. Food chemistry, 279, 171-178.
- Hayıt, T., Erbay, H. ve Hayıt, F., (2018). ***Gıda sektöründe uygulanan görüntü işleme çalışmalarının ve tekniklerinin incelenmesi***. Electronic Letters on Science and Engineering, 14(1), 12-22.
- Hof, A. ve Wolf, N., (2014). ***Estimating potential outdoor water consumption in private urban landscapes by coupling high-resolution image analysis, irrigation water needs and evaporation estimation in Spain***. Landscape and Urban Planning, 123, 61-72.
- Hungilo, G.G., Emmanuel, G. ve Emanuel, A.W., (2019). ***Image processing techniques for detecting and classification of plant disease: a review***. In Proceedings of the 2019 international conference on intelligent medicine and image processing (pp. 48-52).
- Irz, X., Lin, L., Thirtle, C. ve Wiggins, S., (2001). ***Agricultural Productivity Growth and Poverty Alleviation***. Development Policy Review, 19 (4), 449-466.
- Jayasinghe, C., Badenhorst, P., Jacobs, J., Spangenberg, G. ve Smith, K., (2021). ***Image-based high-throughput phenotyping for the estimation of persistence of perennial ryegrass (Lolium perenne L.)*** A review. Grass and Forage Science, 76(3), 321-339.
- Johnson, D.G., (1993). ***Role of agriculture in economic development revisited***. Agricultural economics, 8(4), 421-434.
- Kamilaris, A. ve Prenafeta-Boldú, F.X., (2018). ***Deep learning in agriculture: A survey***. Computers and electronics in agriculture, 147, 70-90.
- Karhan, M., (2011). ***İmge işleme yöntemleri ile kayısılarda yaprak delen hastalığı sonucu oluşan lekelerin tespiti***. Yüksek Lisans Tezi, Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü, Tekirdağ. 125.

- Kaymak, A. M., Örnek, M. N. ve Kahramanlı, H., (2019). **Görüntü İşleme Teknolojilerinin Elma Bahçelerine Yönelik Kullanım Örneği**. Uluborlu Mesleki Bilimler Dergisi, 2(1), 17-26.
- Khazaei, N.B., Tavakoli, T., Ghassemian, H., Khoshtaghaza, M.H. ve Banakar, A., (2013). **Applied machine vision and artificial neural network for modeling and controlling of the grape drying process**. Comput. Electron. Agr., 98, 205-213.
- Khojastehnazhand, M., Mohammadi, V. ve Minaei, S., (2019). **Maturity detection and volume estimation of apricot using image processing technique**. Scientia Horticulturae, 251, 247-251.
- Koçyiğit, M., (2022). **Malatya halk kültüründe kayısı**. Yüksek Lisans Tezi, Gaziantep Üniversitesi Sosyal Bilimler Enstitüsü, Gaziantep. 253.
- Korkmaz, E., (2022). **Yapay Sinir Ağları ve Makine Öğrenmesi İle Güneş Işınımının Analizi: Bursa ve Çanakkale Örneği**. Yüksek Lisans Tezi, Bandırma Onyedi Eylül Üniversitesi Sosyal Bilimler Enstitüsü, Bandırma. 118.
- Korzin, V., Gorina, V. ve Saplev, N., (2021). **The effect of weather conditions in southern Russia on the frost resistance of apricot generative buds**. Horticultural Science, 48(4), 158-165.
- Kulak, M., (2018) **A bibliometric review of research trends in salicylic acid uses in agricultural and biological sciences: where have been studies directed?** Agronomy 61(1):296–303
- Kurtulmuş, F., (2012). **Olgunlaşmamış Şeftali Meyvesini Doğal Bahçe Koşullarında Alınmış Görüntülerde Görüntü İşleme Teknikleri ve Yapay Sınıflandırıcılarla Saptayarak Sayan Algoritmaların Geliştirilmesi**. Doktora Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa. 220.
- Kurtulmuş, F., Polat, A. ve İzli, N., (2020). **Yapay Sinir Ağları Kullanarak Kayısının Farklı Kurutma Yöntemleriyle Kurutulmasında Kuruma Hızı Ve Nem İçeriği Parametrelerinin Modellenmesi**. ÇOMÜ Ziraat Fakültesi Dergisi, 8(2), 261-269.

