



T.C.

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**CEVİZ ÇEŞİTLERİNİN DERİN ÖĞRENME TEKNİKLERİ
KULLANILARAK SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

BARIŞ ATEŞ

ŞUBAT

**CEVİZ ÇEŞİTLERİNİN DERİN ÖĞRENME TEKNİKLERİ
KULLANILARAK SINIFLANDIRILMASI**

Barış ATEŞ

YÜKSEK LİSANS TEZİ
TEKNOLOJİ ve İNOVASYON YÖNETİMİ ANABİLİM DALI

Danışman

Prof. Dr. Mehmet KARA

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ŞUBAT 2025

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Barış ATEŞ tarafından hazırlanan “Ceviz Çeşitlerinin Derin Öğrenme Teknikleri Kullanılarak Sınıflandırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Teknoloji ve İnovasyon Yönetimi Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mehmet KARA

Termodinamik Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

Başkan: Dr. Öğr. Üyesi İncay Hakkı ÇİZMECİ

Bilgisayar Yazılımı Anabilim Dalı, Afyon Kocatepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

Üye: Dr. Öğr. Üyesi Yavuz ÜNAL

Bilgisayar Yazılımı Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.....

Tez Savunma Tarihi: 06/02/2025

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

(İmza)

Barış ATEŞ

(Tarih)

CEVİZ ÇEŞİTLERİNİN DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK
SINIFLANDIRILMASI
(Yüksek Lisans Tezi)

Barış ATEŞ

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Şubat 2025

ÖZET

Ceviz ağacı, tarihsel olarak hem yenilebilir meyvesi hem de yüksek kalitedeki ahşabı ile ekonomik açıdan değerli bir ağaç türü olarak öne çıkmıştır. Ceviz, Omega-3 yağ asitleri, antioksidanlar, protein ve lif gibi besin maddeleri açısından zengin olması nedeniyle sağlıklı beslenmenin önemli bir bileşeni olarak kabul edilmektedir. Ayrıca ceviz, beyin sağlığı ve kalp sağlığına katkıda bulunurken, bağışıklık sistemini güçlendiren ve iltihaplanmayı azaltan özelliklere sahiptir. Ceviz aynı zamanda, farklı mutfaklarda çeşitli yemeklerde ve tatlılarda kullanılarak gastronomi dünyasında da önemli bir yer tutmaktadır. Makine öğrenmesi alanında önemli bir yer edinen derin öğrenme, yapay sinir ağları kullanarak büyük veri kümelerindeki karmaşık yapıları ve desenleri tanımlamak, sınıflandırmak veya tahmin etmek amacıyla kullanılan bir teknolojidir. Sinir ağları yapısı içerisinde çeşitli katmanlardan oluşan derin öğrenme algoritmaları, verileri işleyerek yüksek seviyeli özellikler veya soyut kavramlar oluşturmakta ve doğrusal olmayan aktivasyon fonksiyonları kullanarak bilgileri daha karmaşık şekillerde birleştirmektedir. Tez çalışmamda, besin değeri açısından oldukça yüksek olan ceviz türlerinin sınıflandırılması amacıyla derin öğrenme metodundan yararlanılmış olup, farklı ceviz türlerinin özellikleri ve desenleri analiz edilerek besin değerine göre kategorize edilmesi hedeflenmiştir. Bu tez çalışmasında, Chandler, Fernor, Hekimhan, Kaman-1, Maraş-18 ve Oğuzlar-77 ceviz çeşitlerine ait görüntüler kullanılarak derin öğrenme tabanlı sınıflandırma gerçekleştirilmiştir. Çalışma kapsamında, Chandler türünden 408, Fernor türünden 459, Hekimhan türünden 485, Kaman-1 türünden 425, Maraş-18 türünden 393 ve Oğuzlar-77 türünden 610 olmak üzere toplamda 2780 görüntü elde edilmiştir. Bu görüntüler, ön işleme adımlarından geçirilerek, önceden eğitilmiş modeller olan DenseNet121, NASNetMobile ve MobileNet ile sınıflandırma işlemi yapılmıştır. Veri kümesi, %80 eğitim ve %20 test verisi olacak şekilde ikiye ayrılmıştır. Yapılan sınıflandırma işlemleri sonucunda, sırasıyla %80,25; %65,53 ve %83,66 başarı oranları elde edilmiştir. En yüksek sınıflandırma başarısı MobileNet modeliyle sağlanmıştır. Bununla birlikte, sınıflandırma başarılarının artırılması amacıyla parametre optimizasyonu yapılmıştır. Sonuç olarak, optimizasyon sonrası, ön eğitilmiş DenseNet121, NASNetMobile ve MobileNet modellerinin sınıflandırma başarısı sırasıyla %90,66; %87,61; %92,46 oranlarına yükseltilmiştir. Elde edilen diğer ayrıntılı sonuçlar, tezin ilgili bölümlerinde detaylı bir şekilde sunulmuştur.

Sayfa Adedi	: 78
Anahtar Kelimeler	: Derin Öğrenme, Makine Öğrenmesi, Ceviz Çeşitleri, Yapay Sinir Ağları, Görüntü İşleme
Danışman	: Prof. Dr. Mehmet KARA

CLASSIFICATION OF WALNUT VARIETIES USING DEEP LEARNING TECHNIQUES

(M. Sc. Thesis)

Barış ATEŞ

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

February 2025

ABSTRACT

The walnut tree has historically stood out as an economically valuable tree species due to its edible fruit and high-quality wood. Walnuts are recognized as a significant component of a healthy diet due to their richness in Omega-3 fatty acids, antioxidants, protein, and fiber. Furthermore, walnuts contribute to brain health and heart health, bolstering the immune system and reducing inflammation. In the culinary world, walnuts hold a notable place, being used in various dishes and desserts across different cuisines. In the field of machine learning, deep learning has gained prominence, employing artificial neural networks to identify, classify, or predict complex structures and patterns within large datasets. Comprising multiple layers within the neural network architecture, deep learning algorithms process data to form high-level features or abstract concepts, combining information in more complex ways using non-linear activation functions. In my thesis, deep learning methods have been employed to classify walnut species with high nutritional value, aiming to categorize different walnut species based on their nutritional properties by analyzing their characteristics and patterns. In this thesis, deep learning-based classification was performed using images of walnut varieties Chandler, Fernor, Hekimhan, Kaman-1, Maraş-18, and Oğuzlar-77. A total of 2780 images were obtained, with 408 images of Chandler, 459 of Fernor, 485 of Hekimhan, 425 of Kaman-1, 393 of Maraş-18, and 610 of Oğuzlar-77. After preprocessing these images, the pre-trained models DenseNet121, NASNetMobile, and MobileNet were applied for classification. The dataset was divided into 80% training and 20% test data. As a result of the classification operations, 80,25%; 65,53% and 83,66% success rates were obtained, respectively. The highest classification success was achieved with the MobileNet model. However, parameter optimization was performed in order to increase the classification success. As a result, after optimization, the classification success of the pre-trained DenseNet121, NASNetMobile and MobileNet models was increased to 90,66%; 87,61% and 92,46%, respectively. Other detailed results obtained are presented in detail in the relevant sections of the thesis.

Number of pages : 78

Keywords : Deep Learning, Machine Learning, Walnut Varieties, Artificial Neural Networks, Image Processing

Supervisor : Prof. Dr. Mehmet KARA

ÖN SÖZ ve TEŞEKKÜR

Yüksek lisans eğitimim süresince desteklerini esirgemeyen ve her zaman yanımda olan aileme sonsuz teşekkür ederim. Çalışmalarım esnasında bana yardımcı olan değerli meslektaşım Uzman Öğretmen Selçuk Harmancı' ya, tez yazım sürecimde her türlü desteği sağlayan danışmanım Profesör Doktor Mehmet Kara'ya ve bölüm hocam Doktor Yavuz Ünal'a minnettarım. Onların rehberliği, teşviki ve katkıları olmadan bu çalışma tamamlanamazdı. Ayrıca, araştırmam sırasında faydalandığım tüm kaynaklara ve bu çalışmanın gerçekleştirilmesinde emeği geçen herkese içtenlikle teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
ÖN SÖZ ve TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
RESİMLER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ	1
1.1. Cevizlerin Kökeni.....	2
1.2. Cevizin yapısı.....	7
1.2.1. Cevizin çiçek yapısı	8
1.2.2. Cevizin iklim istekleri.....	9
1.2.3. Cevizin toprak ihtiyacı.....	9
1.3. Çalışmada Kullanılan Ceviz Çeşitleri	9
1.3.1. Chandler cevizi	10
1.3.2. Fernor cevizi	11
1.3.3. Hekimhan cevizi	12
1.3.4. Kaman-1 cevizi	13
1.3.5. Maraş-18 cevizi.....	14
1.3.6. Oğuzlar-77 cevizi.....	15
2. LİTERATÜR TARAMASI	16
3. MATERYAL ve METOD	23

3.1.	Veri seti	23
3.2.	Görüntü Elde Edilmesi	24
3.3.	Yapay Sinir Ağları.....	25
3.4.	Derin Öğrenme	33
3.5.	Transfer Öğrenme.....	35
3.6.	DenseNet121 Modeli.....	36
3.7.	MobileNet Modeli	37
3.8.	NASNetMobile Modeli	38
3.9.	Derin Öğrenmemede Optimizasyon	39
3.9.1.	Parametre optimizasyonu.....	40
3.9.2.	Izgara arama (GridSearch).....	40
4.	PERFORMANS DEĞERLENDİRMESİ.....	42
4.1.	Hesaplama Formülleri	42
5.	DENEYSEL SONUÇLAR	45
5.1.	DenseNet121 Modeli.....	46
5.2.	NASNetMobile Modeli	49
5.3.	MobileNet Modeli	53
5.4.	Parametre Optimizasyonu Yapılmış NASNetMobile Modeli	56
5.5.	Parametre Optimizasyonu Yapılmış DenseNet121 Modeli.....	60
5.6.	Parametre Optimizasyonu Yapılmış MobileNet Modeli	64
6.	SONUÇLAR VE ÖNERİLER.....	68
	KAYNAKLAR	70
	ÖZGEÇMİŞ	78

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2.1 Benzer çalışmalar	19
Çizelge 3.1 Görüntü sayıları.....	23
Çizelge 5.1 Sınıflandırmada elde edilen başarı sayıları.....	45
Çizelge 5.2 Parametre optimizasyonu yapılarak elde edilen sınıflandırma başarı sayıları.....	45
Çizelge 5.3 DenseNet121 doğrulama değerleri.....	46
Çizelge 5.4 NASNetMobile doğrulama değerleri.....	50
Çizelge 5.5 MobileNet doğrulama değerleri.....	53
Çizelge 5.6 NASNetMobile modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri.....	57
Çizelge 5.7 DenseNet121 modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri.....	60
Çizelge 5.8 MobileNet modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri.....	64

ŞEKİLLER DİZİNİ

Şekiller	Sayfa
Şekil 1. 1 Ceviz meyvesinin besin değeri.....	7
Şekil 3.1 Veri aktarımı için kullanılan düzenek şeması.....	24
Şekil 3.2 Sinir ağları	25
Şekil 3.3 Yapay sinir ağları	26
Şekil 3.4 Tek katmanlı sinir ağı.....	27
Şekil 3.5 Çok katmanlı sinir ağı	28
Şekil 3.6 Emrişimsel sinir ağları.....	28
Şekil 3.7 Tekrarlanan sinir ağı yapısı	29
Şekil 3.8 Uzun kısa süreli bellek ağları yapısı	31
Şekil 3.9 Gradyan iniş grafiği.....	32
Şekil 3.10 Derin öğrenme şeması	34
Şekil 3.11 Transfer öğrenme modellerinin tarihsel gelişim sırası diyagramı.....	35
Şekil 3.12 Transfer öğrenme.....	36
Şekil 3.13 DenseNet121 mimari şeması	37
Şekil 3.14 NASNetMobile mimarisi	39
Şekil 5.1 DenseNet121 50 devir (epoch) doğrulama eğrileri grafiği.....	47
Şekil 5.2 DenseNet121 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	48
Şekil 5.3 DenseNet121 karışıklık matrisi.....	48
Şekil 5.4 NASNetMobile 50 devir (epoch) doğrulama eğrileri grafiği.....	51
Şekil 5.5 NASNetMobile 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	51
Şekil 5.6 NASNetMobile karışıklık matrisi.....	52
Şekil 5.7 MobileNet 50 devir (epoch) doğrulama eğrileri grafiği.....	54
Şekil 5.8 MobileNet 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	55

Şekil 5.9 MobileNet karışıklık matrisi.....	55
Şekil 5.10 Parametre optimizasyonu ile elde edilmiş NASNetMobile 50 devir (epoch) doğrulama eğrileri grafiği.....	58
Şekil 5.11 Parametre optimizasyonu ile elde edilmiş NASNetMobile 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	58
Şekil 5.12 Karışıklık matris kullanımı parametre optimizasyonlu NASNetMobile.....	59
Şekil 5.13 Parametre optimizasyonu ile elde edilmiş DenseNet121 50 devir (epoch) doğrulama eğrileri grafiği.....	62
Şekil 5.14 Parametre optimizasyonu ile elde edilmiş DenseNet121 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	62
Şekil 5.15 Karışıklık matris kullanımı parametre optimizasyonlu DenseNet121 modeli	63
Şekil 5.16 Parametre optimizasyonu ile elde edilmiş MobileNet 50 devir (epoch) doğrulama eğrileri grafiği.....	66
Şekil 5.17 Parametre optimizasyonu ile elde edilmiş MobileNet 50 devir (epoch) doğrulama kaybı eğrileri grafiği.....	66
Şekil 5.18 Karışıklık matris kullanımı parametre optimizasyonlu MobileNet modeli...	67

RESİMLER DİZİNİ

Resim	Sayfa
Resim 1. 1 Cevizin çiçek yapısı.....	8
Resim 1. 2 Chandler cevizi.....	10
Resim 1.3 Fernor cevizi.....	11
Resim 1.4 Hekimhan cevizi.....	12
Resim 1.5 Kaman-1 cevizi.....	13
Resim 1.6 Maraş-18 cevizi.....	14
Resim 1.7 Oğuzlar-77 cevizi.....	15

SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir.

Simgeler	Açıklama
ACC	Accuracy (doğruluk)
ADAS	Advanced Driver Assistance Systems (İleri Sürücü Yardım Sistemleri)
ASPP	Atrous Spatial Pyramid Pooling (Aşırı Uzaysal Piramit Havuzu)
CNN	Convolutional Neural Network
CPU	Central Processing Unit (Merkezi İşlem Birimi)
CT	Computed Tomography
ESA	Evrişimli Sinir Ağı
GPU	Graphical Processing Unit (Grafik İşlem Birimi)
HU	Hounsfield Unit
RAM	Random Access Memory (Rastgele Erişim Belleği)
YSA	Yapay Sinir Ağı
NLST	National Lung Screening Trial

1. GİRİŞ

Bulunduğumuz dönemde ceviz ağacı Avrupa’da pek çok ılık iklimli bölgede, Güney ve Kuzey Amerika’da, Güney Afrika, Asya, Avustralya ve Yeni Zelanda gibi Dünyanın pek çok bölgesinde üretilmektedir (Bernard, Barreneche, Lheureux, ve Dirlewanger, 2018).

Ceviz meyvesi üreticiliğinin Anadolu topraklarında yaygın olması temelde iki sebepten kaynaklandığı bilinmektedir. İlk sebep, Akdeniz’e kıyısı olan ülkelerde yaşayan insanların yemek kültürü arasında önemli bir yere sahip olması, ikinci sebep ise uzun zamanlı saklanabilme özelliği olduğundan insanlığın varoluşundan bugüne günlük yemek kültürünün önemli unsurlarından biri olmuştur (Amaral ve diğerleri., 2003).

İnsan sağlığı açısından çokça faydalı ceviz, daha yoğun tekli doymamış yağ hücrelerine sahip olmakla birlikte, günlük yağ ihtiyacımız açısından vazgeçilmez bir etken olan omega-3 ve omega-6 gibi çoklu doymamış yağ asitleri açısından da oldukça zengin bir meyvedir (Amaral, Casal, Pereira, Seabra, ve Oliveira, 2003).

Yemek kültürü açısından yapılan bir araştırma, 120 yıl boyunca 80 000 kadın üzerinde yürütülmüştür. Bu çalışmada, haftada 30 gram ceviz içi tüketenlerin, safra taşı oluşumu riskinde %25 oranında azalma yaşadıkları tespit edilmiştir. Araştırmacılar, elde edilen bu sonucun nedenini tam olarak açıklamakta zorlanmış olmakla birlikte, cevizin yağ profili, fitosteroller ve/veya magnezyum minerali gibi bileşenlerin bu olumlu etkiye katkıda bulunma ihtimalinin yüksek olduğunu belirtmişlerdir (Tsai, ve diğerleri, 2004).

Bilim insanları yaptıkları çalışmalarda ceviz meyvesinin flavonoidler, flavonoller, yağ asitleri açısından oldukça zengin olduğunu tespit etmişlerdir. (Martínez, Labuckas, Lamarque, and Maestri, 2010). İnsan beyninde salgılanan Melatonin hormonu; kişinin biyolojik saat ritmini ayarlanmasına sebep olur ve insanın uyku düzeninin sağlanmasından sorumlu tutulan hormondur. Ceviz meyvesi, insan vücudu tarafından doğrudan kullanılabilen melatonin formunu içermektedir. Yaşlanma ile vücuttaki melatonin üretiminin azalması, sadece uyku düzeninde bozulmalara değil, aynı zamanda olası antioksidan eksikliği ile serbest radikallerin neden olduğu hastalıkların görülme riskinin artmasına da yol açabilir. Ceviz tüketiminin, insan

kanındaki melatonin seviyesini artırdığı ve uyku düzensizlikleri gibi rahatsızlıkların azalmasına katkı sağladığı literatürde belirtilmiştir. (Reiter, Manchester ve Tan, 2005).

Ceviz, gıda alanında endüstriyel açıdan yüksek ekonomik katma değere sahip doğal bir meyve olarak beslenme ve sağlık özellikleri açısından insanlar arasında çok popülerdir ve dünya çapında yaygın olarak tüketilmektedir. (Martínez, Labuckas, Lamarque, ve Maestri, 2010).

Dünyada her yıl 4 498 442 ton ceviz üretilmektedir. Çin dünya üretiminin %50'sinden fazlasını 2 521 504 ton ile karşılayarak birinci sırada yer almaktadır. Türkiye ceviz üretiminde 592 bin ton ile dünyada İran'dan sonra dördüncü sırada yer almaktadır. (FAO, 2019).

Grafik İşleme Birimleri (GPU) teknolojisinin ilerlemesi ve gelişmesi, makine öğreniminin bir alanı olan derin öğrenme dalının gelişmesine yol açmıştır. Ceviz meyvesi türlerinin tanımlanması ve sınıflandırılması için farklı makine öğrenimi ve derin öğrenme hakkında çeşitli araştırma ve geliştirme çalışmaları rapor olarak sunulmuştur (Kırbaş ve Özmen, 2021; Tiwari vd., 2021).

1.1.Cevizlerin Kökeni

Ceviz ailesi, pekan ve hickori ağaçlarını da içermekte olup, kökenleri yaklaşık 40 milyon yıl öncesine dayanmaktadır. Bu tarih, köpeklerin, maymunların, balinaların ve fillerin ortaya çıktığı döneme denk gelir. Gerçekten de ceviz, insanlar tarafından bilinen en eski ağaç yiyeceklerinden biridir. Cevizin ataları, Pers ceviz ağacının fosil kayıtlarında ilk kez 3,45 milyon yıl önce görülmesinden önce, binlerce yıl boyunca farklı şekil ve boyutlarda evrim geçirmiştir. Bu süreçte ceviz, Avrasya'nın geniş bölgelerine; Çin, Orta Asya, Yakın Doğu ve Güney Avrupa'ya yayılmıştır. Ancak, son buzul çağları sırasında ceviz ağacının dağılım alanı daralmış, fakat buzulların çekilmesinden sonra hayatta kalanlar, belirli ceplerde varlığını sürdürmeyi başarmıştır. Arkeolojik bulgular, ceviz tüketiminin yaklaşık 45 000 yıl önce başladığını göstermektedir. Ceviz yetiştiriciliğine dair ilk bulgular, yaklaşık 7 000 yıl öncesine, Neolitik dönemde günümüz İran topraklarına dayanmaktadır. Bu dönem, avcı-toplayıcı yaşam biçiminden tarıma dayalı yerleşik yaşama geçiş sürecini simgelemektedir. Söz konusu dönemden itibaren ceviz, ticaret yolları aracılığıyla Çin, Yakın Doğu ve Avrupa'daki çeşitli medeniyetlere yayılmıştır (Feng ve diğerleri., 2018).