- Latha, M., Poojith, A., Reddy, B. A. ve Kumar, G. V., (2014). ***Image processing in agriculture***. International journal of innovative research in electrical, electronics, instrumentation and control engineering, 2(6).
- Lu, B., Dao, P. D., Liu, J., He, Y. ve Shang, J., (2020). ***Recent advances of hyperspectral imaging technology and applications in agriculture***. Remote Sensing, 12(16), 2659.
- Mahanti, N.K., Pandiselvam, R., Kothakota, A., Ishwarya, P., Chakraborty, S.K., Kumar, M. ve Cozzolino, D., (2021). ***Emerging non-destructive imaging techniques for fruit damage detection: Image processing and analysis***. Trends in Food Science & Technology.120, 418-438
- Martínez Mora, CM., Rodríguez, J., Cenis, JL. ve García, LR., (2009). ***Genetic variability among local apricots (Prunus armeniaca L.) from the Southeast of Spain***. Spanish Journal of Agricultural Research, 7(4), 855-868
- Motevali, A., Younji, S., Chayjan, R.A., Aghilinategh, N. ve Banakar, A., (2013). ***Drying kinetics of dill leaves in a convective dryer***. Int Agrophys., 27(1): 39.
- Mozaffari, M., Sadeghi, S., & Asefi, N. (2022). Prediction of the quality properties and maturity of apricot by laser light backscattering imaging. Postharvest Biology and Technology, 186, 111842.
- Ramos, J. P. S. (2003). ***Fruit sorting using artificial neural networks: bidimensional case***. Ciência e Agrotecnologia, 27, 356-362.
- Muradoğlu, F., Pehlivan, M., Gündoğdu, M. ve Kaya, T., (2011). ***Iğdır yöresinde yetiştirilen bazı kayısı genotiplerin fizikokimyasal özellikleri ile mineral içerikleri***. Journal of the Institute of Science and Technology, 1(1), 17-22.
- Naik, A., Thaker, H. ve Vyas, D., (2021). ***A survey on various image processing techniques and machine learning models to detect, quantify and classify foliar plant disease***. Proceedings of the Indian National Science Academy, 87(2), 191-198.

- Naranjo-Torres, J., Mora, M., Hernández-García, R., Barrientos, R. J., Fredes, C. ve Valenzuela, A., (2020). ***A review of convolutional neural network applied to fruit image processing.*** Applied Sciences, 10(10), 3443.
- Noyan, E. (2016). ***Türkiye'deki tarımsal faaliyetlere uygulanan teşvik politikalarının değerlendirilmesi.*** Yüksek Lisans Tezi, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü, Denizli. 144.
- Odetola, T. ve Etumnu, C., (2013). ***Contribution of agriculture to economic growth in Nigeria.*** In Proceeding: the 18th Annual Conference of the African Econometric Society (AES), Accra, Ghana 22nd and (pp. 1-28).
- Öztemel, E., (2006). ***Yapay Sinir Ağları.*** Papatya Yayıncılık. İstanbul, 29-57.
- Özyörük, C. ve Güleriyüz, M., (1992). ***Iğdır ovasında yetişen kayısı çeşitleri üzerinde pomolojik biyolojik ve fenolojik araştırmalar.*** Atatürk Üniversitesi Ziraat Fakültesi Dergisi, 23(1),16-28.
- Parpinello, G. P., Fabbri, A., Domenichelli, S., Mesisca, V., Cavicchi, L., & Versari, A. (2007). ***Discrimination of apricot cultivars by gas multisensor array using an artificial neural network.*** Biosystems Engineering, 97(3), 371-378.
- Patrício, D. I. ve Rieder, R., (2018). ***Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review.*** Computers and electronics in agriculture, 153, 69-81.
- Pektekin, A. T., (1994). ***Ülkemizde yetiştirilen kayısı çeşitleri ve özellikleri.*** Standart kayısı özel sayısı, 49-53.
- Piryonisi, S. M. ve El-Diraby, T. E., (2020). ***Data analytics in asset management: Cost-effective prediction of the pavement condition index.*** Journal of Infrastructure Systems, 26(1), 04019036.
- Powers, D. M. (2020). ***Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation.*** <https://arxiv.org/abs/2010.16061>

- Rhinithaa, P.T., Selvakumar, P., Sudhakaran, N., Anirudh, V. ve Mathew, J., (2018). ***Comparative study of roundness evaluation algorithms for coordinate measurement and form data.*** Precision Engineering, 51, 458-467.
- Samtaş, G. ve Gülesin, M., (2011). ***Sayısal Görüntü İşleme ve Farklı Alanlardaki Uygulamaları.*** Electronic Journal of Vocational Colleges, 2(1), 85-97.
- Sert, E. (2010). ***Görüntü işleme teknikleri ile şeftali ve elma sınıflandırma.*** Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne. 89.
- Shafi, U., Mumtaz, R., García-Nieto, J., Hassan, S. A., Zaidi, S.A.R. ve Iqbal, N., (2019). ***Precision agriculture techniques and practices: From considerations to applications.*** Sensors, 19(17), 3796.
- Solak, S. ve Altınışık, U., (2018). ***Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması.*** Sakarya University Journal of Science, 22(1), 56-65.
- Sucu, M., (2020). ***Karar Destek Sistemleri ve İş Zekâsı Uygulamalarının İşletmeler Açısından Önemi: Bir Literatür Araştırması.*** Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 44, 261-283.
- Syazwani, R.W.N., Asraf, H.M., Amin, M.M.S. ve Dalila, K.N., (2022). ***Automated image identification, detection and fruit counting of top-view pineapple crown using machine learning.*** Alexandria Engineering Journal, 61(2), 1265-1276.
- Syeda, I.H., Alam, M.M., Illahi, U. ve Su'ud, M.M., (2021). ***Advance control strategies using image processing, UAV and AI in agriculture: a review.*** World Journal of Engineering.18/4 579–589
- Şahin Demirel, A.N., (2022). ***Türkiye'deki Kayısı Üreticilerine Zaman Serileri Analizine Bağlı Ekonomik Bir Tavsiye.*** Türk Tarım ve Doğa Bilimleri Dergisi, 9(1), 19-25.
- Şalvarcı, Ü.B. ve Ayten, U.E., (2019). ***Yapay sinir ağları ile görüntü işlemeye dayalı uzaklıktan bağımsız ağırlık tahmin sistemi: yumurta ve portakal örnekleri.*** Jeodezi ve Jeoinformasyon Dergisi, 6(1), 26-46.

- Şenel, F.A., (2020). *Makine Öğrenmesi Algoritmaları Kullanılarak Kayısı İç Çekirdeklerinin Sınıflandırılması*. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(2), 807-815.
- Tharwat, A. (2020). *Classification assessment methods*. *Applied computing and informatics*, 17(1), 168-192.
- Thirtle, C., Lin, L. ve Piesse, J., (2003). *The impact of research-led agricultural productivity growth on poverty reduction in Africa, Asia and Latin America*. *World Development*, 31(12), 1959-1975.
- Thong, N.D., Thinh, N.T. ve Cong, H.T., (2019). *Mango Classification System Uses Image Processing Technology and Artificial Intelligence*. In 2019 International Conference on System Science and Engineering (ICSSE) (pp. 45-52). IEEE.
- Tin, M.M., Mon, K.L., Win, E.P. ve Hlaing, S.S., (2018). *Myanmar Rice Grain Classification Using Image Processing Techniques*. In International Conference on Big Data Analysis and Deep Learning Applications (pp. 324-332). Springer, Singapore.
- Tresson, P., Brun, L., de Cortazar-Atauri, I.G., Audergon, J.M., Buléon, S., Chenevotot, H. ve Launay, M., (2020). *Future development of apricot blossom blight under climate change in Southern France*. *European Journal of Agronomy*, 112, 125960.
- Türkoğlu, M., Hanbay, K., Sivrikaya, I.S. ve Hanbay, D., (2021). *Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması*. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1), 334-345.
- Uçar, K. Güler, D. ve Engindeniz, S., (2021). *Türkiye’de Kayısı Üretiminin ARIMA Modeli ile Tahmini*. *Tarım Ekonomisi Dergisi*, 27(2), 55-62.
- Üstüner, M. ve Şanlı, F.B., (2019). *Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması*. *Jeodezi ve Jeoinformasyon Dergisi*, 7(1), 1-10.
- Van Eck, N. ve Waltman, L., (2010). *Software survey: VOSviewer, a computer program for bibliometric mapping*. *scientometrics*, 84(2), 523-538.