Büyük İskender'in Asya seferlerinden getirdiği cevizler, Yunanlar ve Romalılar arasında popülerlik kazanmıştır. Yunanlar, bu dönemde zaten yerel ceviz türlerini yetiştirmekteydiler. Ancak, getirilen yeni ceviz türü, boyut ve lezzet açısından üstün bulunmuştur. Yunanlar, bu yeni çeşidi kendi yerel ceviz türleriyle melezleyerek fars cevizi adını verdikleri yeni bir varyete geliştirmişlerdir. Bu yeni tür, günümüzde dünya genelinde en çok tercih edilen ceviz türü olmuştur. Bu nedenle, bu başarı için Yunanlara teşekkür edilmelidir. Ayrıca, çalar saat, iPhone, küvetler, geometri dersi, cheesecake, demokrasi gibi birçok icat ve kavram için de eski Yunan'a minnettar olunmalıdır. Bunların yanı sıra, komünizm ve liberalizm kavramlarının temellerinin de eski Yunan'a dayandığı bilinmektedir. Aynı şekilde, Google Haritalar, Olimpiyatlar ve pap smear testi gibi birçok modern kavram ve uygulamanın kökeni de eski Yunan'a dayanmaktadır. Yunanistan'ın fethedilmesinin ardından, Roma İmparatorluğu, Pers cevizi Güney Avrupa ve Kuzey Afrika'da tarım ve ticaret ürünü olarak benimsemiştir. Batık Roma gemilerinin yüklerinde ve Pompei kalıntılarında ceviz kalıntıları tespit edilmiştir. Bu bulgular, Roma döneminde ceviz ticaretinin yaygın olduğunu göstermektedir. Pompei felaketine atıfta bulunan modern eserlerde, bu döneme ait kültürel ve ekonomik bağlamlar sıklıkla ele alınmaktadır. Orta Çağ'a gelindiğinde, Avrupalılar cevizi tıbbi bir ürün olarak değerlendirmeye başlamışlar ve birçok tıp kitabında cevizden bahsetmişlerdir. Ancak, cevizi dünya genelinde yayanlar İngiliz denizciler olmuştur. Cevizin kabuklu hali aylarca dayanabildiği için, eski dünyadaki uzun ticaret rotalarına oldukça uygun hale gelmiştir. Bu sebeple, Fars cevizi ile İngiliz cevizi çeşitleri aynı çeşit olarak kabul edilmiştir. Cevizi küresel bir ticaret malı haline getirmelerine rağmen, İngilizler kendi ülkelerinde ceviz yetiştirmemişlerdir ki bu, İngilizlerin karakteristik özellikleri ile örtüşmektedir. "Ceviz" kelimesi, Eski Galler/İngilizce "wealhnutu" teriminden türemiş olup "yabancı ceviz" anlamına gelir; zira cevizler Avrupa'dan Britanya'ya getirilmiştir. Denizcilerin bu süreçteki rolü unutulmamalıdır. Cevizin bilimsel adı olan *Juglans regia*, eski Roma tanrısı Jüpiter'den türetilmiş olup Latince'de "Jüpiter'in Cevizi" anlamına gelmektedir. Ticari ceviz çeşidi, diğer türlerden ayırt edilebilmesi için genellikle "Fars" veya "İngiliz" cevizi olarak adlandırılmaktadır (Bernard, Barreneche, Lheureux, ve Dirlewanger, 2018).

Cevizler, *Juglandaceae* olarak bilinen bir ağaç ailesinde baskın bir konuma sahiptir. Bu grup, Avrasya ve Amerika kıtalarında yayılmış neredeyse iki düzine tanınmış ceviz türünü içermektedir. Ayrıca bu aile, hickory ve pecan ağaçlarını da kapsamaktadır. Cevizler, mutfakta kullanılan bir kuruyemiş olarak kabul edilmesine rağmen, botanik açıdan bir tohum olarak sınıflandırılmaktadır. Bilimsel anlamda, ceviz bir iç tohumu çevreleyen ve doğal olarak açılarak tohumu serbest bırakmayan sert bir kabuğa sahip bir meyve türüdür. Botanik kuruyemişlere

örnek olarak fındık, kestane ve meşe palamudu verilebilir. Cevizler, önce yeşil lifli dış kabuklarını (ekzokarp) ve ardından yere düştükten sonra çimlenip ağaca dönüşen sert iç kabuklarını (endokarp) dökerler. Bu süreç, onların botanik anlamda kuruyemiş olarak sınıflandırılmasını engellemektedir. Hasat edilen cevizler, tüketilmeden önce kabuklarından çıkarılana kadar kabuklarını korurlar. Çeşitli bölgesel ceviz türleri arasında birçok yenilebilir çeşit bulunmaktadır. Nitekim, Kuzey Amerika’da birkaç yenilebilir tür ve Kaliforniya’da kendine özgü yerli bir tür mevcuttur. Ancak, ana ticari tür *Juglans regia*, yani Fars Ceviz’idir (McGranahan, G., ve Leslie, C. A., 1991).


Juglans regia türü içerisinde, çiftçiler geniş bir çeşitlilikte kültivar yetiştirmektedir. Kaliforniya’da en popüler çeşitler arasında Chandler, Hartley, Howard, Tulare, Serr ve Vina bulunmaktadır. Botanik açıdan bakıldığında, ceviz içi, büyüyen bir ceviz ağacı için enerji bakımından zengin bir besin kaynağı olarak işlev görmektedir. Bu nedenle, kabuğu içerisine en yüksek besin değerini sığdıracak şekilde donatılmıştır. Cevizlerin ağırlığının %65’ini yağ oluşturmaktadır. Bu yağlar, çeşitli sağlık yararları ile ilişkilendirilen omega-3, omega-6 çoklu doymamış yağ asitlerinden oluşur. Özellikle omega-3 yağ asidi, memelilerin kendi kendine üretemediği ve bu nedenle diyet yoluyla alınması gereken değerli bir bileşendir. Cevizler ayrıca antioksidanlar bakımından da zengindir. İçerdikleri antioksidanlar arasında ellagik asit, kateşin, fitik asit ve melatonin bulunmaktadır. İlginç bir şekilde, bazı Orta Çağ hekimleri, muhtemelen uyku ile ilişkili antioksidan melatonin içeriği nedeniyle, cevizi uyku yardımcısı olarak önermiştir. Cevizler, E vitamini, B6 vitamini, folik asit, bakır, manganez ve fosfor gibi bir dizi önemli vitamin ve mineral içermektedir. Cevizler, lezzetli ve çok yönlü besinler arasında yer almaktadır. Kabuktan çıkarılıp sade olarak tüketilmeye elverişli olan cevizler, hoş bir dokuya ve fındıksı bir aromaya sahiptir. Cevizler, sıklıkla salatalara, hamur işlerine, yoğurda, sotelenmiş yemeklere eklenir veya ekmek kırıntıları ile kaplanarak pişmiş balıkların üzerine yerleştirilir. Ayrıca, cevizler fıstık ezmesine benzer yayılabilir bir püre haline getirilebilir. Özellikle süt bazlı yağların yerine alternatiflerin gerektiği vegan yemeklerde ceviz ezmesi, soslara kıvam kazandırmak amacıyla kullanılabilir. Cevizler aynı zamanda yenilebilir bir baharat yağı üretiminde de yaygın olarak kullanılmaktadır. Bu yağ, salatalara veya etlere son dokunuş olarak serpilebilir ve yemek pişirme sırasında tat katmak amacıyla kullanılabilir; ancak yüksek sıcaklıklarda yanma eğilimi gösterdiği için dikkatli kullanılmalıdır (Koyuncu, M. A., ve İslam, A., 2005).

Dünya genelinde pek çok ünlü yemek ceviz içermektedir. Türk tatlısı baklava, doğranmış ceviz ve bal ile doldurulmuş yufka katmanlarından oluşmaktadır. 1890'larda, New York City'deki ünlü Amerikan oteli Waldorf-Astoria, elma, kereviz ve cevizden oluşan tatlı kremalı bir yemek olan "Waldorf Salatası"nı sunmaya başlamıştır. Dünya her yıl yaklaşık 3,5 milyon ton ceviz üretmektedir. Bu üretimin büyük kısmı Çin'de gerçekleşirken, Amerika Birleşik Devletleri, İran ve Türkiye de önemli üreticiler arasındadır. Amerika Birleşik Devletleri'nde yetiştirilen cevizlerin %99'u Kaliforniya'daki bahçelerden gelmektedir. Üretimin çoğu San Joaquin ve Sacramento Vadileri'nde yoğunlaşmıştır, ancak kıyı vadilerinde ve Sierra eteklerinde de üretim yapılmaktadır. Olgun ceviz ağaçlarının derin köklere sahip olmaları nedeniyle, derin ve verimli toprak gereksinimleri bulunmaktadır. Verimli bir ceviz ağacını desteklemek için en az 5-6 fit derinliğinde verimli toprak gereklidir. Toprak ayrıca iyi drene edilmeli ve düşük su tablasına sahip bir bölgede bulunmalıdır. Dikim öncesinde, bahçenin arazisinin düzgün sulama sağlamak amacıyla düzleştirilmesi gerekmektedir. Yeni fidanların köklerinin gelişebilmesi için 5-6 fit derinliğindeki tüm toprak gevşetilmelidir. Fidanların dikileceği yükseltilmiş yataklar veya bireysel tümsekler oluşturulmalıdır. Ceviz bahçelerinin sulanmasında klasik ve en kolay yöntem sel sulama yöntemidir. Ancak, mevcut kuraklık koşulları göz önüne alındığında, su tasarrufu sağlamak amacıyla daha fazla oranda sprinkler veya damla sulama hatları da kullanılmaktadır. Bu yeni sistemler, su tasarrufu sağlama ve yüzey akışını azaltma açısından önemli faydalar sunmaktadır. Sulama hatlarının dikim öncesinde kurulması gerekmektedir. Ceviz yetiştiriciliğinde en etkili yöntem olarak aşılama kabul edilmektedir. Genel olarak, Fars Cevizi (*Juglans regia*) çeşitleri, dayanıklı ve zararlılara karşı dirençli anaçlar üzerine aşılanmalıdır (Küden, A. B., ve Tanrıver, E., 2002).

Ticari Fars ceviz ağaçları doğrudan Fars cevizlerinden yetiştirilebilir; ancak bu uygulama bazı dezavantajlara sahiptir. Özellikle, Fars ceviz anaçları, yerel zararlılar ve çevresel koşullara karşı doğal direnç geliştirmemiştir. Bu dezavantajlar, ağacın zayıflamasına, verimliliğinin azalmasına ve ticari açıdan riskli hale gelmesine neden olabilir. Fars ceviz dallarının, hastalıklara dirençli yerel ceviz anaçlarına aşılanması, ticari açıdan cazip cevizler üreten dayanıklı ağaçlar elde edilmesini sağlar. Bir ceviz ağacının ticari kalitede ceviz üretmesi yedi yıl kadar sürebileceğinden, bu sürecin doğru bir şekilde uygulanması büyük önem taşımaktadır. Ceviz ağaçları, ılıman iklimlerde iyi gelişirler, ancak soğuk hava koşullarından zarar görebilirler. Erken don olayları dallara zarar verirken, geç don olayları çiçeklere veya genç cevizlere zarar verebilir. Bununla birlikte, ılıman Central Valley bölgesinde don hasarı nadirdir. Kış aylarında ceviz ağaçlarının yaz aylarında meyve verebilmesi için uzun bir soğuk dönemine

ihtiyaları vardır. Bu "soğuma saatleri", sıcaklığın 45°F'nin altında olduėu zaman dilimleri olarak tanımlanır. Ceviz ağalarının 800-1000 saat süren aralıklı soğuma saatlerine ihtiyaları vardır. Güneş hasarı ve yüksek sıcaklıklar da ceviz ağaları için tehdit oluşturabilir. Ağalar ve meyveler üzerindeki sıcak hava etkilerini azaltmak amacıyla özel yansıtıcı sprey kaplamalar kullanılabilir. Ceviz ağalarının iekleri, ilkbahar aylarında Nisan ve mayıs aylarında açar. Ceviz ağaları kendine verimli olup, böcek veya kuş tozlaştırıcılarına ihtiya duymazlar. Meyve, yaz mevsimi boyunca büyüyerek sonbaharda olgunlaşır ve bu dönemde yeşil kabuk atlamaya başlar. Cevizler, Eylül ile Kasım ayları arasında, kabukların atlaması ile hasat edilir (Güneş, M., ve Özkan, Y., 2004).

Ceviz ağaları, Kasım ayında yapraklarını döker ve don dönemi sona erdikten sonra Nisan ayında yeniden yapraklanır. Kış aylarında ceviz ağaları, yapraklarını döküp karbonhidrat depolarına güvenerek ilkbahar ieklenmesine kadar hayatta kalmalarını sağlayan "uyku" adı verilen bir süreç yaşarlar. Bu süreç, ceviz ağalarının sağlıklı meyveler üretmesini garanti altına alan önemli bir mekanizmadır. Ceviz baheleri yaklaşık 35 yıl boyunca ceviz üretimi yaparlar, ancak 100 yıla kadar verimli kalabilirler. Hasat, yeşil kabukların atlaması ve cevizlerin ağalardan düşmeye başlamasıyla Eylül ayında başlar. Ağalar, cevizleri düşürmek amacıyla mekanik sallayıcılarla sallanır. Özel süpürme makineleri, düşen cevizleri sıralar halinde toplar ve hasat makineleri bu cevizleri römorklara aktararak işleme tesisine taşır. Dış kabuk, bir soyucu ile çıkarılır ve cevizler dehidrasyona tabi tutulduktan sonra ihtiya duyulana kadar depolanır. Daha sonra cevizler, kabuklu veya kabuksuz olarak sınıflandırılır. Kabuklu cevizler, USDA standartlarına göre küçük, orta, jumbo ve büyük boyutlar olmak üzere eşitli kategorilere ayrılmaktadır. Kabuksuz cevizler ise mekanik olarak atlatılır, tohumlar basınlı hava kullanılarak ayrılır, ardından boyutlandırılır, ayrıştırılır, elle seçilir ve paketlenir (Amaral ve diğerkleri., 2003).



Şekil 1. 1 Ceviz meyvesinin besin değeri (Tarım Orman Portalı, 2023)

1.2.Cevizin yapısı

Ceviz ağaçları, 25 ila 40 metreye kadar uzayabilen boyları ile dikkat çekmektedir. Ağaç kökleri 3 ila 5 metre derinliğe ulaşabilmektedir ve geniş alan kaplayan ağaç türleri arasında yer almaktadır. Bu ağaçlar, taşlı, yarı dik, dik şekillerde bulunabilir. Ceviz ağaçları kazık köklü olup, bu nedenle bol miktarda kılcal kök barındırırlar. Ağaç yüzeyleri oldukça düzgün bir yapıya sahiptir ve gençlik dönemlerinde gövde renkleri gümüşidir (Koyuncu, M. A., ve İslam, A., 2005).

Ceviz ağaçlarının kök yapısı kazık kök olup, bol miktarda kılcal kök içerir. Kökler 3 ila 5 metre derinliğe ulaşabilir ve ceviz kökü toprak içinde yayılırken herhangi bir fiziksel engel (kaya parçası, geçişi engelleyen herhangi bir yapı gibi) ile karşılaştığında ağacın büyüme oranı ve kuvveti etkilenir. Kumlu, taşlı ve çakıllı topraklarda kökler daha hızlı ilerler. (Koyuncu, M. A., ve İslam, A., 2005).

Ceviz ağaçlarının gövde ve dal yapısı toprağın yüzeyinden 1 ila 2 metre yukarıda dallanır. Gövdenin çevresi ise 5 ila 6 metre yüksekliğe kadar büyüyebilir. Genç yaşlarda ceviz ağaçlarının gövdesi gümüşü renkte olup, yüzeyi oldukça düzgündür. Ağacın yaşı ilerledikçe renkleri koyulaşır ve düzgün yüzeylerinde çatlaklar oluşur (Akça, Y., ve Sen, S. M., 1999).

1.2.1. Cevizin çiçek yapısı

Ceviz ağaçları, rüzgarla tozlanır ve bu özelliğe anemofil denir. Ceviz ağaçları, diploit olup 32 kromozoma sahiptir ve botanik açıdan monoik bitkiler arasında sınıflandırılır. Ceviz genotiplerinde nadiren homogami çiçeklenme gözlemlenmekle birlikte, dikogami çiçeklenme yaygın bir özelliktir. Dişi ve erkek çiçekler aynı ağaçta farklı yerlerde ve farklı zamanlarda açarlar, bu duruma protandri ve protegin denir. Bu nedenle, ceviz çeşitleri büyük oranda yabancı tozlanma ile gerçekleşir (Akça, Y., ve Şen, S. M., 1999).



Resim 1. 1 Cevizin çiçek yapısı (Tarım Orman Portalı 2023)

1.2.2. Cevizin iklim istekleri

Ceviz ağaçlarının soğuklama ihtiyacı 800 ila 1800 saat arasındadır ve deniz seviyesinden 2000 metre yüksekliğe kadar olan alanlarda yayılış gösterirler. Aşırı yaz sıcaklıklarında yeşil kabuk, yapraklar ve meyveler zarar görebilir; yeşil kabukta ve yapraklarda yanıklar, meyvelerde ise büzülmeler oluşabilir. Ceviz yetiştiriciliğini kısıtlayan en kritik faktörlerden biri, ilkbahar geç donlarıdır. Çeşitlerin iklim ihtiyaçları dikkatlice belirlenmeli ve özellikle ilkbahar geç donlarına karşı hassasiyetleri göz önünde bulundurulmalıdır. İlkbahar geç donlarına ek olarak sonbahar geç donları da ceviz yetiştiriciliğini sınırlayıcı faktörler arasındadır. Çeşitlerin geç yapraklanması, vejetasyon süresini kısaltarak, olgunlaşamayan sürgünlerin erken sonbahar donlarından zarar görmesine neden olabilir. Geç sonbahara kadar büyümeye devam eden genç ceviz ağaçlarının uç sürgünleri yeterince olgunlaşmamışsa, -10°C 'de zarar görebilirler. Sonbaharın erken donlarında ise -9°C ile -12°C arasında odunlaşmamış sürgünler zarar görür. Çiçeklenme döneminde soğuk hava hasarı daha yaygın olarak gözlemlenir. Genel anlamda ceviz ağaçları, kışın -25°C 'ye, yazın ise $+40^{\circ}\text{C}$ 'ye kadar dayanıklılık gösterebilmektedir (Güneş, M., ve Özkan, Y., 2004).

1.2.3. Cevizin toprak ihtiyacı

Ceviz ağaçları, toprak türü konusunda fazla seçici olmamakla birlikte, taban suyu seviyesi 2,5-3,0 metreyi aşmayan, su tutmayan ve nemini muhafaza eden derin topraklarda en iyi şekilde gelişirler. Su tutan killi topraklar ve durgun sulu alanlar, ceviz ağaçlarının büyümesi için uygun değildir. İyi havalanabilen ve işba değeri 50-70 arasında olan topraklar, ceviz yetiştiriciliği için en elverişli topraklardır. Kazık köklü olan ceviz ağaçlarının kökleri derinlere uzandığı için, alt katmanları nemli olan derin ve yumuşak topraklar daha uygun büyüme koşulları sağlar. Aşırı nem ve durgun sular, kökler için gereken oksijenin alınmasını engelleyerek kök gelişimini yavaşlatır ve ağacın genel gelişimini durdurur. Toprağın pH değeri 6,5-7,5 arasında olmalıdır (Küden, A. B., ve Tanrıver, E., 2002).

1.3.Çalışmada Kullanılan Ceviz Çeşitleri

Bu tez çalışmasında Türkiye'de yaygın olarak üretilen ceviz türlerinden altı çeşit ele alınmıştır. Kullanılan ceviz çeşitleri hakkında detaylı bilgiler aşağıda verilmiştir.

1.3.1. Chandler cevizi



Resim 1. 2 Chandler cevizi

Chandler cevizleri, kabuğunu neredeyse tamamen dolduran oval biçimli çekirdeği ile diğer birçok ceviz çeşidinden daha büyük boyutlara sahiptir. Kabukları tipik olarak açık renkte ve nispeten incedir, bu da onları kırmayı ve içeriğini çıkarmayı kolaylaştırır. Chandler cevizi son derece verimli bir ceviz türü olup, oldukça bol miktarda meyve verir. Verim oranı %80 ile %90 arasında değişmektedir. Ancak, yetiştirme sırasında oldukça özenli bir bakım gerektiren bir türdür. Örneğin, Chandler ceviz ağaçları, özellikle büyümenin ilk birkaç yılında düzenli sulamaya ihtiyaç duyar. Hastalık dayanıklılığı yüksek olan Chandler ceviz ağaçları, kolay hastalanmayan bir türdür ve bu nedenle meyveleri oldukça yüksek kalitededir. Chandler cevizi, melez bir ceviz türüdür. Bu tür, Pedro cevizi ile UC 56-224 cevizlerinin melezlenmesi sonucu elde edilmiştir (Koşar ve diğerleri., 2023).