- Varjovi, M.H. ve Talu, M.F., (2016). ***Kayıt için otomatik rekolte tahmin sistemi.*** In International conference on artificial intelligence and data processing. September 2016 malatya
- Varlı Yunusoğlu, S., Ekinci, N. ve Gündoğdu, M., (2021). ***Modifiye Atmosfer Paketleme ve Normal Atmosfer Koşullarında Depolanan ‘‘Roxana’’Kayısı Çeşidinin Aroma Bileşenlerindeki Değişim.*** ÇOMÜ Ziraat Fakültesi Dergisi, 9(2).
- Vijayashree, T. ve Gopal, A., (2018). ***Identification Of Herbal Medicinal Plant Leaves Using Image Processing Algorithm.*** Research Journal Of Pharmaceutical Biological And Chemical Sciences, 9(4), 1221-1228.
- Vishnoi, V.K., Kumar, K. ve Kumar, B., (2021). ***Plant disease detection using computational intelligence and image processing.*** Journal of Plant Diseases and Protection, 128(1), 19-53.
- Wu, D. ve Sun, D.W., (2013). ***Colour measurements by computer vision for food quality control–A review.*** Trends in Food Science & Technology, 29(1), 5-20.
- Xie, Y., Plett, D. ve Liu, H., (2022). ***Detecting Crown Rot Disease in Wheat in Controlled Environment Conditions Using Digital Color Imaging and Machine Learning.*** Agri Engineering, 4(1), 141-155.
- Yang, X., Zhang, R., Zhai, Z., Pang, Y., & Jin, Z. (2019). ***Machine learning for cultivar classification of apricots (Prunus armeniaca L.) based on shape features.*** Scientia Horticulturae, 256, 108524.
- Yaqoob, M., Sharma, S. ve Aggarwal, P., (2021). ***Imaging techniques in Agro-industry and their applications, a review.*** Journal of Food Measurement and Characterization, 15(3), 2329-2343.
- Yavuz, F., (2005). ***Türkiye’de tarım.*** Tarım ve Köyişleri Bakanlığı Yayınları, Ankara, 1, 252.
- Yenigül, S.B., (2016). ***Büyükşehirlerde tarımsal alanların korunmasında kentsel tarım ve yerel yönetimlerin rolü.*** Megaron, 11(2), 291-299.

- Yıldız, A.K., Polatçı, H. ve Uçun, H., (2015). *Farklı Kurutma Şartlarında Muz (Musa cavendishii) Meyvesinin Kurutulması ve Kurutma Kinetiğinin Yapay Sinir Ağları ile Modellenmesi*. Tarım Makinaları Bilimi Dergisi, 11(2), 173-178.
- Yıldız, F., (1994). *Kayıt işlemede yeni teknolojiler*. Standart Dergisi (Kayısı Özel Sayısı), 67-69.
- Yılmaz Kızılboğa, A., (2021). *Yapay sinir ağları ve derin öğrenme teknikleri kullanılarak elma ve ayvada çeşitli hastalıkların tespit edilmesi*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale. 91.
- Yılmaz, A., (2007). *Kamera kullanılarak görüntü işleme yoluyla gerçek zamanlı güvenlik uygulaması*. Yüksek Lisan Tezi, Haliç Üniversitesi Fen Bilimleri Enstitüsü, İstanbul. 110.
- Zhang, C., Mouton, C., Valente, J., Kooistra, L., van Ooteghem, R., de Hoog, D. ve de Jong, P.F., (2022). *Automatic flower cluster estimation in apple orchards using aerial and ground based point clouds*. Biosystems Engineering, 221, 164-180.
- Zhang, Q., Liu, Y., Gong, C., Chen, Y. ve Yu, H., (2020). *Applications of deep learning for dense scenes analysis in agriculture: A review*. Sensors, 20(5), 1520.
- Zhaoshuai, Z.H.U., Jie, L.I., Wulan, M.A.O., Liling, Y.A.N.G., Kuanbo, C.U.I. ve Zhanjiang, Z.H.U., (2022). *Design And Test of Apricot Kernel Shell Breaking Machine*. Inmateh-Agricultural Engineering, 67(2).



EKLER

Ek-1. Çalışma da kullanılan kayısıların işlenmiş resimleri



AĞERİK





ŞALAK





TEBERZE





ÇÜRÜK ŞALAK



ÇÜRÜK AĞERİK



TEBERZE ÇÜRÜK



Ek-2. Araştırmada gerekli işlemleri yapabilmek için yazılan scriptler ve fonksiyonlar

Yapay Sinir Ağları

```
%%+ Temizle
clear;
clc;

%% Parametreler
filterno=4;  %{ Uygulanacak resim iyileştirme filtresi
              % 1: Laplacian
              % 2: Average
              % 3: Gaussian
              % 4: Median
              % 5: Unsharpen
              % 6: Blurring
              %}

%% Kategorileri oluştur
kayisiKategorileri = { 'AgerikSaglam', ...
                       'SalakSaglam', ...
                       'TeberzeSaglam', ...
                       'Curuk' ...
                       };
%
% 'AgerikCuruk', ...
% 'SalakCuruk', ...
% 'TeberzeCuruk' ...

% Kategori sayısı
kayisiSinifiSayisi = size(kayisiKategorileri, 2);
%Veriseti adı, resimlerin olduğu ana klasör
kayisiVeriseti= 'trainset';
%% Bir resmin koordinatları
resim =imread('D:/Matlab/Kayisi/trainset/AgerikSaglam/IMG_4689.jpg');
[satir sutun derinlik]=size(resim);
uzunluk = satir*sutun*derinlik;
%% trainsetteki Resimleri diziye at
for i=1:kayisiSinifiSayisi
    dosya = sprintf("%s.txt", kayisiKategorileri{i});
    fid = fopen(dosya);
    kayisiResimleri{i} = textscan(fid, '%s', 'delimiter', '\n');
    fclose(fid);
    kayisiSayilari(i) = length( kayisiResimleri{i}{1});
    for j=1:kayisiSayilari(i)
        resim=imread(kayisiResimleri{i}{1}{j});
        % Kırpma
        resim=imcrop(resim, [1400 750 1999 1999]);
        % Küçültme
        resim = imresize(resim, [224 224]);
        imwrite(resim,kayisiResimleri{i}{1}{j});
    end
end
%% Örnek sayıları
minOrnekSayisi = min(kayisiSayilari);
```

```

%% Hedef
Target = zeros(kayisiSinifiSayisi, minOrnekSayisi);
%% Filtreleme
for i=1:kayisiSinifiSayisi
    for j=1:minOrnekSayisi

        %Resim dosyasını okutup çalışma alanına alma
        rsm = imread(kayisiResimleri{i}{1}{j});

        %Resim renklerindeki kontrastı artırma
        rsm = imadjust(rsm, stretchlim(rsm));
        %rsm = rgb2gray(rsm);

        %Resim Geliştirme Filtresi Uygula
        rsm = Filtrele(rsm, filterno);

        % Resmi oluşturan matrisi ondalıklı sayı haline geitirme
        rsm = double(rsm);

        % Resmi tek sütunluk vektöre dönüştürme
        rsm = reshape(rsm, [], 1);

        % Elde ettiğimiz resmi örnek olarak giriş matrisinin ilgili
        % sütununa aktarma
        Input(:,(i-1)*minOrnekSayisi+j) = rsm;

        % Örneği uygun hedef olarak belirleme
        Target(i, (i-1)*minOrnekSayisi+j)=1;

    end
end

%% YSA
% YSA için ağ oluşturma ve eğitme
%

% Giriş ve hedefler
inputs = Input;
targets = Target;

% Pattern Recognition Network oluşturma
hiddenLayerSize = 10; % Gizli katmanda 10 nöron
nnKayisi = patternnet(hiddenLayerSize);

% Eğitim, Doğrulama ve Test için verileri bölümleme
nnKayisi.divideParam.trainRatio = 70/100;
nnKayisi.divideParam.valRatio = 15/100;
nnKayisi.divideParam.testRatio =15/100;
tekrar=0;
performance = 1;
while performance > 0.001
    % Ağı eğitme
    [nnKayisi,tr] = train(nnKayisi,inputs,targets);

    tekrar = tekrar+1
end