1.3.2. Fernor cevizi



Resim 1.3 Fernor cevizi

Fernor ceviz (*Juglans regia* “Fernor”), Fransa kökenli bir ceviz türü olup, yüksek verimlilik ve besin değerleri ile tanınmaktadır. Franquette ve Lara ceviz türlerinin melezlenmesiyle elde edilen Fernor ceviz, 1200 ila 1800 metre yükseklikte yetişir ve soğuk iklim koşullarına dayanıklıdır. Bu ceviz türü, iyi drene edilmiş, hafif asidik toprak yapısına uygun olup, güneşe yeterli ışık ihtiyacı duyar. Geç çiçeklenme özelliği sayesinde ilkbahar ve sonbahar donlarının etkisinden korunur Fernor cevizinin meyveleri, ince kabuklu ve salkımlar şeklinde olup, ortalama 12 gram ağırlığındadır ve iç meyve oranı %49’dur. Meyvelerdeki yağ oranı %50, protein oranı ise %20’dir. Bu ceviz türü, yüksek omega-3 yağ asit içeriği ve antioksidan özellikleri ile bilinir, bu da kalp sağlığını destekler, kolesterol seviyelerini düzenler ve genel vücut sağlığını iyileştirir. Fernor ceviz, yüksek verimlilik ve kaliteli meyveleri ile ekonomik bir değer taşır. Organik tarıma uygun olarak yetiştirilebilir ve taze veya işlenmiş olarak pazarlanabilir (Aslantaş, R., ve Ertürk, Ü., 2006).

1.3.3. Hekimhan cevizi



Resim 1.4 Hekimhan cevizi

Hekimhan Cevizi (*Juglans regia* L.), Türkiye'nin Malatya ilinin Hekimhan ilçesinde yetiştirilen ve genetik özellikleri ile dikkat çeken bir ceviz türüdür. Bu tür, ince kabuğu (kabuk kalınlığı 1,5 milimetreye kadar), yüksek iç randımanı (iç renginin %50'nin üzerinde beyaz ve açık sarı) ve yüksek yağ oranı (%60-70 arasında) ile ön plana çıkar. Hekimhan cevizinin meyveleri, bilhassa omega-3 yağ asitleri, fitosteroller ve antioksidan bileşenler açısından bol miktarda olup, kalp sağlığını destekleyici, kolesterol seviyelerini düzenleyici ve çeşitli kronik hastalık risklerini azaltıcı etkileriyle bilinir. Organik tarıma uygun olarak yetiştirilebilen bu ceviz türü, taze veya işlenmiş olarak pazarlanabilir ve ekonomik açıdan yüksek değer taşır. Hekimhan cevizinin genetik çeşitliliği ve dayanıklılığı, tarım sektörüne önemli katkılar sağlamakta ve çiftçiler için avantajlı bir seçenek sunmaktadır (Hekimhan Portalı, 2025).

1.3.4. Kaman-1 cevizi



Resim 1.5 Kaman-1 cevizi (Zencefil Organik Portalı, 2025)

Kaman-1 Cevizi (*Juglans regia* “Kaman-1”), Türkiye’de yetiştirilen ve Maras 18 ve Sutyemez 1 gibi diğer yeni ceviz çeşitleriyle birlikte seçimle elde edilmiş bir ceviz türüdür. Bu tür, ince kabuklu ve yüksek iç randıman özellikleri ile dikkat çeker. İç rengi %50’nin üzerinde beyaz ve açık sarı olan bu ceviz türü, gecikmiş yaprak döngüsü ve lateral bölme özellikleri ile öne çıkar (Özkan, Y., ve Gülşen, Y., 2005).

Kaman-1 ceviz, derin ve nemliliğini koruyan topraklarda iyi gelişir ve güneşe yeterli ışık ihtiyacı duyar. Geç çiçeklenme özelliği sayesinde, ilkbahar ve sonbahar donlarından etkilenmez. Bu ceviz türü, özellikle ilkbahar ve sonbahar donlarına karşı dayanıklıdır. Kaman-1 cevizinin meyveleri, ince kabuklu ve salkımlar şeklinde olup, ortalama 11 gram ağırlığındadır. Meyvelerin yağ oranı %60-70 arasında değişmektedir. Bu ceviz türü, yüksek omega-3 yağ asitleri ve antioksidan bileşenler içerir. Bu özellikler, kalp sağlığını destekleyici ve kolesterol seviyelerini düzenleyici etkileri ile bilinir. Ekonomik açıdan değerlendirildiğinde, Kaman-1 ceviz organik tarıma uygun olarak yetiştirilebilir ve taze veya işlenmiş olarak pazarlanabilir. Genetik çeşitliliği ve dayanıklılığı ile tarım sektörüne önemli katkılar sağlar (Özkan, Y., ve Gülşen, Y., 2005).

1.3.5. Maraş-18 cevizi



Resim 1.6 Maraş-18 cevizi (Aksu Tarım Portalı, 2025)

Maraş-18 Cevizi (*Juglans regia* “Maraş-18”), Türkiye’nin Kahramanmaraş ilinde yetiştirilen ve Prof. Dr. Mehmet Sütyemez tarafından geliştirilen bir ceviz türüdür. Bu tür, ince kabuklu (kabuk kalınlığı 1,5 milimetreye kadar) ve yüksek iç randıman (iç renginin %54’ün üzerinde beyaz ve açık sarı) özellikleri ile bilinir. Meyvelerin kabuk kalınlığı ve kolay kabuktan ayrılma özelliği, Maraş-18 cevizi özel kılan önemli özelliklerdir. Yetiştirme özellikleri açısından Maraş-18 cevizi, derin ve nemliliğini koruyan topraklarda iyi gelişir ve güneşe yeterli ışık ihtiyacı duyar. Bu ceviz türü, ilkbahar ve sonbahar donlarının etkisinden korunmakta olup, genellikle 900 ila 1700 metre yüksekliklerde yetişmektedir. Maraş-18 cevizinin meyveleri, yüksek omega-3 yağ asitleri ve antioksidan bileşenler içerir. Bu özellikler, kalp sağlığını destekleyici ve kolesterol seviyelerini düzenleyici etkileri ile bilinmektedir. Ekonomik açıdan değerlendirildiğinde, Maraş-18 ceviz, organik tarıma uygun olarak yetiştirilebilir ve taze veya işlenmiş olarak pazarlanabilir. Bu ceviz türü, genetik çeşitliliği ve dayanıklılığı ile tarım sektörüne önemli katkılar sağlar. Yüksek kaliteli ve besleyici özelliklere sahip olması, Maraş-18 cevizi ticari açıdan değerli kılar (Küden, A. B., ve Tanrıver, E., 2005).

1.3.6. Oğuzlar-77 cevizi



Resim 1.7 Oğuzlar-77 cevizi (Oğuzlar Portalı, 2019)

Oğuzlar cevizi, Türkiye'nin Çorum ilinin Oğuzlar ilçesinde yetiştirilen ve özel coğrafi işaretlere sahip olan bir ceviz türüdür. Bu ceviz, ince kabuklu ve yüksek iç randıman özellikleri ile bilinir. Oğuzlar cevizinin meyvesi, lezzeti ve besin değerleri ile dikkat çeker. Meyvelerin kabuk kalınlığı ve kolay kabuktan ayrılma özelliği, bu ceviz türünün özel bir yere sahip olmasına katkıda bulunur. Oğuzlar cevizleri, ilçe sınırları içinde 510 metreden 1260 metreye kadar değişen yüksekliklerde yetişir. Bu ceviz türü, çok şiddetli soğuklara maruz kalmadığı sürece düzenli olarak meyve verir. Oğuzlar cevizinin kendine özgü dallanma biçimi, diğer ceviz türlerinden kolayca ayırt edilmesini sağlar. Meyvenin dış rengi koyu yeşil olup, ucu hafifçe sivridir. İç rengi ise açık sarı olup, bu rengi uzun süre muhafaza edebilir. Hasat dönemi eylül sonlarında gerçekleşen Oğuzlar cevizi, kurutulduktan sonra tüketilmeye hazır hale gelir. Lezzetli meyvesi ve kabuktan bütün olarak kolayca ayrılması, bu cevizi diğer türlerden ayıran özelliklerdendir. Oğuzlar ceviz, organik tarıma uygun olarak yetiştirilebilir ve hem taze hem de işlenmiş olarak pazarlanabilir. Modern teknoloji ve yapay zekâ uygulamaları, tarım sektöründe hastalıkların tespiti ve bitki türlerinin sınıflandırılması gibi çalışmalarda da kullanılmaya başlamıştır. Yapay zekâ teknikleri ve yüksek doğruluğa sahip sınıflandırma yöntemleri sayesinde, zaman ve iş gücü tasarrufu sağlanmaktadır (Arsenovic ve diğerleri., 2019).

Biz bu çalışmada ile Türkiye'de yetişen ve yaygın olarak tüketilen ceviz türlerinden altı tanesi görüntü işleme ve derin öğrenme yöntemleri ile sınıflandırılmıştır.

2. LİTERATÜR TARAMASI

Ceviz çeşitlerinin derin öğrenme yöntemleriyle tespitine yönelik çalışmalar ve benzer meyveler üzerine gerçekleştirilen araştırmalar aşağıda ele alınmıştır.

Simopoulos (2004) tarafından yapılan çalışmada, ceviz meyvesinin besin bileşimi detaylı olarak incelenmiştir. Araştırma bulgularına göre, 100 gram ceviz içerisinde Omega-3 ve Omega-6 çoklu doymamış yağ asitleri sırasıyla 9,081 gram ve 38,095 gram olarak belirlenmiştir. Ayrıca, cevizde yağda çözünen A ve E vitaminlerinin yanı sıra, B1, B2, C, folik asit, pantotenik asit ve niasin gibi suda çözünen vitaminler de tespit edilmiştir. Bununla birlikte, ceviz içeriğinde demir, magnezyum, bakır, çinko ve fosfor gibi temel minerallerin bulunduğu da ortaya konmuştur.

Bryant ve ark. (1999) tarafından yapılan çalışmada, çeşitli minerallerin insan sağlığı üzerindeki etkileri incelenmiştir. Araştırma bulgularına göre, kalsiyumun diş ve kemik gelişiminde kritik bir rol oynadığı belirlenmiştir. Magnezyum eksikliğinin hipertansiyon, koroner kalp hastalıkları, diyabet, astım ve migren gibi sağlık sorunlarına yol açabileceği tespit edilmiştir. Çinko, insan vücudunda yaygın olarak bulunan temel bir element olup, toplam içeriğinin %85'i kas ve kemiklerde, %11'i ise deri ve akciğerlerde yer almaktadır. Manganın, sinir sistemi fonksiyonları ve kalp ritminin düzenlenmesinde önemli bir rol oynadığı ortaya konmuştur. Bununla birlikte, demirin insan organizmasının sağlıklı işleyişi için hayati bir mineral olduğu belirlenmiştir. Ayrıca, bakırın birçok enzimin işlevselliğinde kofaktör olarak görev yapan temel bir iz element olduğu tespit edilmiştir.

Anagnostis ve arkadaşları (2021) yaptıkları çalışmada ceviz ağacındaki antraknoz hastalığını real time tespit eden bir sistem tasarlamışlardır. Bu sistem ile %87 sınıflama doğruluğu elde etmişlerdir.

Dian, Lijuan, ve arkadaşları (2019) yaptıkları çalışmada cevizdeki yabancı cisimleri tespit eden bir sistem tasarlamışlardır. Bu sistemde 101 test görüntüsünde nesne bölgelerinin %99,5 ini ve 277 doğrulama görüntüsündeki yabancı nesnelerin %95'ini doğru bir şekilde sınıflandırmışlardır.

Ercişli ve ark. (2012) yaptıkları çalışmada Türkiye’de yetiştirilen 10 adi ceviz (*Juglans regia* L.) çeşidinin boyut ve şekil özellikleri görüntü işleme tekniği kullanılarak incelemişlerdir. Çeşitler arasındaki kütle, hacim, geometrik ortalama çap, küresellik ve yüzey alanı için ortalama değerler sırasıyla 11,42 ile 18,28 gram, 23,84 ile 48,32 santimetreküp, 35,71 ile 45,89 milimetre, %83,0 ile %94,1 ve 42,73 ile 66,16 santimetrekare arasında değişiklik göstermektedir.

Altuntaş ve Özkan (2008) tarafından gerçekleştirilen çalışmada, Türkiye’de yetişen üç ceviz çeşidinin sert kabuklu yemiş ve iç kısımlarına ait fiziksel özellikler belirlenmiştir. Bu özellikler arasında boyut, ağırlık, küresellik, kütle yoğunluğu, hacim ve sürtünme katsayısı yer almaktadır. Ayrıca, farklı sıkıştırma hızları (30 ve 60 mm/dak) kullanılarak X, Y ve Z eksenleri boyunca ortalama kopma kuvveti, deformasyon ve kırılma enerjisi ölçülmüş ve bu veriler aracılığıyla ceviz çeşitlerinin kabuklu yemiş ve iç kısmının hasara karşı dirençleri tespit edilmiştir. Çalışma sonucunda, ceviz veya çekirdeğin kırılması için gereken en düşük kuvvetin, 60 mm/dak sıkıştırma hızında test edilen Şebin ceviz çeşidinde olduğu bulunmuştur.

Sanlı ve ark. (2022) tarafından gerçekleştirilen çalışmada, ceviz sınıflarını tespit etmek amacıyla YOLOv5 sınıflandırma modeli kullanılmış ve elde edilen sonuçlar, YOLOv4 ve YOLOv3 modelleri ile karşılaştırılmıştır. Çalışmada, üç farklı ceviz türü üzerinde bu karşılaştırma yapılmış ve elde edilen doğruluk oranları sırasıyla %99,5; %98,4 ve %97,1 olarak belirlenmiştir. Ayrıca, tek bir görüntünün algılama süresi 7 ms olarak ölçülmüştür. Sonuçlar, YOLOv5 tabanlı ceviz algılama modelinin, en yüksek algılama doğruluğu ve hızına sahip olduğunu göstermektedir.

Chen ve ark. (2022) tarafından yapılan çalışmada, toplamda 4395 adet orijinal görüntü kullanılmıştır. Bu görüntüler, 947 adet birinci sınıf ceviz içi, 1183 adet ikinci sınıf ceviz içi, 1020 adet üçüncü sınıf ceviz içi ve 1245 adet dördüncü sınıf ceviz içi olarak sınıflandırılmıştır. Çalışmada, ResNet 152V2 modeli kullanılarak %87,7 doğruluk oranı elde edilmiştir.

Yu ve ark. (2023) tarafından yapılan çalışmada, başlangıçta 1320 adet ceviz içi görüntüsü kullanılarak MATLAB ile geliştirilen 5732 adet yeni görüntü elde edilmiştir. Elde edilen bu verilerle, YOLOv5 modeli kullanılarak %90,81 başarı oranı sağlanmıştır.

Roy ve ark. (2021) tarafından yapılan çalışmada, derin öğrenme modeli kullanılarak meyveler üzerindeki hastalıklar tespit edilmiştir. Çalışmada E-Unet modeli uygulanmış ve %97,54 doğruluk oranıyla hastalıkların tespiti başarıyla gerçekleştirilmiştir.

Karadeniz ve ark. (2023) tarafından yapılan çalışmada, 18 farklı ceviz çeşidinden elde edilen 1751 yaprak görüntüsü kullanılarak araştırmalar gerçekleştirilmiştir. Çalışmada, VGG16 ESA algoritmasıyla %77,11, DVM metoduyla %84,75 ve ResNet101 modeliyle %92,59 doğruluk oranları elde edilmiştir.

Derin öğrenme ile bu alanda yapılmış benzer çalışmalar çizelge 2.1 de verilmiştir.



Çizelge 2.1 Benzer çalışmalar

Sıra	Mahsul	Veri Sayıları	Sınıf	Metot	Doğruluk(%)	Referanslar
1	Ceviz Ağacı	279 ağaç	2	Resnet50, Inceptionv2, Mobilenetv2	63 39 48	(Anagnostis ve diğerleri., 2021)
2	Ceviz	1562	4	UNET	95 99,5	(Rong ve diğerleri., 2019)
3	Ceviz	300	3	PCA	83 94,1	(Erişli ve diğerleri., 2012)
4	Ceviz	200	4	VGG19, EfficientNetB7, ResNet152V2, ResNet152V2-SA-SE	74,1 63,2 6,2 92,2	(Chen ve diğerleri., 2022)
5	Ceviz	1751	18	VGG 16 ESA , SVM, ResNet101	77,11 84,75 92,59	(Yu ve diğerleri., 2023)

Song ve ark. (2019) tarafından yapılan çalışmada, ceviz çeşitleri su ve yağ içeriğine göre sınıflandırılmış ve saklama koşulları belirlenmiştir. Ayrıca, ceviz kalitesinin fiziksel ve kimyasal göstergelerine dayanarak numunelerin nükleer manyetik rezonans (NMR) enine gevşeme süresi (T2) elde edilmiştir. Bu tespit için düşük alanlı nükleer manyetik rezonans (LFNMR) teknolojisi kullanılmıştır.

Peng Jiyu ve ark. (2015) tarafından yapılan çalışmada, yazarlar ceviz tozu çeşitlerini ilk kez sınıflandırmak amacıyla lazer kaynaklı bozulma spektroskopisi (LIBS) ve çok değişkenli analiz yöntemlerini kullanmışlardır. Çalışma sonuçları, ceviz tozu çeşitlerinin sınıflandırılmasında LIBS teknolojisinin çevrimiçi uygulanması için ilk ilke kanıtı verilerini sağlamıştır.

Lu Jun ve ark. (2017) tarafından yapılan çalışmada, Mangjian aslan başı, Guanmao cevizi ve Jixin cevizine ait 300 numune üzerinde Matlab simülasyon yazılımı ile özellik çıkarma ve sınıflandırma testi gerçekleştirilmiştir. Çalışma sonuçları, gri seviye eş-oluşum matrisi ile çıkarılan özellik parametrelerinin tanınma oranının %93,3'e kadar ulaştığını göstermektedir.

Simin Khalesi ve ark. (2011) tarafından yapılan çalışmada, İran cevizlerinin Sangi ve Kaghazi genotiplerinin sınıflandırılması amacıyla akustik tabanlı akıllı bir sistem geliştirilmiş ve Yapay Sinir Ağları (YSA) modelleri oluşturulmuştur. Her bir genotip için 2000 örnek olmak üzere toplamda 4000 ceviz ses sinyali kaydedilmiştir.

Hongzhe Jiang ve ark. (2021) tarafından yapılan çalışmada, Çin ceviz çeşitlerini doğru bir şekilde tanımlamak ve görselleştirmek amacıyla hiperspektral görüntüleme tekniği araştırılmıştır. Çalışma, hiperspektral görüntüleme tekniğinden çıkarılan özelliklerin olağanüstü bir yeteneğe sahip olduğunu ve Çin cevizleri için çevrimiçi bir tanımlama sisteminin daha da geliştirilmesi için güvenilir bir araç olarak uygulanabileceğini göstermiştir.

Hongyan Zhu ve Jun Li Xu (2020) tarafından yapılan çalışmanın sonucunda, 700–4350 cm⁻¹ arasındaki tam spektral aralığın kullanılmasının, bazı sınıflandırıcılar için optimum spektral değişkenlerin alt kümelerinin kullanılmasından daha yetersiz olduğu tespit edilmiştir. Çalışma, geri yayımlı sinir ağının (BPNN) en iyi model performansını sağladığını, rastgele ormanlar (Random Forest) yönteminin ise en kötü sonucu ürettiğini göstermiştir.

Koç ve ark. (2020) tarafından yapılan çalışmada, fındık meyvesini kabuklu halde fotoğraflar üzerinden sınıflandıran bir sistem geliştirilmiştir. Tombul, sivri ve kara fındık çeşitleri, makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak sınıflandırılmıştır. Çalışmada, kabuk sıkıştırma mukavemeti göz önünde bulundurularak, Arttırma yöntemiyle %72, Torbalama yöntemi (Random Forest) ile %83 ve DL4J (Derin Öğrenme Algoritması) ile %71 sınıflandırma doğruluğu elde edilmiştir.

Bayrakdar ve ark. (2015) tarafından yapılan çalışmada, 3 farklı fındık türü görüntüler üzerinden sınıflandırılmıştır. Tombul, sivri ve badem türü fındık çeşitleri, çap, yarıçap, alan gibi şekil ve boyut özelliklerinden yararlanarak %84 doğruluk oranına ulaşılmıştır.

İkramullah K. ve Eros P. (2014) tarafından yapılan çalışmada, fındık çeşitleri X-ray görüntülerinde özellik çıkarımı ve sınıflandırma yöntemiyle tespit edilmiştir. Çalışmada, röntgen görüntüleriyle elde edilen veri seti 748 sağlıklı görüntü içermektedir. Fındık ürünleri üzerinde yapılan analizde, 20 hasarlı ve 20 enfekte fındık görüntüsü kullanılmıştır. Örneklerin %95'i "iyi" kategorisine aitken, "kötü" kategorisine ait örnekler %5 oranında bulunmuştur. Seçilen bozuk fındıkların tespiti için anormallik tespit algoritması uygulanmıştır.

Russakovsky ve ark. (2015) tarafından yapılan çalışmada, büyük ölçekli gerçek veri toplamanın zorlukları tartışılmış, kategorik nesne tanımadaki önemli atılımlar vurgulanmış ve büyük ölçekli görüntü sınıflandırma ile nesne algılama alanının mevcut durumu detaylı bir şekilde analiz edilmiştir. Çalışma sonuçları, mevcut durumla karşılaştırıldığında bilgisayar verilerinin daha kesin olduğunu ortaya koymuştur.