```

```

    % Ağı test etme
    outputs = nnKayisi(inputs);
    errors = gsubtract(targets,outputs);
    performance = perform(nnKayisi,targets,outputs)
end;
% Ağı görüntüleme
view(nnKayisi);
%% Gözlemlenen etiketler
kategori1 = {'Agerik'};
kategori2 = {'Salak'};
kategori3 = {'Teberze'};
kategori4 = {'Curuk'};
gozlemEtiketler = [repmat(kategori1, 1, 250), ...
    repmat(kategori2, 1, 250),...
    repmat(kategori3, 1, 250), ...
    repmat(kategori4, 1, 250)];

%% Tahmin edilen etiketler
for i=1:size(gozlemEtiketler,2)
    if outputs(1,i) >= outputs(2,i) && outputs(1,i) >= outputs(3,i)
        tahminEtiketler{i}='Agerik';
    elseif outputs(2,i) >= outputs(3,i)
        tahminEtiketler{i}='Salak';
    else
        tahminEtiketler{i}='Teberze';
    end
end

%% Karışıklık Matrisi
[m p] = confusionmat(gozlemEtiketler, tahminEtiketler)
figure
cm = confusionchart(m,p,'RowSummary', ...
    'row-normalized','ColumnSummary','column-normalized');
stats = confusionmatStats(gozlemEtiketler, tahminEtiketler)

%% PERFORMANS
cellPred = cellstr(tahminEtiketler);
cellValid = cellstr(gozlemEtiketler);
cp = classperf(cellPred, cellValid)

%% ROC
scores = max(outputs)
figure
[X,Y] = perfcurve(gozlemEtiketler{1:250}, scores(1:250), 'Agerik');
    subplot(2, 2, 1)
    title('Agerik')
    plot(X,Y)
    xlabel('False positive rate')

%% Örnek Resim Almak için
figure
A=[25 5 15];
for i=1:3
    j = A(i);
    subplot(3, 3, (i-1)*3+1)
    title(kayisiKategorileri{i})

```

```
%Resim dosyasını okutup çalışma alanına alma
rsm = imread(kayisiResimleri{i}{1}{j});
imshow(rsm)

subplot(3, 3, (i-1)*3+2)
title('Renk Normalizasyonu')
%Resim renklerindeki kontrastı artırma
rsm = imadjust(rsm, stretchlim(rsm));
%rsm = rgb2gray(rsm);
imshow(rsm)

subplot(3, 3, (i-1)*3+3)
title('Filtrelenmiş')
%Resim Geliştirme Filtresi Uygula
rsm = Filtrele(rsm, filterno);
imshow(rsm)

end
```

Karar Ağacı

```
%% Temizle
clear;
clc;

%% Parametreler
filterno=4;  %{ Uygulanacak resim iyileştirme filtresi
               % 1: Laplacian
               % 2: Average
               % 3: Gaussian
               % 4: Median
               % 5: Unsharpen
               % 6: Blurring
               %}

%% Kategorileri oluştur
kayisiKategorileri = { 'AgerikSaglam', ...
                       'SalakSaglam', ...
                       'TeberzeSaglam', ...
                       'Curuk' ...
                       };
%
%           'AgerikCuruk', ...
%           'SalakCuruk', ...
%           'TeberzeCuruk' ...

% Kategori sayısı
kayisiSinifiSayisi = size(kayisiKategorileri, 2);
%Veriseti adı, resimlerin olduğu ana klasör
kayisiVeriseti= 'trainset';
%% Bir resmin koordinatları
resim=imread('D:/Matlab/Kayisi/trainset/AgerikSaglam/IMG_4689.jpg');
[satir sutun derinlik]=size(resim);
uzunluk = satir*sutun*derinlik;
% trainsetteki Resimleri diziye at
c=0;
for i=1:kayisiSinifiSayisi
    dosya = sprintf("%s.txt", kayisiKategorileri{i});
    fid = fopen(dosya);
    kayisiResimleri{i} = textscan(fid,'%s','delimiter','\n');
    fclose(fid);
    kayisiSayilari(i) = length( kayisiResimleri{i}{1});
    for j=1:kayisiSayilari(i)
        resim=imread(kayisiResimleri{i}{1}{j});
        c=c+1;
        % Özellik çıkarma
        fn = kayisiResimleri{i}{1}{j};
        rsm = imread(fn);
        [Reds(c), Greens(c), Blues(c)] = GetAverageRGBColor(rsm);
        Rounds(c) = Roundness(rsm, fn);
        Species(c)=i;
    end
end
```



```

%% Veriseti oluřturma
Inputs (:,1)=Reds;
Inputs (:,2)=Greens;
Inputs (:,3)=Blues;
Inputs (:,4)=Rounds;
%% Ağ eđitimi
ctree = fitctree(Inputs, Species)
view(ctree)
view(ctree, 'mode', 'graph')

%% Sonular
DTSonuc=zeros(4,1000);
DTOutput=zeros(1,1000);
dogru=0;
for c=1:1000
    turno=fix(1+(c-1)/250);
    fn = kayisiResimleri{turno}{1}{c-(turno-1)*250};
    %disp(fn);
    rsm = imread(fn);
    [red, green, blue] = GetAverageRGBColor(rsm);
    round = Roundness(rsm, fn);
    TotalInputs(c,:)= [red green blue round];
    specy=predict(ctree, [red green blue round]);
    DTSonuc(specy,c)=1;

    if(c>=1 && c<= 250) tur=1;
    elseif (c>=251 && c<=500) tur=2;
    elseif (c>=501 && c<=750) tur=3;
    elseif (c>=751 && c<=1000) tur=4;
    else tur=0;
    end
    DTOutput(c)=specy;
    if(specy == tur )
        dogru =dogru+1;
    else
        disp(strcat(int2str(tur), ' -> ',int2str(specy)));
    end
end
%%
disp(strcat('Dogru sayısı: ', num2str(dogru)));
gscatter(TotalInputs(:,1), TotalInputs(:,2),DTOutput, 'bmrk', 'o+*x');
% end

%% Karıřıklık Matrisi
[m p]=confusionmat(Species, DTOutput)
figure
cm = confusionchart(m,p, 'RowSummary', 'row-
normalized', 'ColumnSummary', 'column-normalized');
stats = confusionmatStats(Species, DTOutput)
%% Ortamı kaydet
save('kayisiDT.mat');
table = struct2table(stats);
writetable(table, 'kayisiDT.xlsx');

```

Naïve-Bayes

```
%% Temizle
clear;
clc;

%% Parametreler
filterno=4;  %{ Uygulanacak resim iyileştirme filtresi
               % 1: Laplacian
               % 2: Average
               % 3: Gaussian
               % 4: Median
               % 5: Unsharpen
               % 6: Blurring
               %}

%% Kategorileri oluştur
kayisiKategorileri = { 'AgerikSaglam', ...
                       'SalakSaglam', ...
                       'TeberzeSaglam', ...
                       'Curuk' ...
                       };
%
% 'AgerikCuruk', ...
% 'SalakCuruk', ...
% 'TeberzeCuruk' ...

%% Kategori sayısı
kayisiSinifiSayisi = size(kayisiKategorileri, 2);
%Veriseti adı, resimlerin olduğu ana klasör
kayisiVeriseti= 'trainset';
%% Bir resmin koordinatları
resim =imread('D:/Matlab/Kayisi/trainset/AgerikSaglam/IMG_4689.jpg');
[satir sutun derinlik]=size(resim);
uzunluk = satir*sutun*derinlik;
%% trainsetteki Resimleri diziye at
c=0;
for i=1:kayisiSinifiSayisi
    dosya = sprintf("%s.txt", kayisiKategorileri{i});
    fid = fopen(dosya);
    kayisiResimleri{i} = textscan(fid,'%s','delimiter','\n');
    fclose(fid);
    kayisiSayilari(i) = length( kayisiResimleri{i}{1});
    for j=1:kayisiSayilari(i)
        resim=imread(kayisiResimleri{i}{1}{j});
        c=c+1;
        % Özellik çıkarma
        fn = kayisiResimleri{i}{1}{j};
        rsm = imread(fn);
        [Reds(c), Greens(c), Blues(c)] = GetAverageRGBColor(rsm);
        Rounds(c) = Roundness(rsm, fn);
        Species(c)=i;
    end
end
end
```

```

%% Veriseti oluşturma
Inputs(:,1)=Reds;
Inputs(:,2)=Greens;
Inputs(:,3)=Blues;
Inputs(:,4)=Rounds;

%% Ağ eğitimi
nbMdl = fitcnb(Inputs, Species)

%% Sonuçlar
DTSonuc=zeros(4,1000);
DTOutput=zeros(1,1000);
dogru=0;
for c=1:1000
    turno=fix(1+(c-1)/250);
    fn = kayisiResimleri{turno}{1}{c-(turno-1)*250};
    %disp(fn);
    rsm = imread(fn);
    [red, green, blue] = GetAverageRGBColor(rsm);
    round = Roundness(rsm, fn);
    TotalInputs(c,:)=[red green blue round];
    specy=predict(nbMdl, [red green blue round]);
    DTSonuc(specy,c)=1;

    if(c>=1 && c<= 250) tur=1;
    elseif (c>=251 && c<=500) tur=2;
    elseif (c>=501 && c<=750) tur=3;
    elseif (c>=751 && c<=1000) tur=4;
    else tur=0;
    end
    DTOutput(c)=specy;
    if(specy == tur )
        dogru =dogru+1;
    else
        disp(strcat(int2str(tur), ' -> ',int2str(specy)));
    end
end
%%
disp(strcat('Dogru sayısı: ', num2str(dogru)));
gscatter(TotalInputs(:,1), TotalInputs(:,2),DTOutput,'bmrk','o+*x');
% end

%% Karışıklık Matrisi
[m p]=confusionmat(Species, DTOutput)
figure
cm = confusionchart(m,p,'RowSummary','row-
normalized','ColumnSummary','column-normalized');
stats = confusionmatStats(Species, DTOutput)
%% Ortamı kaydet
save('kayisiNB.mat');
table = struct2table(stats);
writetable(table, 'kayisiNB.xlsx');