Gupta ve ark. (2022) tarafından yapılan çalışmada, derin öğrenme metotlarının tıbbi çalışmalardaki uygulama alanları incelenmiş ve bu yöntemlerin tıbbi tedavilerde gözle görülür faydalar sağladığı belirlenmiştir.

Engin Güneş'in (2022) tez çalışmasında, oluşturulan veri setinin %10'u kullanılarak VGG16 sınıflandırma modelinin %88, InceptionV3 modelinin %72 ve ResNet50 modelinin %56 başarı oranına sahip olduğu belirlenmiştir.

Sun Z. ve ark. (2020) tarafından yapılan çalışmada, mısır, arpa, soya, şeker pancarı, yonca ve buğday gibi tarımsal ürünlerin sınıflandırılması üzerine araştırma gerçekleştirilmiş ve %82'nin üzerinde bir başarı oranı elde edilmiştir.

Türkoğlu M. ve ark. (2021) tarafından yapılan çalışmada, kayısı meyvesindeki hastalıkların tespiti ve sınıflandırılması amacıyla derin öğrenme yöntemleri kullanılmıştır. Çalışma sonucunda, kayısı hastalıkları %98,20 doğruluk oranıyla sınıflandırılmıştır.

Hossain M. S. ve ark. (2018) tarafından yapılan çalışmada, derin öğrenme yaklaşımı kullanılarak meyve çeşitlerinin sınıflandırılması üzerine araştırma gerçekleştirilmiş ve %99'un üzerinde bir başarı oranı elde edilmiştir.

Kang H. ve Chen C. (2020) tarafından yapılan çalışmada, derin öğrenme yöntemi kullanılarak meyve üretim alanlarında gerçek zamanlı elma tespiti gerçekleştirilmiş ve %85 doğruluk oranı elde edilmiştir.

Han Y. ve ark. (2021) tarafından yapılan çalışmada, kuruyemiş türleri kullanılarak kuruyemiş kalitesinin tahmini üzerine araştırma gerçekleştirilmiş ve derin öğrenme yöntemi ile ortalama %95 başarı oranı elde edilmiştir.

Saranya ve ark. (2020) tarafından yapılan çalışmada, elma, muz, portakal ve nar meyvelerinin sınıflandırılması için makine öğrenimi ve derin öğrenme algoritmaları kullanılmıştır. Sınıflandırma sürecinde R, G, B renk bileşenleri, meyve boyu ve eni fiziksel özellikler olarak değerlendirilmiştir. Çalışmanın karşılaştırmalı sonuçlarında, K-en yakın komşu algoritması için doğruluk oranı %49, destek vektör makinesi için %61 olarak belirlenirken, evrişimli sinir ağı tabanlı sınıflandırma sisteminde %97 doğruluk oranı elde edilmiştir.

Kavdir ve Guyen (2008) tarafından yapılan çalışmada, elma sınıflandırması için bulanık mantık kullanılmış ve bulanık mantık uzman sistemi ile elde edilen sınıflandırma sonuçları %89 doğruluk oranına ulaşmıştır.

Pronprasit ve Natwichai (2013) tarafından yapılan çalışmada, NIR spektroskopisi ve topluluk sınıflandırması kullanılarak mango meyve kalitesinin tahmin edilmesi üzerine odaklanılmıştır. Standart hata değerleri, önerilen topluluk sınıflandırıcı, naif topluluk sınıflandırıcı ve tek sınıflandırıcı için sırasıyla 0,95; 1,08 ve 0,99 olarak belirlenmiştir. Çalışma, topluluk sınıflandırıcılarının değişen koşullarda iyi performans gösterebileceğini ortaya koymuştur.

Miraei Ashtiani ve ark. (2020) tarafından yapılan çalışmada, uzunluk, maksimum genişlik ve maksimum kalınlık gibi kabuk özelliklerinden yararlanarak tahmini badem taneleri kütlesi hesaplanmıştır. Bu amaçla, çok doğrusal regresyon modeli, çok katmanlı algılayıcı sinir ağı, radyal tabanlı fonksiyon sinir ağı, uyarlanabilir nöro-bulanık çıkarım sistemi ve destek vektör makinesi algoritmaları kullanılmıştır. Radyal tabanlı fonksiyon sinir ağı kullanılarak badem tanelerinin kütlesi için yüksek genel doğruluk oranı %96 olarak elde edilmiştir.

3. MATERYAL ve METOD

Tez çalışmasında kullanılan veri seti, yöntemler ve araçlar bu bölümde açıklanmıştır. Araştırmanın bilimsel geçerliliğini ve tekrar edilebilirliğini garanti altına almak için kullanılan teknolojik altyapı ve analiz yöntemleri detaylı bir biçimde sunulmuştur. Bu çalışmada, derin öğrenme tabanlı sınıflandırma yöntemlerinin ceviz çeşitlerinin ayırt edilmesi üzerindeki uygulanabilirliği incelenmiştir.

3.1. Veri seti

Tez çalışmasında Chandler, Fernor, Hekimhan, Kaman-1, Maraş-18 ve Oğuzlar-77 ceviz çeşitlerinden alınan görüntüler üzerinden derin öğrenme ile sınıflandırma yapılmıştır. Bu amaçla Chandler cinsi cevizden 408 tane, Fernor cinsi cevizden 459 tane, Hekimhan cinsi cevizden 485 tane, Kaman-1 cinsi cevizden 425 tane Maraş-18 cinsi cevizden 393 tane ve Oğuzlar-77 cinsi cevizden 610 görüntü olmak üzere toplam 2780 adet görüntü elde edilmiştir.

Veri setinde yer alan ceviz çeşitleri ve bu ceviz çeşitlerinin görüntü sayıları Çizelge 3.1 de verilmiştir.

Çizelge 3.1 Görüntü sayıları


Ceviz Çeşitleri	Görüntü Sayısı
Chandler	408
Fernor	459
Hekimhan	485
Kaman-1	425
Maraş-18	393
Oğuzlar-77	610
Toplam	2780

Bu görüntüler Şekil 3.1 de verilen düzenek yardımı ile çekilmiştir. Görüntüler 3024x3024 boyutunda renkli ve jpg formatındadır. Resimler, F1,7 diyafram açıklığı ISO40 hassasiyeti ile flaşsız olarak çekilmiştir.

3.2.Görüntü Elde Edilmesi

Araştırmamızda kullandığımız cevizlerin görselleri, üzerinde kamera yerleştirdiğimiz dört tarafı kapalı bir kutu kullanılarak elde edilmiştir ve içinde bir aydınlatma mekanizması bulunmaktadır. Bunun sebebi ışık almasını önlemek ve dışarıdan gelen ışığı ve gölgeyi önlemek ayrıca numuneler üzerinde gölge oluşumuna engel olmaktır. Kutu zemini beyaz olarak ayarlanmıştır. Böylece cevizler çekim sırasında kolayca ayırt edilebilir.

Derin öğrenme materyallerinin sisteme aktarılmasında kullanılan düzenek Şekil 3.1’de gösterilmiştir.




Şekil 3.1 Veri aktarımı için kullanılan düzenek şeması

Ceviz görüntüleri, dış ortam koşullarının etkisini en aza indirmek ve tutarlı veri elde etmek amacıyla özel olarak tasarlanmış kapalı bir düzenek içerisinde kaydedilmiştir. Görüntüleme işlemi, sabit aydınlatma ve standart çekim koşulları sağlanarak gerçekleştirilmiş olup, bu sayede ışık değişimlerinden kaynaklanabilecek olası varyasyonlar minimize edilmiştir. Veri toplama sürecinde, yüksek çözünürlüklü bir cep telefonu kamerası kullanılmış ve farklı açılardan görüntüler alınarak çeşitliliğin artırılması hedeflenmiştir. Böylece, ceviz türlerinin belirlenmesine yönelik daha güvenilir ve tutarlı bir veri seti oluşturulmuştur.


3.3.Yapay Sinir Ağları

Yapay sinir ağları (YSA), bilgisayar sistemlerinin insan beynindeki nöronların çalışma prensiplerini taklit ederek öğrenme ve karar verme yeteneği kazanmasını sağlayan makine öğrenmesi modelleridir. YSA, biyolojik sinir hücrelerinin işlevlerini benzer şekilde taklit eden yapay nöronlardan oluşur ve bu nöronlar katmanlar halinde düzenlenir. Bu katmanlar, girdi katmanı, gizli katmanlar ve çıktı katmanı olarak sıralanır.



Şekil 3.2 Sinir ağları (Sevindik, 2025)


Girdi katmanı, verinin ağıza giriş yaptığı ilk katmandır. Gizli katmanlar, verinin işlenmesi ve öğrenilmesi sürecinde kullanılan ara katmanlardır. Çıktı katmanı ise nihai sonucu üreten katmandır. Yapay sinir hücreleri, girdi değerlerini alır ve belirli ağırlıklarla çarpar. Toplama fonksiyonu, ağırlıklı girdileri toplar ve aktivasyon fonksiyonu aracılığıyla toplamı bir çıktı değerine dönüştürür (Ucuza, 2020).



Şekil 3.3 Yapay sinir ağı (Çakı, 2024)

Yapay sinir ağlarının öğrenme sürecinde eğitim verileri kullanılarak hatalar minimize edilir ve modelin doğruluğu artırılır. Bu süreçte iki ana yöntem kullanılır: ileri besleme (feedforward) ve geri yayılım (backpropagation). İleri besleme yönteminde, veriler girdi katmanından çıktı katmanına doğru akar. Geri yayılım yönteminde hata geri yayılım algoritması kullanılarak modelin ağırlıkları güncellenir ve hatalar azaltılır. Aktivasyon fonksiyonları, nöronların çıktıları belirlemek için kullanılır ve ağıın öğrenme yeteneğini artırır. En yaygın kullanılan aktivasyon fonksiyonları arasında sigmoid fonksiyon, ReLU (Düzeltilmiş Doğrusal Birim) ve softmax fonksiyonları yer almaktadır. Sigmoid fonksiyonu, çıkış değerlerini 0 ile 1 arasında sınırlarken, ReLU fonksiyonu negatif değerleri 0'a, pozitif değerleri ise kendisine eşitler. Softmax fonksiyonu ise çıkış değerlerini olasılık dağılımına dönüştürür. Yapay sinir ağları, görüntü tanıma, doğal dil işleme, tahmin ve sınıflandırma gibi çeşitli alanlarda etkili bir şekilde kullanılmaktadır. Özellikle nesne tanıma, yüz tanıma, metin sınıflandırma, dil çevirisi, finansal analizler ve sağlık teşhisleri gibi uygulamalarda yüksek doğruluk oranlarıyla dikkat çeker. Yapay sinir ağları, büyük veri setleri ile eğitildiğinde karmaşık problemleri çözme yeteneği kazanır ve çeşitli alanlarda önemli katkılar sağlar. Yapay sinir ağları, birbirine bağlı birçok yapay sinir hücresinden (nöron) oluşur. Bu nöronlar, katmanlar şeklinde organize edilir ve her katmandaki nöronlar, bir önceki katmandaki nöronlarla ilişkilidir. Bir yapay sinir hücresi, girdileri alır, bu girdileri ağırlıklandırır, toplar ve aktivasyon fonksiyonları ile çıktıyı hesaplar (Ucuza, 2020).


Tek Katmanlı Algılayıcı (Perceptron) yalnızca bir girdi ve bir çıktı katmanına sahip basit bir ağıdır.



Şekil 3.4 Tek katmanlı sinir ağı (Koç, 2022)


Burada Σ (Sigma (sigma)), toplayıcı fonksiyonu temsil eder. Girdiler $x_1, x_2, \dots, x_{n-1}, x_n$ ve ağırlıklar $w_1, w_2, \dots, w_{n-1}, w_n$ çarpılarak, elde edilen sonuçlar toplanır. Toplam değer, aktivasyon fonksiyonuna giriş yapar ve sonuç olarak bir çıktı y elde edilir.

Çok Katmanlı Algılayıcı (MLP- Multilayer Perceptron) bir veya daha fazla gizli katmana sahip daha karmaşık bir ağıdır.




Şekil 3.5 Çok katmanlı sinir ağı (Koç, 2022)

Evrişimsel Sinir Ağları (CNN- Convolutional Neural Networks) özellikle görüntü işleme ve bilgisayarla görme alanlarında kullanılan, evrişim katmanları içeren ağlardır.



Şekil 3.6 Evrişimsel sinir ağları (Towards Data Science Portalı)


Birden fazla evrimsel katman ve havuzlama katmanı eklendiğinde, görüntü özellik çıkarma için işlenecektir. Ve softmax (çok sınıflı bir durum için) veya sigmoid (ikili bir durum için) işlevi için katmana doğru giden tamamen bağlı katmanlar olacaktır. ReLu aktivasyon adımından bahsetmedim, ancak YSA'daki aktivasyon adımıyla hiçbir farkı yoktur. Katmanlar daha da derinleştikçe, modelin ele aldığı özellikler daha karmaşık hale gelir. Örneğin, ConvNet'in erken aşamasında, yönlendirilmiş çizgi desenlerini arar ve sonra bazı basit şekiller bulur. Derin aşamada, nesnelerin belirli formlarını yakalayabilir ve sonunda bir giriş görüntüsünün nesnesini tespit edebilir. ESA'yı anlamak, görüntü verilerinin nasıl işlendiğini anlamaktır. Görüntülerin verilere nasıl aktarılacağı ve tahmin için özelliklerin nasıl çıkarılacağı. Bu temel yapıdan, birçok değiştirilmiş ve birleştirilmiş sürüm vardır. ResNet, AlexNet, VGG-16 veya Inception Networks bunlardan bazılarıdır. Tekrarlayan Sinir Ağları (RNN- Recurrent Neural Networks) zaman serileri ve dizisel veri analizi için kullanılan, girdileri ve çıktıları arasındaki zamansal bağımlılıkları modelleyen ağlardır. Tekrarlayan sinir ağları (TSA), düğümler arasındaki bağlantıların döngüsel olduğu ve bazı düğümlerden alınan çıktının aynı düğümlere sonraki girdileri etkilemesine izin veren bir yapay sinir ağı türüdür. TSA'lar genellikle bir sonraki adımı tahmin etmek için kullanılan bir derin öğrenme yapısıdır. Diğer derin öğrenme yapılarından en önemli farkları ise hafızaya sahip olmalarıdır. TSA'larda girdiler birbiriyle bağlantılıdır. TSA'lar, bir sonraki adımı izlemek için girdiler arasında ilişki kurar ve eğitilirken bu ilişkileri hatırlarlar. Tekrarlayan sinir ağlarının (TSA) asıl amacı, önceki bilgileri kullanmaktır. Geleneksel bir sinir ağında tüm girişlerin ve çıktıların birbirinden bağımsız olduğu varsayılır. TSA'lar, her dizinin her ögesi için aynı görevi yerine getirirler ve çıktılar, önceki hesaplamalara dayanır. Bu nedenle, TSA'lar tekrarlayan olarak adlandırılır. TSA'lar, kurdukları ilişkilerin kalıcı olmasını sağlamak için döngü benzeri bir yapı kullanırlar. Bu yapı, çıktının bir sonraki adımı beslemesini sağlar (Çataloluk, 2012).



Şekil 3.7 Tekrarlanan sinir ağı yapısı (Güler, 2022)

A, şekilde bir yapay sinir ağını, xt ağı giriş vektörlerini ve ht ağı çıkış vektörlerini temsil etmektedir.


Uzun Kısa Süreli Bellek (LSTM- Long Short-Term Memory) TSA'ların (Recurrent Neural Networks) geliştirilmiş bir versiyonu olup, uzun dönemli bağımlılıkları daha etkin bir şekilde öğrenebilen yapay sinir ağı mimarisidir. Tekrarlayan Sinir Ağları (TSA) mimarileri, daha önceki bilgilerin tekrar kullanımına dayalı bir yöntem kullanır. Örneğin, “Zekânın ruhu kısa sözde yatar.” ifadesinde, “ruhu” kelimesinin tahmini dilin yapısına bağlı olarak ne çok kolay ne de çok zordur. Bir başka örnek, “Meyveli ağacı taşlarlar.” cümlesinde, “ağaç” kelimesinin “meyveli” olduğu sonucunu çıkarmak daha basittir. Ancak, bağlamlar arasındaki mesafe arttıkça, TSA'nın geçmiş bilgiyi kullanması güçleşir. Örneğin, “Gül kokusunu severim” ile “Gülmek sana çok yakışıyor.” cümlelerinde, “Gül” kelimesinin anlamını doğru tahmin edebilmek için ilk cümleyi hafızada tutmak gereklidir. Uzun Kısa Süreli Bellek (UKSB) ağları, temel olarak tekrarlayan sinir ağlarından (TSA) farklı değildir. Ancak, TSA'ların bağlam boşluklarını tahmin etmekte yaşadığı zorluklar nedeniyle, Hochreiter ve Schmidhuber tarafından 1997 yılında UKSB ağları geliştirilmiştir. UKSB'lar, gizli durumları hesaplamak için özel bir yapı kullanır. Bu hücreler hem önceki durumu hem de girdi bilgisini tutar ve hangi verinin korunacağına ya da hangi verinin silineceğine karar verir. Sonraki aşamada ise, önceki durum mevcut bellek ile giriş verisini birleştirir. Bu yöntem sayesinde, uzun vadeli bağımlılıkların etkisi ortadan kaldırılarak veri dizilerinin sürekliliği sağlanır. UKSB ağları, bu bağlamda, TSA ağlarının uzun vadeli bağımlılıkları hafızada tutma konusundaki zorluklarını aşarak, daha verimli ve etkili bir öğrenme süreci sunar. Bu özellikleri sayesinde, UKSB'ler, dil işleme, konuşma tanıma ve zaman serisi analizi gibi çeşitli alanlarda yaygın olarak kullanılmaktadır (Schmidhuber, 1997).



Şekil 3.8 Uzun kısa süreli bellek ağları yapısı (T. W. C. B. Aya Abdelsalam Ismail, 2018)

Yapay sinir ağlarının eğitimi, hata fonksiyonunu minimize eden ağırlıkları bulma sürecidir. Bu süreçte kullanılan ana teknikler şunlardır, geri yayılım (Backpropagation) algoritması, ağırlık çıkışının belirlendiği ileri besleme ve oluşan hatanın gradyanı azaltacak şekilde geri yayılarak ağırlıkların güncellendiği geri besleme aşamalarını içerir. İleri besleme aşamasında, eğitim setinin girdileri ağırlık giriş katmanına verilir. Giriş katmanı, bu girdileri alan nöronlardan oluşur ve bu nedenle giriş katmanındaki nöron sayısının veri setindeki girdi değeri sayısı ile eşit olması gerekir. Giriş katmanındaki nöronlar, girdi değerlerini doğrudan gizli katmana iletir. Gizli katmandaki her bir nöron, ağırlıklandırılmış girdi değerlerine eşik değeri ekleyerek toplam değeri hesaplar ve bunları bir aktivasyon fonksiyonu ile işleyerek bir sonraki katmana veya doğrudan çıkış katmanına iletir. Katmanlar arasındaki ağırlıklar başlangıçta genellikle rastgele seçilir. Çıkış katmanındaki her bir nöronun net girdisi, ağırlıklandırılmış girdi değerlerine eşik değerin eklenmesiyle hesaplanır. Bu net giriş değeri aktivasyon fonksiyonu ile işlenir ve çıktı değerleri belirlenir. Ağırlık ürettiği çıktı değerleri, beklenen değerlerle karşılaştırılarak hata değeri hesaplanır. Bu nedenle, çıkış katmanındaki nöron sayısının, veri setindeki çıktı sayısı ile uyumlu olması gerekmektedir (S. Haykin, 2009).

Gradyan iniş (Gradient Descent) hata fonksiyonunu minimize etmek için kullanılan optimizasyon algoritmasıdır.



Şekil 3.9 Gradyan iniş grafiği (Bozarık, 2018)


Bu noktada, maliyeti en aza indirmek amacıyla en uygun w ve b değerlerini belirlemeye çalışıyoruz. Gradyan inişi yöntemi, güçlü ve genel bir optimizasyon yöntemidir. Gradyan inişi, makine öğrenmesi alanında yaygın olarak kullanılan bir tekniktir. Çünkü makine öğrenmesinin temel hedeflerinden biri, eğitim verisi kullanılarak en yüksek doğruluğu elde etmek ya da hata oranını minimize etmektir. Bu yöntem, maliyet fonksiyonunu en aza indirerek minimum hata seviyesini bulmak amacıyla kullanılır. Bir $J(w, b)$ noktası belirleyelim; bu nokta, gradyan inişi yöntemi için başlangıç noktamız olacaktır. J 'nin değerlerini sürekli olarak azaltmak amacıyla uzayda küçük adımlar atıyoruz. Bu yöntemin temel hedefi, gradyan inişlerini kullanarak gözlenen riski yani tahmin hatasını en aza indirmektir. Her iterasyonda, gradyanlara bağlı olarak ağırlıklarda azaltmalar ve güncellemeler yapılır. J 'nin değerleri sürekli azaltmak zorundadır çünkü J 'nin değeri sıfıra yakın olmalıdır. Bu süreç sonunda, bir denge noktasına ulaşmak zorunludur. Mini-batch ve Stokastik Gradyan İniş (SGD- Stochastic Gradient Descent) veri seti küçük parçalara bölünerek gradyan inişi uygulanır, böylece daha hızlı ve etkili öğrenme sağlanır. Adaptif Optimizasyon Algoritmaları, öğrenme hızını adaptif olarak ayarlayan ve daha hızlı yakınsama sağlayan Adam ve RMSprop gibi algoritmaları içerir. Yapay sinir ağları, çeşitli alanlarda etkili bir şekilde kullanılmaktadır. Görüntü İşleme alanında, yüz tanıma, nesne tanıma ve görüntü sınıflandırma gibi uygulamalarda yaygın olarak kullanılırken, Doğal Dil İşleme (NLP) alanında duygu analizi, metin sınıflandırma, makine çevirisi ve dil modelleme gibi görevlerde önemli rol oynamaktadır. Tıp ve Sağlık alanında yapay sinir ağları; hastalık teşhisi,

medikal görüntü analizi ve genetik veri analizi gibi uygulamalarda kullanılmaktadır. Finans sektöründe ise; piyasa tahminleri, kredi skorlama ve dolandırıcılık tespiti gibi görevlerde önemli rol oynamaktadır. Otonom Sistemler alanında, yapay sinir ağları otonom araçlar, robotik ve insansız hava araçları gibi teknolojilerin geliştirilmesinde etkin bir şekilde kullanılmaktadır. Yapay sinir ağları, büyük veri setleri ve güçlü donanımlar kullanılarak eğitildiğinde, insan benzeri karar verme yeteneklerine sahip olabilir. Bu teknolojinin hızlı gelişimi, çeşitli alanlarda devrim niteliğinde yenilikler getirmekte ve insan yaşamını dönüştürmektedir (Çataloluk, 2012).

3.4.Derin Öğrenme

Derin öğrenme (Deep Learning) bir makine öğrenimi yöntemidir. Bu yöntem, çok katmanlı yapay sinir ağları (artificial neural networks, ANNs) kullanarak, girdi verilerinden bir hedef çıktıyı öğrenmeyi amaçlar. YSA, birbirlerine bağlı birçok nöron (neuron) ve bunlar arasında bağlantıları temsil eden ağırlıkları içerir. Bu ağırlıklar, veri setleri üzerinde çalışılarak, hedef çıktıyı tahmin etmek için optimize edilir. Derin öğrenme, diğer makine öğrenimi yöntemlerinden farklı olarak, girdi verilerinin özelliklerini önceden belirlemek zorunda değildir. Bunun yerine, YSA girdi verilerinin özelliklerini öğrenir ve bunları kendi katmanları arasında işler. Bu sayede, derin öğrenme yöntemi, daha karmaşık veri setlerinde daha yüksek performans gösterir (Mitchell ve diğerleri., 1990).

Derin öğrenme yöntemi, çeşitli alanlarda etkili bir şekilde kullanılmaktadır. Görüntü tanıma, resimlerdeki nesneleri tanımak ve sınıflandırmak için; ses tanıma, seslerdeki kelime ve cümleleri tanımak ve anlamlandırmak için; makine çevirisi, bir dili başka bir dile otomatik olarak çevirmek için; makine öğrenimi ise, öğrenme algoritmalarını geliştirmek için kullanılmaktadır. Derin öğrenme yöntemi, veri miktarı ve kalitesine bağlı olarak iyi sonuçlar verir. Bu nedenle, derin öğrenme yöntemi, geniş ve detaylı veri setleri ile çalışıldığında daha iyi performans gösterir (Council ve diğerleri., 2000).




Şekil 3.10 Derin öğrenme şeması (Onar, 2020)

Derin öğrenme yönteminde, bir YSA katmanları arasında verileri işler ve bu verilerin özelliklerini öğrenir. Bu katmanların sayısı, bir YSA'nın derinliğini belirler. Daha fazla katmanı olan bir YSA, daha karmaşık veri setleri ile çalışabilecektir ve daha yüksek performans gösterebilir. Ancak, daha fazla katmanı olan bir YSA, daha fazla veri ve daha uzun bir eğitim süreci gerektirir. Derin öğrenme yönteminde, YSA veri setleri üzerinde eğitilir. Bu eğitim süreci, veriler üzerinde birkaç iterasyon (döngü) yapılarak gerçekleştirilir. Her iterasyon sırasında, YSA veriler üzerinde çalışır ve ağırlık değerlerini optimize etmeye çalışır. Bu optimize edilen ağırlık değerleri, YSA'nın hedef çıktıyı tahmin etme performansını artırır (Ucuza, 2020).

Derin öğrenme yönteminde, veri setlerinin büyüklüğü ve kalitesi çok önemlidir. Daha fazla ve daha detaylı veri, YSA'nın öğrenme performansını artırır. Ayrıca, veri setlerinin çeşitliliği de önemlidir. Farklı veri setleri, YSA'nın farklı durumlarda daha iyi performans göstermesini sağlar. Derin öğrenme yöntemi, çeşitli alanlarda kullanılmaktadır ve giderek daha fazla alanda kullanılmaya başlanmıştır. Örneğin, derin öğrenme yöntemi, ses ve görüntü tanıma, makine çevirisi, makine öğrenimi gibi alanlarda kullanılmaktadır. Bu yöntem, aynı zamanda sağlık, finans ve otomotiv gibi alanlarda da kullanılmaktadır. Derin öğrenme yönteminin avantajları, veri setlerinin büyüklüğü ve kalitesine bağlı olarak değişebilir, ancak genel olarak daha yüksek performans ve daha doğru tahminler sunar (Karaküçük ve Eker, 2020).

3.5. Transfer Öğrenme


Transfer öğrenimi, bir görev için önceden eğitilmiş bir modelin, benzer bir ikinci görevde başlangıç noktası olarak kullanıldığı bir makine öğrenmesi yöntemidir. Buradaki fikir, yeni model için bir başlangıç noktası veya "aktarma" olarak kullanılabilen önceden eğitilmiş model tarafından öğrenilen bilgi ve özelliklerden yararlanarak yeni modeli sıfırdan eğitmek için gereken veri ve hesaplama miktarını azaltmaktır (Huang ve diğerleri., 2017).



Şekil 3.11 Transfer öğrenme modellerinin tarihsel gelişim sırası diyagramı (Baheti, 2021)

Transfer öğrenimi, özellikle hedef görev için etiketli veri eksikliğinin olduğu veya hedef görevin, önceden eğitilmiş modelin eğitildiği orjinal göreve benzediği durumlarda yararlı olabilir. Önceden eğitilmiş bir modeli başlangıç noktası olarak kullanarak, transfer öğrenimi, yeni bir modeli eğitmek için gereken veri miktarını ve hesaplamayı önemli ölçüde azaltabilir ve bu da onu çeşitli ortamlarda yararlı bir yaklaşım haline getirir. (Huang ve diğerleri., 2017)

Transfer Learning



Şekil 3.12 Transfer öğrenme (Gülsen, 2021)

Transfer öğrenimini kullanırken akılda tutulması gereken birkaç önemli husus vardır. Birincisi, hedef görevle yakından ilgili olmayan önceden eğitilmiş bir modelin kullanılması etkili olmayabileceğinden, önceden eğitilmiş model ile hedef görevin yeterince ilişkili olmasını sağlamaktır. Ek olarak, önceden eğitilmiş modelin aktarılabilecek katmanlarını dikkatli bir şekilde seçmek önemlidir, çünkü çok az katmanın aktarılması yeterli bilgi sağlamayabilir, çok fazla katmanın aktarılması ise fazla uydurmaya neden olabilir. Genel olarak, transfer öğrenimi, yeni bir modeli eğitmek için gereken veri ve hesaplama miktarını önemli ölçüde azaltabilen ve onu çeşitli ortamlarda etkili bir yaklaşım haline getiren güçlü bir tekniktir (Barış Koçer, 2012).

3.6.DenseNet121 Modeli


DenseNet'ler (Yoğun Konvolüsyonel Ağlar), ağdaki her katmanın sonraki tüm katmanlara ileri beslemeli bir şekilde bağlandığı konvolüsyonel sinir ağlarıdır. Her katmanın girişi, önceki tüm katmanların özellik haritalarının birleştirilmesiyle oluşur. Örneğin, L katmanlı bir ağda, 1. katman tüm önceki katmanların özellik haritalarını birleştirerek 1 girişe sahip olur ve bu birleşik özellik haritasını sonraki L- 1 katmana iletir. Bu nedenle ağda toplam $L \times (L + 1) / 2$ bağlantı bulunmaktadır. Bu yoğun bağlantı deseni, ağın geleneksel konvolüsyonel sinir ağlarına göre daha az parametre gerektirmesini sağlar, çünkü gereksiz özellik haritalarının yeniden öğrenilmesine gerek yoktur. Ayrıca, her katmanın kayıp fonksiyonundan ve orijinal giriş

sinyalinden gelen gradyanlara doğrudan erişimi olduğu için, yoğun bağlantı yapısı daha derin mimariler eğitilirken kaybolan gradyan problemini azaltır ve böylece gradyanların ve bilginin ağ boyunca akışını iyileştirir (Iandola ve diğerleri., 2014).

DenseNet, her biri doğrusal olmayan bir dönüşüm uygulayan L katmandan oluşur. Her I . katman, bir toplu normalleştirme (BN), ardından bir doğrultulmuş doğrusal birim (ReLU) ve bir konvolüsyon (Conv) içeren bileşik bir fonksiyon olan H_I 'yı uygular. Ağdaki I katmanının yoğun bağlantısı şu şekilde ifade edilebilir:

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (1)$$

Burada x_l , katmanın girişidir ve $[x_0, x_1, \dots, x_{l-1}]$ 0'dan $I - 1$ 'e kadar olan katmanların özellik haritalarının birleştirilmesidir. Yazarlar, ağlarını iki ana yapı bloğuna ayırmıştır: yoğun blok (DB) ve geçiş bloğu (TB). Yoğun blok, her biri 1×1 konvolüsyon ve 3×3 konvolüsyon katmanlarından oluşan birden çok yoğun katmandan meydana gelir. Yoğun blok, bir toplu normalleştirme katmanı, bir 1×1 konvolüsyon katmanı ve bir 2×2 ortalama havuzlama katmanı içeren geçiş blokları ile birbirine bağlanır. DenseNet121, dört yoğun blok içeren DenseNet ağına bir uygulaması olup, her yoğun blok sırasıyla 6, 12, 24 ve 16 yoğun katmandan oluşur. DenseNet121 mimarisinin bir örneği Şekil 3.20'de gösterilmiştir (Huang ve diğerleri., 2017).



Şekil 3.13 DenseNet121 mimari şeması (Amin ve diğerleri., 2022)

3.7.MobileNet Modeli


MobileNet, mobil ve gömülü sistemlerde yüksek performans sağlamak amacıyla Google tarafından geliştirilen hafif ve verimli bir evrişimli sinir ağı (CNN) mimarisidir. Bu mimari, özellikle sınırlı hesaplama kaynaklarına sahip cihazlarda kullanılmak üzere tasarlanmıştır. MobileNet'in temel özelliği, standart evrişim işlemlerine kıyasla daha az parametre ve

hesaplama gerektiren derinlik ayrılabilir evriřimler (depthwise separable convolutions) kullanmasıdır (Howard ve diğeri., 2017). Bu yöntem, modelin hem boyutunu hem de hesaplama karmařıklıđını önemli ölçüde azaltırken, görüntü sınıflandırma, nesne tanıma ve benzeri bilgisayarlı görü görevlerinde yüksek doğruluk oranları elde etmesini sağlar. MobileNet ayrıca, modelin genişliğini ve giriş çözünürlüğünü ayarlamak için width multiplier ve resolution multiplier gibi parametreler sunar, bu da modelin farklı donanım kısıtlamalarına uyarlanabilmesine olanak tanır (Howard ve diğeri., 2017).

MobileNet'in ilk versiyonu olan MobileNetV1, derinlik ayrılabilir evriřimlerin kullanımıyla dikkat çekerken, MobileNetV2 bu mimariyi daha da geliştirerek ters artık bağlantılar (inverted residuals) ve doğrusal darboğazlar (linear bottlenecks) gibi yenilikler getirmiştir (Sandler ve diğeri., 2018). Bu gelişmeler, modelin özellikle düşük hesaplama kaynaklarına sahip ortamlarda daha verimli çalışmasını sağlamıştır. MobileNetV3 ise, donanım bilgisiyle optimize edilmiş ve otomatik sinir ağı arama (neural architecture search-NAS) teknikleri kullanılarak geliştirilmiş en güncel versiyondur (Howard ve diğeri., 2019).

3.8.NASNetMobile Modeli

NASNetMobile, NASNet'in mobil ve gömülü cihazlar için optimize edilmiş hafif bir versiyonudur. Bu model, hesaplama maliyetini azaltmak amacıyla derinlik ayrımlı evriřimler kullanarak tasarlanmıştır. NASNetMobile, 1000 nesne kategorisini içeren bir milyondan fazla görüntüden oluşan ImageNet veritabanı üzerinde eğitilmiştir. Bu model, 224x224 piksel giriş boyutuna sahip görüntüleri sınıflandırarak yüksek doğruluk sağlar. Düşük kaynak tüketimi ile mobil uygulamalar için son derece uygun bir performans sergiler.



Şekil 3.14 NasNet Mobil mimarisi (Shah ve diğerleri., 2021)

NASNetMobile, bitki hastalığı sınıflandırması, nesne tespiti ve görüntü tanıma gibi çeşitli uygulamalarda kullanılmaktadır. Bu geniş kullanım alanları, modelin verimli ve etkili bir şekilde çalışmasını sağlamak için optimize edilmiş yapısının bir sonucudur. Bu nitelikler, NASNetMobile'ı mobil cihazlarda görüntü işleme görevleri için ideal bir seçim haline getirmektedir (Zoph B ve diğerleri., 2017).

3.9.Derin Öğrenmemede Optimizasyon

Derin Öğrenme Optimizasyonu, yapay sinir ağlarının eğitiminde kullanılan çeşitli algoritma ve stratejilerin bir bütünüdür. Bu teknikler, model performansını maksimize etmek ve eğitim sürecini verimli hale getirmek amacıyla geliştirilmiştir. Temel optimizasyon algoritmaları arasında Toplu Gradyan İnişi (Batch Gradient Descent), Stokastik Gradyan İnişi (Stochastic Gradient Descent-SGD), Mini-Toplu Gradyan İnişi (Mini-Batch Gradient Descent), Momentumlu Gradyan İnişi (Gradient Descent with Momentum) ve RMSprop yer almaktadır. Toplu Gradyan İnişi, tüm veri kümesini kullanarak gradyanı hesaplar ve ağırlıkları bu doğrultuda günceller. Buna karşılık, Stokastik Gradyan İnişi her bir veri noktası için ayrı ayrı gradyanı hesaplar ve her bir yineleme sonunda ağırlıkları günceller. Mini-Toplu Gradyan İnişi ise veri kümesinin küçük bir bölümünü kullanarak gradyanı hesaplar ve bu süreçte daha dengeli

bir yaklaşım sunar. Momentumlu Gradyan İnişi, önceki hızları dikkate alarak daha hızlı bir yakınsama sağlar ve RMSprop, öğrenme hızını optimize etmek için gradyanı dikey yönde kısıtlar.

Bu algoritmalar, modelin eğitim sürecini hızlandırarak daha iyi ve daha hızlı sonuçlar elde edilmesine olanak tanır. Hangi algoritmanın kullanılacağı, veri kümesinin boyutu ve özellikleri gibi faktörlere bağlı olarak değişiklik gösterebilir. Dolayısıyla, derin öğrenme modellerinin performansını optimize etmek ve etkili sonuçlar elde etmek amacıyla bu tekniklerin dikkatle seçilmesi ve uygulanması gerekmektedir (Seyyarer, E., Ayata, F., Uçkan, T., Karcı, A., 2020).

3.9.1. Parametre optimizasyonu

Derin öğrenmede parametre optimizasyonu, modelin performansını maksimize etmek ve eğitim sürecini verimli hale getirmek amacıyla kullanılan çeşitli algoritmalar ve stratejiler bütünüdür. Bu süreçte, modelin hiperparametreleri (örneğin, öğrenme oranı (learning rate), ağırlık başlatma değeri (weight initialization), batch büyüklüğü (batch size) gibi) en uygun değerlere ayarlanır. Temel parametre optimizasyon tekniklerinden biri olan Grid Search (Grid Search), belirli bir parametre aralığında sistematik olarak tüm olası kombinasyonları dener. Random Search (Random Search) ise hiperparametrelerin rastgele kombinasyonlarını deneyerek en iyi sonucu bulmaya çalışır. Bayesian Optimization (Bayesian Optimization), önceki deneyimlerden yararlanarak parametrelerin daha verimli bir şekilde optimize edilmesini sağlar. Adaptive Learning Rate (Adaptive Learning Rate) algoritmaları, öğrenme oranını dinamik olarak ayarlayarak optimizasyon sürecini hızlandırır ve Early Stopping (Early Stopping), modelin overfitting (overfitting) durumu ortaya çıktığında eğitim sürecini erken durdurarak daha iyi genelleme sağlar. Bu yöntemler, derin öğrenme modellerinin performansını optimize etmek için kritik öneme sahiptir ve dikkatlice uygulanmalıdır (Seyyarer, E., Ayata, F., Uçkan, T., Karcı, A., 2020).

3.9.2. Izgara arama (GridSearch)

Hiperparametre optimizasyonu, makine öğrenmesi modellerinin performansını artırmak için kritik bir süreçtir. Bu süreçte kullanılan yöntemlerden biri olan ızgara arama (GridSearch), belirli bir hiperparametre uzayında tüm olası kombinasyonları sistematik bir şekilde deneyerek en iyi performansı sağlayan hiperparametre setini bulmayı amaçlar. Izgara aramanın

(GridSearch) temel avantajı, tanımlanan hiperparametre uzayı içinde kapsamlı bir arama yapması ve bu uzayda en iyi kombinasyonu bulma garantisi sunmasıdır (Pedregosa ve diğerleri., 2011). Ancak, bu yöntemin önemli bir dezavantajı, hiperparametre uzayı büyüdükçe hesaplama maliyetinin katlanarak artmasıdır. Özellikle çok sayıda hiperparametre ve geniş değer aralıkları söz konusu olduğunda, ızgara arama pratik olmaktan uzaklaşabilir (Bergstra ve Bengio, 2012).

Izgara aramanın bu sınırlılıkları, alternatif hiperparametre optimizasyon yöntemlerinin geliştirilmesine yol açmıştır. Örneğin, rastgele arama (random search) yöntemi, ızgara aramaya kıyasla daha az hesaplama maliyetiyle benzer veya daha iyi sonuçlar elde edebilir. Bergstra ve Bengio (2012), rastgele aramanın özellikle yüksek boyutlu hiperparametre uzaylarında ızgara aramadan daha etkili olduğunu göstermiştir. Benzer şekilde, Bayes optimizasyonu gibi daha gelişmiş yöntemler, hiperparametre uzayında daha akıllı bir arama yaparak ızgara aramanın gereksiz hesaplama yükünü azaltır (Snoek ve diğerleri., 2012). Bu yöntemler, özellikle karmaşık modeller ve büyük veri setleri söz konusu olduğunda ızgara aramaya kıyasla daha verimli sonuçlar sunar.

Sonuç olarak, ızgara arama hiperparametre optimizasyonu için basit ve anlaşılır bir yöntem olmakla birlikte, özellikle büyük ölçekli problemlerde hesaplama maliyeti ve sınırlı arama yeteneği gibi dezavantajlara sahiptir. Bu nedenle, ızgara aramanın yanı sıra rastgele arama ve Bayes optimizasyonu gibi alternatif yöntemlerin kullanılması, hiperparametre optimizasyon sürecini daha verimli hale getirebilir (Hutter ve diğerleri., 2011). Bu yöntemler, makine öğrenmesi uygulamalarında model performansını artırmak için giderek daha yaygın bir şekilde benimsenmektedir.

4. PERFORMANS DEĞERLENDİRMESİ

Modellerin performansı; veri setinin eğitim, test ve doğrulama setlerine nasıl bölüneceğine ve veri seti boyutlarına tamamen araştırmacının kararına bağlıdır. Bu çalışmada, toplamda 6 sınıf ve 2780 ceviz meyvesi görüntüsü içeren bir veri seti kullanılmış ve model eğitimleri buna göre yapılmıştır. Farklı ve daha büyük veri setleri ile alternatif veri seti bölme yöntemleri kullanılarak, karşılaştırmalı sonuçlar elde edilebilir.