```

Destek Vektör Makinaları

```
%% Temizle
clear;
clc;

%% Parametreler
filterno=4;  %{ Uygulanacak resim iyileştirme filtresi
               % 1: Laplacian
               % 2: Average
               % 3: Gaussian
               % 4: Median
               % 5: Unsharpen
               % 6: Blurring
               %}

%% Kategorileri oluştur
kayisiKategorileri = { 'AgerikSaglam', ...
                       'SalakSaglam', ...
                       'TeberzeSaglam', ...
                       'Curuk' ...
                       };
%
% 'AgerikCuruk', ...
% 'SalakCuruk', ...
% 'TeberzeCuruk' ...

%% Kategori sayısı
kayisiSinifiSayisi = size(kayisiKategorileri, 2);
%Veriseti adı, resimlerin olduğu ana klasör
kayisiVeriseti= 'trainset';
%% Bir resmin koordinatları
resim =imread('D:/Matlab/Kayisi/trainset/AgerikSaglam/IMG_4689.jpg');
[satir sutun derinlik]=size(resim);
uzunluk = satir*sutun*derinlik;
%% trainsetteki Resimleri diziye at
c=0;
for i=1:kayisiSinifiSayisi
    dosya = sprintf("%s.txt", kayisiKategorileri{i});
    fid = fopen(dosya);
    kayisiResimleri{i} = textscan(fid,'%s','delimiter','\n');
    fclose(fid);
    kayisiSayilari(i) = length( kayisiResimleri{i}{1});
    for j=1:kayisiSayilari(i)
        resim=imread(kayisiResimleri{i}{1}{j});
        c=c+1;
        % Özellik çıkarma
        fn = kayisiResimleri{i}{1}{j};
        rsm = imread(fn);
        [Reds(c), Greens(c), Blues(c)] = GetAverageRGBColor(rsm);
        Rounds(c) = Roundness(rsm, fn);
        Species(c)=i;
    end
end
end
```

```

%% Veriseti oluşturma
Inputs(:,1)=Reds;
Inputs(:,2)=Greens;
Inputs(:,3)=Blues;
Inputs(:,4)=Rounds;
%% Ağ eğitimi
svmModel = fitcecoc(Inputs, Species')

%% Sonuçlar
DTSonuc=zeros(4,1000);
DTOutput=zeros(1,1000);
dogru=0;
for c=1:1000
    turno=fix(1+(c-1)/250);
    fn = kayisiResimleri{turno}{1}{c-(turno-1)*250};
    %disp(fn);
    rsm = imread(fn);
    [red, green, blue] = GetAverageRGBColor(rsm);
    round = Roundness(rsm, fn);
    TotalInputs(c,:)= [red green blue round];
    specy=predict(svmModel, [red green blue round]);
    DTSonuc(specy,c)=1;

    if(c>=1 && c<= 250) tur=1;
    elseif (c>=251 && c<=500) tur=2;
    elseif (c>=501 && c<=750) tur=3;
    elseif (c>=751 && c<=1000) tur=4;
    else tur=0;
    end
    DTOutput(c)=specy;
    if(specy == tur )
        dogru =dogru+1;
    else
        disp(strcat(int2str(tur), ' -> ',int2str(specy)));
    end
end
%%
disp(strcat('Dogru sayısı: ', num2str(dogru)));
gscatter(TotalInputs(:,3), TotalInputs(:,4),DTOutput, 'bmrk','o+*x');
% end

%% Karışıklık Matrisi
[m p]=confusionmat(Species, DTOutput)
figure
cm = confusionchart(m,p,'RowSummary','row-
normalized','ColumnSummary','column-normalized');
stats = confusionmatStats(Species, DTOutput)
%% Ortamı kaydet
save('kayisiSVM.mat');
table = struct2table(stats);
writetable(table, 'kayisiSVM.xlsx');

```