Sınıflandırma yöntemleri için gerek duyulan yeni bir model yapma veya mevcut model kullanma sonucunda o model ile olumlu sonuç elde edilmesi, doğru olan tahminleme rakamına göre hesaplanır. Bu durum, modelin iyi bir model olup olmadığını tahmin etmekten daha fazla olarak, sınıflandırmanın doğru olup olmadığı konusunda ön plana çıkmaktadır. Bundan sebepten ötürü, sınıflandırmanın tahminleri değerlendirmelerini ortaya koyabilmek için karışıklık matrisinden yararlanılır. Test verisi kullanılarak bir sınıflandırma modeli yardımıyla bulunan tahmini sınıflar ve gerçek sınıflar ile ilgili bilgi içeren matris, karışıklık matrisidir (Çataloluk, 2012).

Karışıklık matrisinde dört parametre bulunmaktadır. Bu parametreler şu şekilde adlandırılır: DP (doğru pozitifler), YP (yanlış pozitifler), YN (yanlış negatifler) ve DN (doğru negatifler). Pozitif sınıfa doğru şekilde sınıflandırılan örneklere gerçek pozitifler denir. Negatif sınıfa doğru şekilde sınıflandırılan örneklere gerçek negatifler denir. "Pozitif sınıf örneklerinin hatalı bir şekilde negatif olarak sınıflandırılmasına yanlış negatif denir. Benzer şekilde, negatif sınıf örneklerinin hatalı bir şekilde pozitif olarak sınıflandırılmasına da yanlış pozitif denir (Ruuska ve diğerleri., 2018).

4.1.Hesaplama Formülleri

Tez çalışmasında gerçekleştirilen analizlerin performansını değerlendirmek amacıyla doğruluk, duyarlılık, özgüllük, kesinlik ve F1 skoru gibi ölçütler kullanılmıştır. Bu ölçütlerin teorik temelleri aşağıda kısaca sunulmuştur.

Doğruluk (accuracy) terimi, bir tahmin veya ölçümün gerçek değere ne kadar yakın olduğunu ifade eden istatistiksel bir ölçüttür.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

Duyarlılık (sensitivity), bir sınıflandırma modelinin pozitif sınıftaki örnekleri doğru şekilde sınıflandırma yeteneğini ölçen bir ölçüttür. Duyarlılık, gerçek pozitif oranı olarak da adlandırılır.

$$Duyarlılık = \frac{DP}{DP+YN} \quad (2)$$

Özgüllük (specificity), bir sınıflandırma modelinin negatif sınıftaki örnekleri doğru şekilde sınıflandırma yeteneğini ölçen bir ölçüttür. Özgüllük, gerçek negatif oranı olarak da adlandırılır.

$$Özgüllük = \frac{DN}{DN+YP} \quad (3)$$

Kesinlik (precision), bir sınıflandırma modelinin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Kesinlik, pozitif olarak tahmin edilen örneklerin gerçek pozitif örnekler içindeki oranını belirtir.

$$Kesinlik = \frac{DP}{DP+YP} \quad (4)$$

F1-Skoru, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir ölçüttür. F1-Skoru, doğruluk (accuracy), kesinlik (precision) ve geri çağırma (recall) gibi diğer sınıflandırma metriklerine göre daha dengeli bir performans ölçüsüdür (Powers, 2011).

$$F1-Skoru = \frac{2DP}{2DP+YN+YP} \quad (5)$$

Negatif Tahmini Değer (negative predictive value), tıp ve istatistikte kullanılan bir terimdir ve bir testin veya modelin negatif sonuç vermesi durumunda, gerçekte negatif olan sonuçların oranını ifade eder (Singh ve diğerleri., 2022). Aşağıda gerçekte negatif olan sonuçların oranını hesaplama formülü verilmiştir.

$$Negatif Tahmini Değer = \frac{DN}{DN+YP} \quad (6)$$

Yanlış Pozitif Oranı (false positive rate), bir sınıflandırma modelinin özellikle negatif sınıftaki örnekleri yanlışlıkla pozitif olarak sınıflandırma sıklığını ifade eder. Aşağıda Yanlış Pozitif Oranı hesaplama formülü verilmiştir.

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{DP + YP} \quad (7)$$

Yanlış Negatif Oranı (false negative rate), bir sınıflandırma modelinin özellikle pozitif sınıftaki örnekleri yanlışlıkla negatif olarak sınıflandırma sıklığını ifade eder (Singh ve diğerleri., 2022). Aşağıda Yanlış Negatif Oranı hesaplama formülü verilmiştir.

$$\text{Yanlış Negatif Oranı} = \frac{YN}{DP + YN} \quad (8)$$

5. DENEYSEL SONUÇLAR

Uygulamalar, Google Colab platformunda gerçekleştirilmiş ve Python programlama dili kullanılmıştır. Kullanılan bilgisayar, NVIDIA T4 grafik işlemcisi ve 16 GB RAM'e sahiptir. Tez çalışmasında ön eğitilmiş derin öğrenme modellerinden DenseNet121, NasNetMobile, MobileNet kullanılmıştır. Başarı oranlarını arttırmak için ızgara arama (GridSearch) yöntemi ile parametreler değiştirilip tekrar sınıflandırılmıştır.

Çizelge 5.1 Sınıflandırmada elde edilen başarı sayıları

Kullanılan Model	Doğruluk (Val-Accuracy)	Doğruluk (Training Validation)	Kesinlik (Precision)	Geri Çağırma (Recall)	f1 skoru
DenseNet121	%80,25	%81,06	0,85	0,79	0,79
NASNetMobile	%65,53	%68,42	0,73	0,63	0,62
MobileNet	%83,66	%85,74	0,87	0,82	0,83

Çizelge 5.1' de ön eğitilmiş derin öğrenme modellerinden DenseNet121, NasNetMobile, MobileNet ile elde edilen başarı oranları görülmektedir.

Çizelge 5.2 Parametre optimizasyonu yapılarak elde edilen sınıflandırma başarı sayıları

Kullanılan Model	Doğruluk (Val-Accuracy)	Doğruluk (Training Validation)	Kesinlik (Precision)	Geri Çağırma (Recall)	f1 skoru
DenseNet121	%90,66	%75,21	0,92	0,90	0,91
NASNetMobile	%87,61	%77,64	0,88	0,88	0,88
MobileNet	%92,46	%84,93	0,93	0,92	0,92

Çizelge 5.2' de ön eğitilmiş derin öğrenme modellerinden DenseNet121, NasNetMobile, MobileNet modellerine parametre optimizasyonu uygulandıktan sonra elde edilen başarı oranları görülmektedir.

Modellerin başarıları, veri setinin eğitim, test ve doğrulama aşamalarına ayrılma biçimi ve her bir bölümde bulunan veri miktarı, araştırmayı gerçekleştiren çalışmacıya bağlı olarak değişkenlik gösterebilmektedir. Tezin uygulama aşamasında, 6 ceviz çeşidinden toplam 2780

görüntü kullanılarak veri seti oluşturulmuştur. Bunların 2223 tanesi eğitim ve 557 tanesi doğrulama işlemleri için ayrılmıştır.

5.1. DenseNet121 Modeli

DenseNet121 modeli kullanılarak gerçekleştirilen çalışmada, eğitim doğruluğu %81,06, doğrulama doğruluğu ise %80,25 olarak elde edilmiştir. Bu sonuçlar, modelin eğitim verisi üzerinde yüksek bir performans gösterdiğini ve doğrulama aşamasında bu performansını daha da artırdığını göstermektedir. Eğitim doğruluğunun %81,06 olması, modelin eğitim sürecinde veri setini iyi bir şekilde öğrendiğini, doğrulama doğruluğunun %80,25 olması ise modelin yeni ve görülmemiş veriler üzerinde etkili sonuçlar elde edebildiğini ortaya koymaktadır. Modelin doğrulama doğruluğunun eğitim doğruluğundan yüksek olması, genelleme yeteneğinin güçlü olduğunu ve gerçek dünya verileri üzerinde başarılı performans sergileyebileceğini işaret etmektedir. Bu bağlamda, DenseNet121 modeli, kullanılan veri seti ve eğitim yöntemleriyle güvenilir ve verimli bir sınıflandırma performansı sergilemiştir. Bu modelde parti boyutu (batch size) 16, öğrenme oranı (learning rate) 0,0001 ve optimizör olarak SGD seçilmiştir.


Çizelge 5.3 DenseNet121 doğrulama değerleri

Ceviz Türü	Kesinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,99	0,82	0,89	82
Fernor	0,86	0,87	0,86	92
Hekimhan	0,88	0,69	0,77	97
Kaman-1	1,00	0,47	0,64	85
Maraş-18	0,58	0,91	0,71	79
Oğuzlar-77	0,78	0,99	0,87	122
Doğruluk			0,80	557
Makro Ortalama	0,85	0,79	0,79	557
Ağırlıklı Ortalama	0,85	0,80	0,80	557

Alınan sonuçlara göre, Chandler sınıfı için kesinlik değeri 0,99, geri çağırma değeri 0,82 ve F1-skoru 0,89 olarak elde edilmiştir. Fernor sınıfı için kesinlik değeri 0,86, geri çağırma değeri 0,87 ve F1-skoru 0,86 olarak bulunmuştur. Hekimhan sınıfı için kesinlik değeri 0,88, geri


çağırma değeri 0,69 ve F1-skoru 0,77 olarak belirlenmiştir. Kaman-1 sınıfı için kesinlik değeri 1,00 geri çağırma değeri 0,47 ve F1-skoru 0,64 olarak tespit edilmiştir. Maraş-18 sınıfı için kesinlik değeri 0,58, geri çağırma değeri 0,91 ve F1-skoru 0,71 olarak elde edilmiştir. Oğuzlar-77 sınıfı için ise kesinlik değeri 0,78, geri çağırma değeri 0,99 ve F1-skoru 0,87 olarak bulunmuştur.

Test veri seti için tüm çeşitlerin genel sınıflandırma doğruluk oranı DenseNet121 modeline göre %80 olarak bulunmuştur.




Şekil 5.1 DenseNet121 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.1’de ceviz türlerinin sınıflandırılması için model eğitimi sırasında DenseNet121 modelinin eğitim ve doğrulama grafiği.



Şekil 5.2 DenseNet121 50 devir (epoch) doğrulama kaybı eğrileri grafiği

Şekil 5.2’de ceviz türleri sınıflandırması için model eğitimi sırasında DenseNet121 modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.3 DenseNet121 karışıklık matrisi

Şekil 5.3’te verilen karışıklık matrisi, birleşim modelinin özeti özetlemektedir. Model, Chandler, Fernor, Hekimhan, Kaman-1, Maraş-18 ve Oğuzlar-77 adlı sınıflar arasında yer alıyor. Yatay eksen modellemenin tahmin ettiği sınıfları, dikey eksen ise gerçek sınıfları temsil

etmektedir. Matris üzerindeki değerler, tahmin edilen ve gerçek sınıflar arasındaki örnek sayıları göstermektedir. Genel doğruluk, diyagonal elemanlar (ör. Fernor için 80, Oğuzlar-77 için 121), doğru sınıflandırılan örneklerin sayısını temsil eder. Bu değerlerin yüksek olması modelin genel olarak doğru çalıştığını göstermektedir. Şekil 5.3 incelendiğinde ceviz çeşitleri arasında DenseNet121'in Kaman-1 çeşidi cevizi sınıflandırmada daha az başarılı olduğu görülmektedir. Oğuzlar-77 çeşidi cevizi sınıflandırma performansının daha yüksek olduğu görülmektedir.

5.2.NASNetMobile Modeli

NASNetMobile modeli, derinlik ayrımlı evrişimler kullanarak mobil ve gömülü cihazlar için optimize edilmiş hafif bir konvolüsyonel sinir ağıdır. Bu model, bir milyondan fazla görüntüden oluşan ve 1000 nesne kategorisi içeren ImageNet veri seti üzerinde eğitilmiştir. Eğitim aşamasında %68,42 eğitimin ortaya çıkması ve %65,53 sağlıklı bir şekilde devam ediyor, modelin makul düzeyde bir öğrenme durumuna sahip olduğu ancak genelleme yeteneğinin sınırlı olabileceğini gösteriyor. Eğitim ve çalıştırmayı durdurma arasındaki farkın görece düşük olması (%2,89), modelin aşırı (aşırı uyum) desteklemediğini göstermekle birlikte, hızda doğruluğun azalmasının düşük kalması modelin test verisi üzerinde daha yüksek performans sergilemesi için mevcutlara ihtiyaç duyulduğunu gösteriyor. Bu bağlamda, modelin takviyesini artırmak amacıyla veriyi artırmak (veri artırma) tekniklerinin, daha düzenli ve veri setleriyle yeniden eğitim yapılması, hiperparametre takviyesi ve ince ayar (ince ayar) yöntemlerinin kullanılması önerilebilir. Ayrıca, farklı düzenleme (düzenleme) yöntemleri ve analizlerinin değerlendirilmesi, modelin genelleme kabiliyetini artırarak dayanıklılığın kalıcılığına katkı sağlayabilir. Bu modelde parti boyutu (batch size) 16, bırakma oranı (dropout rate) 0 öğrenme oranı (learning rate) 0,0001 ve optimizör olarak SGD seçilmiştir.


NASNetMobile, bitki hastalığı sınıflandırması, nesne tespiti ve görüntü tanıma gibi çeşitli uygulamalarda kullanılmıştır. Modelin düşük kaynak tüketimi ile yüksek doğruluk sağlaması, mobil cihazlarda görüntü işleme görevleri için ideal bir seçim olmasını sağlamaktadır. Bu özellikler, NASNetMobile'ı verimli ve etkili bir şekilde çalışmasını sağlamak için optimize edilmiş yapısının bir sonucudur.

Çizelge 5.4 NASNetMobile doğrulama değerleri

Ceviz Türü	Kesinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,65	0,94	0,77	82
Fernor	0,77	0,61	0,68	92
Hekimhan	0,63	0,68	0,65	97
Kaman-1	0,89	0,28	0,43	85
Maraş-18	0,85	0,37	0,51	79
Oğuzlar-77	0,57	0,93	0,70	122
Doğruluk			0,66	557
Makro Ortalama	0,73	0,63	0,62	557
Ağırlıklı Ortalama	0,71	0,66	0,63	557


Chandler çeşidi için doğruluk oranları şu şekildedir: kesinlik oranı 0,65, geri çağırma oranı 0,94, f1-skoru 0,77 ve destek 82. Fernor çeşidi için bu değerler sırasıyla kesinlik oranı 0,77, geri çağırma oranı 0,61, f1-skoru 0,68 ve destek 92 olarak belirtilmiştir. Hekimhan çeşidi için kesinlik oranı 0,63, geri çağırma oranı 0,68, f1-skoru 0,65 ve destek 97 olarak tespit edilmiştir. Kaman-1 çeşidinin doğruluk oranları, kesinlik oranı 0,89, geri çağırma oranı 0,28, f1-skoru 0,43 ve destek 85 olarak belirlenmiştir. Maraş-18 çeşidinin değerleri ise kesinlik oranı 0,85, geri çağırma oranı 0,37, f1-skoru 0,51 ve destek 79 şeklindedir. Oğuzlar-77 çeşidinin doğruluk oranları, kesinlik oranı 0,57, geri çağırma oranı 0,93, f1-skoru 0,70 ve destek 122 olarak hesaplanmıştır.

Genel doğruluk oranı %66'tır ve toplamda 557 veri desteklenmiştir. Makro ortalama değerler, kesinlik oranı 0,73, geri çağırma oranı 0,63 ve f1-skoru 0,62 olarak belirlenmiştir. Ağırlıklı ortalama değerler ise kesinlik oranı 0,71, geri çağırma oranı 0,66 ve f1-skoru 0,63 şeklindedir. Bu değerler, modelin genel performansının ortalama düzeyde olduğunu ve farklı sınıflar arasında dengeli bir doğruluk sağladığını göstermektedir.




Şekil 5.4 NASNetMobile 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.4'te ceviz türlerinin sınıflandırılması için model eğitimi sırasında NASNetMobile modelinin eğitim ve doğrulama grafiği.



Şekil 5.5 NASNetMobile 50 devir (epoch) doğrulama kaybı eğrileri grafiği

Şekil 5.5'te ceviz türleri sınıflandırması için model eğitimi sırasında NASNetMobile modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.6 NASNetMobile karışıklık matrisi

Karışıklık matrisi, sınıflandırma modellerinin performansını değerlendirmede kullanılan kritik bir araçtır. Matris, modelin doğru ve yanlış sınıflandırmalarını detaylandırarak, gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi ortaya koyar. Satırlar, gerçek sınıfları, sütunlar ise tahmin edilen sınıfları temsil eder. Her hücre, belirli bir gerçek sınıfın belirli bir tahmin edilen sınıfa kaç kez atandığını gösterir.

Bu bağlamda, Chandler sınıfının 77 kez doğru tahmin edilmesi ve 5 örneğin Fernor olarak yanlış sınıflandırılması modelin bu sınıfta genel olarak iyi performans gösterdiğini gösterir. Benzer şekilde, Fernor sınıfının 56 kez doğru tahmin edilmesi, ancak bazı örneklerin başka sınıflara yanlış sınıflandırılması, modelin bu sınıftaki performansının incelenmesi gerektiğini ortaya koyar. Hekimhan sınıfında 66 doğru tahmin bulunmakta ve diğer sınıflarla karışıklıklar gözlenmektedir. Kaman-1 ve Maraş-18 sınıflarında sırasıyla 24 ve 29 doğru tahmin yapılmış, bu sınıflarda da hatalar bulunmaktadır. Oğuzlar-77 sınıfı ise 113 kez doğru tahmin edilmiş, fakat bazı örnekler yine yanlış sınıflandırılmıştır. Bu karışıklık matrisi, modelin güçlü ve zayıf yönlerini belirlemekte ve iyileştirme stratejileri oluşturmada önemli bir rol oynar. Analiz, yanlış sınıflandırmaların sayısı ve dağılımının dikkate alınmasını gerektirir ve bu bilgiler, model performansını artırmak için gelecekteki çalışmaların temelini oluşturur.

5.3.MobileNet Modeli

Bu modelin eğitim doğruluğu %85,74 ve doğrulama doğruluğu %83,66 olarak belirlenmiştir. Bu değerler, modelin eğitim verisi üzerinde yüksek bir performans sergilediğini, ancak doğrulama verisi üzerinde biraz daha düşük bir doğruluk oranına sahip olduğunu göstermektedir.


Sonuç olarak, MobileNet modelimiz eğitim verisinde %85,74 doğrulukla tahmin yaparken, görmediği verilerde %83,66 doğrulukla tahmin yapabiliyor. Bu, modelin iyi bir genelleme performansına sahip olduğunu gösterir.

Çizelge 5.5 MobileNet doğrulama değerleri

Ceviz Türü	Kesinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,84	0,99	0,91	82
Fernor	1,00	0,72	0,84	92
Hekimhan	0,79	0,97	0,87	97
Kaman-1	0,93	0,64	0,76	85
Maraş-18	0,91	0,62	0,74	79
Oğuzlar-77	0,74	1,00	0,85	122
Doğruluk			0,84	557
Makro Ortalama	0,87	0,82	0,83	557
Ağırlıklı Ortalama	0,86	0,84	0,83	557


Chandler çeşidi için doğruluk oranları şu şekildedir: kesinlik oranı 0,84, geri çağırma oranı 0,99, f1-skoru 0,91 ve destek 82. Fernor çeşidi için bu değerler sırasıyla kesinlik oranı 1,00, geri çağırma oranı 0,72, f1-skoru 0,84 ve destek 92 olarak belirtilmiştir. Hekimhan çeşidi için kesinlik oranı 0,79, geri çağırma oranı 0,97, f1-skoru 0,87 ve destek 97 olarak tespit edilmiştir. Kaman-1 çeşidinin doğruluk oranları, kesinlik oranı 0,93, geri çağırma oranı 0,64, f1-skoru 0,76 ve destek 85 olarak belirlenmiştir. Maraş-18 çeşidinin değerleri ise kesinlik oranı 0,91, geri çağırma oranı 0,62, f1-skoru 0,74 ve destek 79 şeklindedir. Oğuzlar-77 çeşidinin doğruluk oranları, kesinlik oranı 0,74, geri çağırma oranı 1,00, f1-skoru 0,85 ve destek 122 olarak hesaplanmıştır.

Genel doğruluk oranı %84'tür ve toplamda 557 veri desteklenmiştir. Makro ortalama değerler, kesinlik oranı 0,87, geri çağırma oranı 0,82 ve f1-skoru 0,83 olarak belirlenmiştir. Ağırlıklı ortalama değerler ise kesinlik oranı 0,86, geri çağırma oranı 0,84 ve f1-skoru 0,83 şeklindedir. Bu verilere göre MobileNet modeli, bazı ceviz türlerinde yüksek performans gösterirken (örneğin Chandler ve Oğuzlar-77), bazı türlerde ise geri çağırma açısından düşük performans göstermektedir (örneğin Kaman-1 ve Maraş-18).




Şekil 5.7 MobileNet 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.7'de ceviz türlerinin sınıflandırılması için model eğitimi sırasında MobileNet modelinin eğitim ve doğrulama grafiği görülmektedir.



Şekil 5.8 MobileNet 50 devir (epoch) doğrulama kaybı eğrileri grafiği

Şekil 5.8’de ceviz türleri sınıflandırması için model eğitimi sırasında MobileNet modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.9 MobileNet karışıklık matrisi

Matrisin satırları gerçek sınıfları, sütunları ise tahmin edilen sınıfları temsil eder. Her hücre, belirli bir gerçek sınıfın belirli bir tahmin edilen sınıfa kaç kez atandığını gösterir. Matrisin her

bir hücresi, modelin belirli bir gerçek sınıfı belirli bir tahmin edilen sınıf olarak kaç kez sınıflandırdığını gösterir. Örneğin, Chandler sınıfı için model 81 doğru tahmin yapmış, 1 kez Oğuzlar-77 olarak yanlış tahmin etmiştir. Fernor sınıfı için model 66 doğru tahmin yapmış, 2 kez Chandler, 3 kez Hekimhan, 3 kez Kaman-1 ve 15 kez Oğuzlar-77 olarak yanlış tahmin etmiştir. Hekimhan sınıfı için model 94 doğru tahmin yapmış, 2 kez Chandler, 1 kez Maraş-18 olarak yanlış tahmin etmiştir. Kaman-1 sınıfı için model 54 doğru tahmin yapmış, 4 kez Hekimhan, 26 kez Oğuzlar-77 olarak yanlış tahmin etmiştir. Maraş-18 sınıfı için model 49 doğru tahmin yapmış, 10 kez Chandler, 18 kez Hekimhan, 1 kez Kaman-1 ve 1 kez Oğuzlar-77 olarak yanlış tahmin etmiştir. Oğuzlar-77 sınıfı için model 122 doğru tahmin yapmış, 0 kez yanlış tahmin etmiştir.

Bu karışıklık matrisi, modelin hangi sınıflarda daha başarılı olduğunu ve hangi sınıflarda daha fazla hata yaptığını belirlemek için kullanışlıdır. Örneğin, model Oğuzlar-77 sınıfında oldukça başarılı iken, Maraş-18 sınıfında daha fazla hata yapmaktadır. Bu tür analizler, modelin iyileştirilmesi gereken alanları belirlemek için önemlidir.

5.4.Parametre Optimizasyonu Yapılmış NASNetMobile Modeli

Bu tez çalışmasında NASNetMobile ile sınıflandırma yaptıktan sonra elde edilen sonuçların başarısını arttırmak için parametre optimizasyonu yapılmıştır. Optimizasyon yapılırken ızgara arama (GridSearch) yöntemi ile parametreler değiştirilip tekrar sınıflandırılmıştır. Parti boyutu (batch size) 64, öğrenme oranı (learning rate) 0,0001 ve optimizör olarak RMSprop alınmıştır.

Eğitim doğruluğu %77,64 değerine çıkmıştır. Bu sonuç, modelin eğitim verileri üzerinde oldukça başarılı bir şekilde öğrenim gerçekleştirdiğini göstermektedir. Bununla birlikte, doğrulama doğruluğunun %87,61 olması, modelin daha önce görmediği veriler üzerinde de güçlü bir performans sergilediğini ortaya koymaktadır.

Eğitim ve doğrulama doğruluğu arasındaki fark, modelin hafif bir şekilde aşırı uyum (overfitting) yapmış olabileceğini işaret etmektedir. Bu durum, modelin eğitim verileri üzerindeki performansının doğrulama verileri üzerindeki performansından daha yüksek olmasına sebep olmuştur. Ancak, bu farkın makul seviyelerde olması, modelin genelleme kabiliyetinin iyi olduğunu göstermektedir.


Özetle, NASNetMobile modelinin parametre optimizasyonu sonucunda elde edilen yüksek eğitim ve doğrulama doğruluğu, modelin hem eğitim verileri hem de doğrulama verileri üzerinde etkili bir performans sergilediğini ve genelleme kabiliyetinin yüksek olduğunu göstermektedir.

Çizelge 5.6 NASNetMobile modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri

Ceviz Türü	Keskinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,98	0,96	0,97	82
Fernor	0,87	0,87	0,87	92
Hekimhan	0,88	0,79	0,83	97
Kaman-1	0,99	0,82	0,90	85
Maraş-18	0,72	0,90	0,80	79
Oğuzlar-77	0,87	0,91	0,89	122
Doğruluk			0,88	557
Makro Ortalama	0,88	0,88	0,88	557
Ağırlıklı Ortalama	0,88	0,88	0,88	557


Çizelge 5.6' da verilen sonuçlara göre; çeşitli sınıflar için "precision" (keskinlik), "recall" (geri çağırma), "f1-score" ve "support" (destek) değerlerini göstermektedir. Chandler sınıfı için keskinlik 0,98, geri çağırma 0,96, f1-skoru 0,97 ve destek 82 olarak belirtilmiştir. Fernor sınıfında ise keskinlik 0,87, geri çağırma 0,87, f1-skoru 0,87 ve destek 92'dir. Hekimhan sınıfı için keskinlik 0,88, geri çağırma 0,79, f1-skoru 0,83 ve destek 97 olarak belirtilmiştir. Kaman-1 sınıfında keskinlik 0,99, geri çağırma 0,82, f1-skoru 0,90 ve destek 85'tir. Maraş-18 sınıfı için keskinlik 0,72, geri çağırma 0,90, f1-skoru 0,80 ve destek 79 olarak raporlanmıştır. Son olarak Oğuzlar-77 sınıfında keskinlik 0,87, geri çağırma 0,91, f1-skoru 0,89 ve destek 122'dir.

Genel doğruluk oranı %88 olarak hesaplanmıştır. Makro ortalama değerleri keskinlik için 0,88, geri çağırma için 0,88, f1-skoru için 0,88 ve destek için 557 olarak belirtilmiştir. Ağırlıklı ortalama değerleri ise keskinlik için 0,88, geri çağırma için 0,88, f1-skoru için 0,88 ve destek için 557 olarak hesaplanmıştır.




Şekil 5.10 Parametre optimizasyonu ile elde edilmiş NASNetMobile 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.10'da ceviz türlerinin sınıflandırılması için model eğitimi sırasında parametre optimizasyonlu NASNetMobile modelinin eğitim ve doğrulama grafiği görülmektedir.



Şekil 5.11 Parametre optimizasyonu ile elde edilmiş NASNetMobile 50 devir (epoch) doğrulama kaybı eğrileri grafiği

Şekil 5.11’de ceviz türleri sınıflandırması için model eğitimi sırasında parametre optimizasyonlu NASNetMobile modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.12 Karışıklık matris kullanımı parametre optimizasyonlu NASNetMobile

Parametre optimizasyonu uygulanmış NasNetMobile modelinin performansı, karışıklık matrisi yardımıyla detaylandırılmıştır. Bu matris, modelin çeşitli sınıflar için doğru ve yanlış tahminlerini göstermektedir. Chandler sınıfında model, 79 doğru tahmin yanında 3 kez Fernor yanlış tahmin yapmıştır. Fernor sınıfında model, 80 doğru tahminin yanında 1 kez Chandler 2 kez Hekimhan 7 kez Maraş-18 2 kez Oğuzlar-77 sınıflarına yanlış tahmin yapmıştır. Hekimhan sınıfında model, 77 doğru tahmin yaparken 2 kez Fernor 16 kez Maraş-18 2 kez Oğuzlar-77 sınıfına yanlış tahmin yapmıştır. Kaman-1 sınıfında model, 70 doğru tahmin yanında 3 kez Fernor 12 kez Oğuzlar-77 sınıfına yanlış tahminde bulunmuştur. Maraş-18 sınıfında model, 71 doğru tahmin yaparken 1 kez Chandler, 7 kez Hekimhan sınıflarına yanlış tahmin yapmıştır. Oğuzlar-77 sınıfında model, 111 doğru tahmin yapmış ve 4 kez Fernor 2 kez Hekimhan 1 kez Kaman-1 4 kez Maraş-18 sınıfına yanlış tahminde bulunmuştur.

Bu karışıklık matrisi sonuçları, modelin bazı sınıflarda yüksek bir doğruluk oranı sağladığını, ancak bazı sınıflarda belirli düzeyde hatalar yaptığını göstermektedir. Bu analizler, modelin

hangi sınıflarda iyileştirilmesi gerektiğini belirlemekte ve modelin genel performansını artırmak için önemli bilgiler sunmaktadır.

Bu bağlamda, modelin parametre optimizasyonu sonucunda elde edilen karışıklık matrisi, modelin sınıflandırma yetkinliğini değerlendirmek için kritik bir araçtır.

5.5.Parametre Optimizasyonu Yapılmış DenseNet121 Modeli

Bu tez çalışmasında DenseNet121 ile sınıflandırma yaptıktan sonra elde edilen sonuçların başarısını arttırmak için parametre optimizasyonu yapılmıştır. Optimizasyon yapılırken ızgara arama (GridSearch) yöntemi ile parametreler değiştirilip tekrar sınıflandırılmıştır. Parti boyutu (batch size) 64, dropout 0,6, öğrenme oranı (learning rate) 0,0001 ve optimizier olarak adam alınmıştır.

Elde edilen sonuçlara göre, DenseNet121 modelinin eğitim ve doğrulama aşamalarında farklı doğruluk değerleri gözlemlenmiştir. Modelin eğitim doğruluğu %75,21 iken, doğrulama doğruluğu %90,66 olarak ölçülmüştür. Bu durum, modelin eğitim veri kümesi üzerinde nispeten daha düşük bir performans sergilediğini, ancak doğrulama veri kümesinde daha yüksek bir genelleme yeteneği gösterdiğini işaret etmektedir.


Bu tür bir davranış, modelin eğitim sırasında aşırı öğrenme (overfitting) sorunu yaşamadığını, hatta tam tersine, eğitim verilerine yeterince iyi uyum sağlayamadığını (underfitting) düşündürmektedir. Doğrulama doğruluğunun eğitim doğruluğundan daha yüksek olması, modelin eğitim verilerindeki belirli örüntülere aşırı odaklanmak yerine, daha genel ve transfer edilebilir özellikler öğrendiğini göstermektedir. Bu durum, özellikle modelin daha önce görmediği verilere karşı daha iyi performans sergileme potansiyeline sahip olduğunu ifade etmektedir.

Çizelge 5.7 DenseNet121 modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri

Ceviz Türü	Keskinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,99	0,99	0,99	82
Fernor	1,00	0,85	0,92	92
Hekimhan	0,91	0,86	0,88	97
Kaman-1	1,00	0,81	0,90	85
Maraş-18	0,72	0,92	0,81	79
Oğuzlar-77	0,89	0,99	0,94	122
Doğruluk			0,91	557
Makro Ortalama	0,92	0,90	0,91	557
Ağırlıklı Ortalama	0,92	0,91	0,91	557


Çizelge 5.7’ de verilen sonuçlara göre; çeşitli sınıflar için "precision" (keskinlik), "recall" (geri çağırma), "f1-score" ve "support" (destek) değerlerini göstermektedir. Chandler sınıfı için keskinlik 0,99, geri çağırma 0,99, f1-skoru 0,99 ve destek 82 olarak belirtilmiştir. Fernor sınıfında ise keskinlik 1,00, geri çağırma 0,85, f1-skoru 0,92 ve destek 92’dir. Hekimhan sınıfı için keskinlik 0,91, geri çağırma 0,86, f1-skoru 0,88 ve destek 97 olarak belirtilmiştir. Kaman-1 sınıfında keskinlik 1,00, geri çağırma 0,81, f1-skoru 0,90 ve destek 85’tir. Maraş-18 sınıfı için keskinlik 0,72, geri çağırma 0,92, f1-skoru 0,81 ve destek 79 olarak raporlanmıştır. Son olarak Oğuzlar-77 sınıfında keskinlik 0,89, geri çağırma 0,99, f1-skoru 0,94 ve destek 122’dir.

Genel doğruluk oranı %91 olarak hesaplanmıştır. Makro ortalama değerleri keskinlik için 0,92, geri çağırma için 0,90, f1-skoru için 0,91 ve destek için 557 olarak belirtilmiştir. Ağırlıklı ortalama değerleri ise keskinlik için 0,92, geri çağırma için 0,91, f1-skoru için 0,91 ve destek için 557 olarak hesaplanmıştır.




Şekil 5.13 Parametre optimizasyonu ile elde edilmiş DenseNet121 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.13'te ceviz türlerinin sınıflandırılması için model eğitimi sırasında parametre optimizasyonlu DenseNet121 modelinin eğitim ve doğrulama grafiği görülmektedir.



Şekil 5.14 Parametre optimizasyonu ile elde edilmiş DenseNet121 50 devir (epoch) doğrulama kaybı eğrileri grafiği

Şekil 5.14'te ceviz türleri sınıflandırması için model eğitimi sırasında parametre optimizasyonlu DenseNet121 modelinin eğitim ve doğrulama kaybı görülmektedir.



Şekil 5.15 Karışıklık matris kullanımı parametre optimizasyonlu DenseNet121 modeli

Matriste diyagonal elemanlar, her bir sınıfı doğru bir şekilde tahmin ettiği örnek sayısını ifade etmektedir. Buna göre, DenseNet121 modeli "Chandler" (81), "Fernor" (78), "Hekimhan" (83), "Kaman-1" (69), "Maraş-18" (73) ve "Oğuzlar-77" (121) sınıflarında yüksek başarı göstermektedir. Bununla birlikte, "Fernor" sınıfındaki örneklerin 13 tanesinin yanlışlıkla "Maraş-18" olarak tahmin edilmesi ve "Kaman-1" sınıfındaki 14 örneğin "Oğuzlar-77" olarak sınıflandırılması, modelin bazı sınıflarda karışıklık yaşadığını göstermektedir. Özellikle "Hekimhan" sınıfındaki 13 örneğin "Maraş-18" olarak yanlış tahmin edilmesi de dikkat çekicidir. Genel olarak, modelin belirli sınıflarda yüksek doğruluk oranına sahip olduğu ancak bazı sınıflar arasında ayrım yapmada zorlandığı söylenebilir. Bu durum, veri kümesindeki sınıflar arasındaki benzerliklerden veya modelin eğitiminde kullanılan özelliklerin ayrıştırıcı gücünün sınırlı olmasından kaynaklanabilir. Modelin performansını artırmak için ek özellik mühendisliği veya modelin hiperparametre optimizasyonu gibi iyileştirmeler önerilebilir.

5.6. Parametre Optimizasyonu Yapılmış MobileNet Modeli

Bu tez çalışmasında MobileNet ile sınıflandırma yaptıktan sonra elde edilen sonuçların başarısını arttırmak için parametre optimizasyonu yapılmıştır. Optimizasyon yapılırken ızgara arama (GridSearch) yöntemi ile parametreler değiştirilip tekrar sınıflandırılmıştır. Parti boyutu (batch size) 64, dropout 0,6, öğrenme oranı (learning rate) 0,0001 ve optimizier olarak adam alınmıştır.

MobileNet modeli ile yapılan optimizasyon sonrasında elde edilen eğitim doğruluğu (%84,93) ve doğrulama doğruluğu (%92,46) değerleri, modelin performansı hakkında önemli bilgiler sunmaktadır. Genellikle, eğitim doğruluğunun doğrulama doğruluğundan daha yüksek olması beklenirken, bu durumda doğrulama doğruluğunun daha yüksek çıkması dikkat çekicidir. Bu durum, doğrulama veri kümesinin eğitim veri kümesine kıyasla daha kolay sınıflandırılabilir örnekler içermesinden veya modelin eğitim sırasında uygulanan düzenleme (regularizasyon) teknikleri (örneğin, dropout veya veri artırma) sayesinde doğrulama verilerine daha iyi genelleme yapmasından kaynaklanıyor olabilir. Ayrıca, optimizasyon sürecinde modelin hiperparametrelerinin başarılı bir şekilde ayarlanmış olması da bu sonucu etkilemiş olabilir.

Modelin genelleme yeteneği açısından bakıldığında, doğrulama doğruluğunun eğitim doğruluğundan yüksek olması, modelin eğitim verilerine aşırı uyum sağlamadığını (overfitting) ve görülmeyen verilere karşı iyi bir performans sergilediğini göstermektedir. Ancak, bu durumun doğrulama veri kümesinin yapısından kaynaklanıp kaynaklanmadığını anlamak için veri dağılımının detaylı bir şekilde incelenmesi gerekmektedir. Eğer doğrulama veri kümesi eğitim veri kümesine göre daha az çeşitli veya daha kolay sınıflandırılabilir örnekler içeriyorsa, modelin gerçek dünya verileri üzerinde benzer bir performans göstermesi garanti değildir. Bu nedenle, modelin test veri kümesi üzerindeki performansının da değerlendirilmesi önemlidir.


Sonuç olarak, bu değerler MobileNet modelinin başarılı bir şekilde eğitildiğini ve optimizasyon sürecinin etkili olduğunu göstermektedir.

Çizelge 5.8 MobileNet modelinin parametre optimizasyonu sonucunda elde edilen doğrulama değerleri

Ceviz Türü	Keskinlik	Geri Çağırma	F1-Skoru	Destek
Chandler	0,95	1,00	0,98	82
Fernor	1,00	0,84	0,91	92
Hekimhan	0,89	0,95	0,92	97
Kaman-1	0,96	0,91	0,93	85
Maraş-18	0,82	0,86	0,84	79
Oğuzlar-77	0,93	0,98	0,95	122
Doğruluk			0,92	557
Makro Ortalama	0,93	0,92	0,92	557
Ağırlıklı Ortalama	0,93	0,92	0,92	557


Çizelge 5.8’ de verilen sonuçlara göre; çeşitli sınıflar için "precision" (keskinlik), "recall" (geri çağırma), "f1-score" ve "support" (destek) değerlerini göstermektedir. Chandler sınıfı için keskinlik 0,95, geri çağırma 1,00, f1-skoru 0,98 ve destek 82 olarak belirtilmiştir. Fernor sınıfında ise keskinlik 1,00, geri çağırma 0,84, f1-skoru 0,91 ve destek 92’dir. Hekimhan sınıfı için keskinlik 0,89, geri çağırma 0,95, f1-skoru 0,92 ve destek 97 olarak belirtilmiştir. Kaman-1 sınıfında keskinlik 0,96, geri çağırma 0,91, f1-skoru 0,93 ve destek 85’tir. Maraş-18 sınıfı için keskinlik 0,82, geri çağırma 0,86, f1-skoru 0,84 ve destek 79 olarak raporlanmıştır. Son olarak Oğuzlar-77 sınıfında keskinlik 0,93, geri çağırma 0,98, f1-skoru 0,95 ve destek 122’dir.

Genel doğruluk oranı %92 olarak hesaplanmıştır. Makro ortalama değerleri keskinlik için 0,93, geri çağırma için 0,92, f1-skoru için 0,92 ve destek için 557 olarak belirtilmiştir. Ağırlıklı ortalama değerleri ise keskinlik için 0,93, geri çağırma için 0,92, f1-skoru için 0,92 ve destek için 557 olarak hesaplanmıştır.




Şekil 5.16 Parametre optimizasyonu ile elde edilmiş MobileNet 50 devir (epoch) doğrulama eğrileri grafiği

Şekil 5.16'da ceviz türlerinin sınıflandırılması için model eğitimi sırasında parametre optimizasyonlu MobileNet modelinin eğitim ve doğrulama grafiği görülmektedir.



Şekil 5.17 Parametre optimizasyonu ile elde edilmiş MobileNet 50 devir (epoch) doğrulama kaybı eğrileri grafiği



Şekil 5.18 Karışıklık matris kullanımı parametre optimizasyonlu MobileNet modeli

Matrisin satırları gerçek sınıfları, sütunları ise tahmin edilen sınıfları temsil eder. Diyagonal elemanlar, modelin doğru bir şekilde sınıflandırdığı örneklerin sayısını gösterirken, diyagonal dışındaki elemanlar yanlış sınıflandırılan örnekleri temsil eder. Chandler sınıfı için model, 82 örneği doğru sınıflandırmış, ancak 1 örneği yanlışlıkla Fernor olarak sınıflandırmıştır. Oğuzlar-77 sınıfı için model, 119 örneği doğru sınıflandırmış, ancak 2 örneği Maraş-18 olarak ve 1 örneği Kaman-1 olarak yanlış sınıflandırmıştır. Maraş-18 sınıfı, 54 örneği doğru sınıflandırmış, ancak 3 örneği Oğuzlar-77, 1 örneği Kaman-1 ve 1 örneği Maraş-12 olarak yanlış sınıflandırmıştır. Kaman-1 sınıfı için model, 38 örneği doğru sınıflandırmış, ancak 2 örneği yanlışlıkla Oğuzlar-77 ve 1 örneği Maraş-12 olarak sınıflandırmıştır. Maraş-12 sınıfında 39 örnek doğru sınıflandırılmışken, 3 örnek Maraş-18, 2 örnek Oğuzlar-77 ve 1 örnek Maraş-18 olarak yanlış sınıflandırılmıştır. Son olarak, Fernor sınıfı için model, 83 örneği doğru sınıflandırmış ve 1 örneği Chandler olarak yanlış sınıflandırmıştır. Bu analiz, modelin performansını değerlendirmenin yanı sıra, hangi sınıflarda iyileştirmelerin gerektiğini belirlemek için de kritiktir. Ayrıca, sınıflandırma algoritmasının parametre optimizasyonu ve model seçimi süreçlerinde rehberlik edebilir.

6. SONUÇLAR VE ÖNERİLER

Tez çalışmasında Chandler, Fernor, Hekimhan, Kaman-1, Maraş-18 ve Oğuzlar-77 ceviz çeşitlerinden alınan görüntüler üzerinden derin öğrenme ile sınıflandırma yapılmıştır. Bu amaçla 10 cm sabit mesafe olacak şekilde beyaz zemin üzerine kapalı kurduğumuz düzenekte Chandler cinsi cevizden 408 tane, Fernor cinsi cevizden 459 tane, Hekimhan cinsi cevizden 485 tane, Kaman-1 cinsi cevizden 425 tane Maraş-18 cinsi cevizden 393 tane ve Oğuzlar-77 cinsi cevizden 610 görüntü olmak üzere toplam 2780 adet görüntü elde edilmiş ve veri seti oluşturulmuştur. Analizler, önceden eğitilmiş derin öğrenme algoritmalarından DenseNet121, NASNetMobile ve MobileNet modelleri ile gerçekleştirilmiştir. Tezin uygulama aşamasında, toplam 2780 görüntü kullanılmış olup, bunların 2223 tanesi eğitim ve 557 tanesi doğrulama işlemleri için ayrılmıştır. İncelenen modeller arasında en yüksek performans MobileNet modelinde elde edilmiştir. Yapılan sınıflandırma analizlerinde DenseNet121 %80,25, NASNetMobile %65,53, MobileNet %83,66 sınıflandırma başarısına ulaşılmıştır.

Modellerin performansını maksimize etmek ve eğitim sürecini verimli hale getirmek amacıyla parametre optimizasyonu yöntemi uygulanmıştır. Sınıflandırma başarısı sırasıyla %90,66; %87,61; %92,46 oranlarına çıkmıştır.

Bu sonuçlar, derin öğrenme algoritmalarının ceviz türlerinin sınıflandırılmasında etkili bir yöntem olduğunu göstermektedir. Özellikle MobileNet modelinin yüksek sınıflandırma başarısı ve eğitim doğruluğu, ceviz çeşitlerinin doğru bir şekilde kategorize edilmesini sağlamıştır. Bu da cevizlerin besin değerine göre daha etkin bir şekilde değerlendirilmesini mümkün kılmıştır. İlerleyen çalışmalarda, ürün çeşitliliğinin belirlenmesi amacıyla yapılan çalışmaların geliştirilmesi, bu alandaki verim kaybını önleyecektir. Ürün sınıflandırılmasının daha hızlı ve kolay bir şekilde tespit edilmesi, özellikle bu alanda çalışanlar için zaman ve iş gücü açısından büyük kolaylıklar sağlayacaktır. Sınıflandırma alanında, daha az parametreye sahip yeni ürün modellerinin iyileştirilmesi için çalışmalar devam edecektir.

Gelecek çalışmalar için önerilerimiz, derin öğrenme tabanlı ceviz sınıflandırma modelinin iyileştirilmesine ve genişletilmesine odaklanmaktadır. Öncelikle, sınıflandırma başarısını artırmak amacıyla farklı derin öğrenme modelleri ve optimizasyon teknikleri kullanılarak modelin performansı iyileştirilebilir. Daha geniş ve çeşitli veri setleri kullanılarak modelin genelleme yeteneği artırılabilir, bu da modelin farklı ceviz türleri üzerinde daha yüksek

doğrulukla çalışmasını sağlayacaktır. Geliştirilen modellerin gerçek zamanlı ceviz sınıflandırma sistemlerine entegrasyonu, tarımsal üretim süreçlerinde pratik uygulamalara olanak tanıyacaktır. Ayrıca, bu derin öğrenme yaklaşımının diğer tarım ürünlerinin sınıflandırılması ve kalite kontrolü için kullanılması, tarımsal üretim süreçlerinin verimliliğini artırabilir. Bu bağlamda, geleneksel tarım ve bilişim teknolojileri alanlarında multidisipliner çalışmalar yapılarak yenilikçi ve sürdürülebilir çözümler geliştirilebilir. Bu öneriler, ceviz sınıflandırma çalışmalarının etkinliğini artırmanın yanı sıra, derin öğrenme uygulamalarının tarımsal üretim ve kalite kontrol süreçlerinde daha geniş bir yelpazede kullanımını teşvik etmektedir.



KAYNAKLAR

- Akça, Y., ve Sen, S. M. (1999). Ceviz (*Juglans regia* L.)'in Biyolojik ve Ekolojik Özellikleri. *Turkish Journal of Agriculture and Forestry*, 23(4), 831-838.
- Altuntaş, E., ve Özkan, Y. (2008). Physical and mechanical properties of some walnut (*Juglans regia* L.) cultivars. *International Journal of Food Engineering*, 4(4).
- Anagnostis, A., Tagarakis, A. C., Asiminari, G., Papageorgiou, E., Kateris, D., Mylonas, N., and Bochtis, D. (2021). A deep learning approach for anthracnose infected trees classification in walnut orchards. *Computers and Electronics in Agriculture*, 182, 105998.
- Amaral, J. S., Casal, S., Pereira, J. A., Seabra, R. M., and Oliveira, B. P. (2003). Determination of sterol and fatty acid compositions, oxidative stability, and nutritional value of six walnut (*Juglans regia* L.) cultivars grown in Portugal. *Journal of Agricultural and Food Chemistry*, 51(26), 7698–7702.
- Amin, H., Darwish, A., Hassanien, A. E., and Soliman, M. (2022). End-to-end deep learning model for corn leaf disease classification. *IEEE Access*, 10, 31103–31115.
- Ashtiani, S.-H. M., Rohani, A., and Aghkhani, M. H. (2020). Soft computing-based method for estimation of almond kernel mass from its shell features. *Scientia Horticulturae*, 262, 109071.
- Aslantaş, R., ve Ertürk, Ü. (2006). Ceviz Çeşitlerinin Pomolojik ve Fenolojik Özelliklerinin Belirlenmesi. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 37(2), 123-130.
- Bayrakdar, S., Çomak, B., Başol, D., ve Yücedag, İ. (2015). Determination of type and quality of hazelnut using image processing techniques. In *23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 616–619).
- Bergstra, J., and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(Feb), 281–305.
- Bernard, A., Barreneche, T., Lheureux, F., and Dirlewanger, E. (2018). Analysis of genetic diversity and structure in a worldwide walnut (*Juglans regia* L.) germplasm using SSR markers. *PLOS ONE*, 13(11), e0208021.
- Bhardwaj, P., and Kaur, A. (2021). A novel and efficient deep learning approach for COVID-19 detection using X-ray imaging modality. *International Journal of Imaging Systems and Technology*, 31(4), 1775–1791.
- Bryant, R. J., Weaver, C. M., and FACN. (1999). The new dietary reference intakes for calcium: Implications for osteoporosis. *Journal of the American College of Nutrition*, 18(5), 406–412.

- Chen, S., Liu, F., Zhang, C., Yu, K., He, Y., Feng, L., and Fang, H. (2022). Intelligent grading method for walnut kernels based on deep learning and physiological indicators. *Frontiers in Nutrition*, 9.
- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1800–1807).
- Çataloluk, H. (2012). *Gerçek tıbbi veriler üzerinde veri madenciliği yöntemlerini kullanarak hastalık teşhisi* [Master's thesis, Bilecik Üniversitesi, Fen Bilimleri Enstitüsü].
- Dian, R., Xu, L., and Yang, Y. (2019). Computer vision detection of foreign objects in walnuts using deep learning. *Computers and Electronics in Agriculture*, 162, 1001–1010.
- Doğan, F., and Türkoğlu, İ. (2018). Comparison of leaf classification performance of deep learning algorithms. *Sakarya University Journal of Computer and Information Sciences*, 1(1), 10–21.
- Ercisli, S., and S., B. (2012). Determination of size and shape features of walnut (*Juglans regia* L.) cultivars using image processing. *Scientia Horticulturae*, 133, 47–55.
- Feng, X., Zhou, H., Zulfikar, S., Luo, X., Hu, Y., Feng, L., Malvolti, M. E., Woeste, K., and Zhao, P. (2018). The phytogeographic history of common walnut in China. *Frontiers in Plant Science*, 9, 1399.
- Food and Agriculture Organization (FAO). (2019). *The state of food and agriculture 2019*. Rome: Food and Agriculture Organization of the United Nations.
- Gupta, D., Khanna, A., Bhattacharyya, S., Hassanien, A. E., and Anand, S. (Eds.). (2022). *Deep learning for medical applications with unique data*. Academic Press.
- Güneş, E. (2022). *Derin öğrenme yaklaşımı ile fındık meyvesinin sınıflandırılması* [Doctoral dissertation, Marmara Üniversitesi].
- Güneş, M., ve Özkan, Y. (2004). Ceviz Yetiştiriciliğinde İklim ve Toprak İstekleri. *Tarım Bilimleri Dergisi*, 10(3), 357-362.
- Han, Y., Chen, C., and Kang, H. (2021). Quality estimation of nuts using deep learning classification of hyperspectral imagery. *Computers and Electronics in Agriculture*, 180, 105868.
- Haykin, S. (2009). *Neural networks and learning machines* (Vol. 3). Pearson.
- Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hossain, M. S., Al-Hammadi, M., and Muhammad, G. (2018). Automatic fruit classification using deep learning for industrial applications. *IEEE Transactions on Industrial Informatics*, 15(2), 1027–1034.

- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint arXiv:1704.04861*.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., and Adam, H. (2019). Searching for MobileNetV3. *arXiv preprint arXiv:1905.02244*.
- Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700–4708).
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., Fischer, I., Wojna, Z., Song, Y., Guadarrama, S., and Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. *Proceedings of the 30th IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017)*, 3296–3305.
- Hutter, F., Hoos, H. H., and Leyton-Brown, K. (2011). Sequential model-based optimization for general algorithm configuration. In *International Conference on Learning and Intelligent Optimization* (pp. 507–523). Springer, Berlin, Heidelberg.
- Iandola, F., Moskewicz, M., Karayev, S., Girshick, R., Darrell, T., and Keutzer, K. (2014). DenseNet: Implementing efficient ConvNet descriptor pyramids. *arXiv preprint arXiv:1404.1869*.
- Ismail, A. A. (2018). Improving long-horizon forecasts with expectation-biased. *arXiv preprint arXiv:1804.XXXXXX*.
- İnternet: Tarım Orman Portalı(2023)Url: https://arastirma.tarimorman.gov.tr/ktae/Belgeler/BGT/1-Cevizin_Bitkisel_Ozellikleri.pdf. Son Erişim Tarihi: 23.01.2025
- İnternet: Hekimhan Portalı(2025)Url: <http://www.hekimhan.gov.tr/hekimhan-cevizi>. Son Erişim Tarihi: 21.01.2025
- İnternet: Zencefil Organik Portalı(2025)Url: <https://www.zencefilorganik.com/kaman-cevizi-kaman-1-k1-cinsi-ceviz-ince-kabuk-ozel-kuru-ceviz>. Son Erişim Tarihi: 18.01.2025
- İnternet: Aksu Tarım Portalı(2025)Url: <https://www.aksutarim.com.tr/Ceviz-Fidan%C4%B1-%C3%87e%C5%9Fitleri/Mara%C5%9F-18>. Son Erişim Tarihi: 17.01.2025
- İnternet: Oğuzlar Portalı(2019)Url: <http://www.oguzlar.gov.tr/oguzlar-77-vevizi>. Son Erişim Tarihi: 22.01.2025
- İnternet: Sevindik, B.(2025)Url: <https://river.com.tr/makine-ogrenmesi-modelleri-yapay-sinir-aglari-ysa-ile-yenilikci-cozumler/>. Son Erişim Tarihi: 30.01.2025

İnternet: Çakı, Ö.(2024)Url: https://www.linkedin.com/posts/%C3%B6zg%C3%BCr-ozan-h%C3%BCseyin-%C3%A7aki-b85418296_bug%C3%BCnk%C3%BC-yaz%C4%B1m%C4%B1zda-ara%C5%9Ft%C4%B1rmakta-ve-%C3%BCzerine-activity-7276250073250844672-Er-k/?originalSubdomain=tr. Son Erişim Tarihi: 05.01.2025

İnternet: Koç, E.(2022)Url: (<https://miuul.com/blog/evrisimli-sinir-aglarina-giris>). Son Erişim Tarihi: 08.01.2025

İnternet: Towards Data Science Portalı Url: <https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>. Son Erişim Tarihi: 20.12.2024

İnternet: Güler, E.(2022)Url: [https://efecanxrd.medium.com/rnn-nedir-recurrent-neural-network-3caa3a245624#:~:text=Tekrarlayan%20sinir%20a%C4%9F%C4%B1%20\(RNN\)%2C,bir%20%C3%A7e%C5%9Fit%20derin%20%C3%B6%C4%9Frenme%20yap%C4%B1lar%C4%B1d%C4%B1r](https://efecanxrd.medium.com/rnn-nedir-recurrent-neural-network-3caa3a245624#:~:text=Tekrarlayan%20sinir%20a%C4%9F%C4%B1%20(RNN)%2C,bir%20%C3%A7e%C5%9Fit%20derin%20%C3%B6%C4%9Frenme%20yap%C4%B1lar%C4%B1d%C4%B1r). Son Erişim Tarihi: 08.11.2024

İnternet: Bozarık, E.(2018) Url: <https://medium.com/smlr-center/sinir-a%C4%9Flar%C4%B1-ve-derin-%C3%B6%C4%9Frenme-v-grandyan-d%C3%BC%C5%9F%C3%BC%C5%9F%C3%BC-8c6d15a3d965>. Son Erişim Tarihi: 12.11.2024

İnternet: Onar, A.(2020) Url: <https://alitunacanonar.medium.com/derin-%C3%B6%C4%9Frenme-y%C3%B6ntemleri-ve-uygulamalar%C4%B1-1ce215de40e8>. Son Erişim Tarihi: 02.01.2025

İnternet: Baheti, P.(2021) Url: <https://www.v7labs.com/blog/convolutional-neural-networks-guide>). Son Erişim Tarihi: 10.01.2025

İnternet: Gülşen, F.(2021) Url: <https://furkangulsen.medium.com/tensorflow-ile-transfer-learning-%C3%B6zellik-%C3%A7%C4%B1kar%C4%B1m%C4%B1-feature-extraction-ed0a62739470>. Son Erişim Tarihi: 13.11.2024

Jiang, H., Ye, L., Li, X., and Shi, M. (2021). Variety identification of Chinese walnuts using hyperspectral imaging combined with chemometrics. *Applied Sciences*, 11(19), 9124.

Kang, H., and Chen, C. (2020). Fast implementation of real-time fruit detection in apple orchards using deep learning. *Computers and Electronics in Agriculture*, 168, 105108.

Karadağ, B., Arı, A., ve Karadağ, M. (2021). Derin öğrenme modellerinin sinirsel stil aktarımı performanslarının karşılaştırılması [Comparison of neural style transfer performances of deep learning models]. *Journal of Polytechnic*, 24(4), 1611–1622.

Karadeniz, A., Başaran, E., and Çelik, Y. (2024). Classification of walnut dataset by selecting CNN features with whale optimization algorithm. *Multimedia Tools and Applications*.

- Karadeniz, A. T. (2023). *Yaprak görüntülerini kullanarak derin öğrenme ile ceviz türlerinin belirlenmesi* (Unpublished doctoral dissertation).
- Karaküçük, Y., ve Eker, S. (2020). Sağlık bilimlerinde yapay zeka, oftalmolojide yapay zeka ve derin öğrenme uygulamaları. In D. Şahin ve Ş. Sivri (Eds.), *Sağlık bilimlerinde yapay zeka* (pp. 123-145). Özyurt Matbaacılık.
- Kavdır, İ., and Guyer, D. E. (2008). Evaluation of different pattern recognition techniques for apple sorting. *Biosystems Engineering*, 99(2), 211-219.
- Khalesi, S., Mahmoudi, A., Hosainpour, A., and Alipour, A. (2011). Detection of walnut varieties using impact acoustics and artificial neural networks (ANNs). *Modern Applied Science*, 6(1), 43–50.
- Khosa, I., and Pasero, E. (2014). Feature extraction in X-ray images for hazelnuts classification. *Proceedings of the 2014 International Joint Conference on Neural Networks (IJCNN)*, 2354–2360.
- Koç, C., Gerdan, D., Eminoğlu, M. B., Yegül, U., Koç, B., and Vatandaş, M. (2020). Classification of hazelnut cultivars: Comparison of DL4J and ensemble learning algorithms. *Notulae Botanicae Horti Agrobotanici Cluj-Napoca*, 48(4), 2316–2327.
- Koçer, B. (2012). *Transfer öğrenmede yeni yaklaşımlar* [Doctoral dissertation, Selçuk Üniversitesi].
- Koşar, M. B., Koşar, D. A., Sönmez, E., ve Ertürk, E. (2023). ‘Chandler’ ceviz çeşidinin fenolojik ve pomolojik özellikleri üzerine farklı çöğür anaçların etkisi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(2), 726-735.
- Koyuncu, M. A., ve İslam, A. (2005). Ceviz (*Juglans regia* L.)’in Morfolojik ve Pomolojik Özellikleri. *Süleyman Demirel Üniversitesi Ziraat Fakültesi Dergisi*, 1(1), 1-8.
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1-9.
- Küden, A. B., ve Tanrıver, E. (2002). Ceviz Yetiştiriciliğinde Toprak İstekleri ve Gübreleme. *Akdeniz Üniversitesi Ziraat Fakültesi Dergisi*, 15(2), 45-52.
- Küden, A. B., ve Tanrıver, E. (2005). Türkiye’de Geliştirilen Bazı Yerli Ceviz Çeşitlerinin Verim ve Kalite Özellikleri. *Akdeniz Üniversitesi Ziraat Fakültesi Dergisi*, 18(2), 45-52.
- Lu, J., Han, X.-z., and Wang, K.-j. (2017). Classification of collection walnut based on GLCM and SVM. *DEStech Transactions on Engineering and Technology Research*.
- Martínez, M., Labuckas, D., Lamarque, A., and Maestri, D. (2010, September). Walnut (*Juglans regia* L.): Genetic resources, chemistry, by-products. *Journal of the Science of Food and Agriculture*, 90(12), 1959–1967.

- McGranahan, G., and Leslie, C. A. (1991). Walnuts (*Juglans* spp.). In *Genetic Resources of Temperate Fruit and Nut Crops* (pp. 907-951). International Society for Horticultural Science (ISHS).
- Mitchell, T., Buchanan, B., DeJong, G., Dietterich, T., Rosenbloom, P., and Waibel, A. (1990). Machine learning. *Annual Review of Computer Science*, 4(1), 417–433.
- National Research Council. (2000). *How people learn: Brain, mind, experience, and school: Expanded edition*. National Academies Press.
- Özkan, Y., ve Gülşen, Y. (2005). Türkiye’de Geliştirilen Bazı Yerli Ceviz Çeşitlerinin Pomolojik ve Fenolojik Özellikleri. *Tarım Bilimleri Dergisi*, 11(3), 287-294.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... and Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825-2830.
- Peng, J., Liu, F., Zhang, C., Yu, K., He, Y., Feng, L., and Fang, H. (2015). Classification of the varieties of walnut powder by laser-induced breakdown spectroscopy and chemometrics. *Agricultural Information Management*, 2.
- Powers, D. M. W. (2011). Evaluation: From precision, recall, and F-measure to ROC, informedness, markedness, and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Pronprasit, R., and Natwichai, J. (2013). Prediction of mango fruit quality from NIR spectroscopy using an ensemble classification. *International Journal of Computer Applications*, 83(14).
- Reiter, R., Manchester, L., and Tan, D. (2005, September 21). Melatonin in walnuts: Influence on levels of melatonin and total antioxidant capacity of blood. *Nutrition*, 21(9), 920–924.
- Rismiyati, S. N. E., Khadijah, and Shiddiq, I. N. (2020). Xception architecture transfer learning for garbage classification. In *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)* (pp. 1-4).
- Roy, K., Chaudhuri, S. S., and Pramanik, S. (2021). Deep learning-based real-time industrial framework for rotten and fresh fruit detection using semantic segmentation. *Microsystem Technologies*, 27, 3365–3375.
- Russakovsky, O., Deng, J., Su, H., et al. (2015). ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115, 211–252.
- Ruuska, S., Hämäläinen, W., Kajava, S., Mughal, M., Matilainen, P., and Mononen, J. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural Processes*, 148, 56–62.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *arXiv preprint arXiv:1801.04381*.

- Sanlin, Zhang, et al. (2022). Identification and localization of walnut varieties based on YOLOv5. *Journal of Chinese Agricultural Mechanization*, 43(7), 167.
- Saranya, N., et al. (2020). Fruit classification using traditional machine learning and deep learning approach. In *Computational Vision and Bio-Inspired Computing: ICCVBIC 2019* (pp. 123-135). Springer International Publishing.
- Seyyarer, E., Ayata, F., Uçkan, T., Karcı, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Bilgisayar Bilimi*, 5(2), 90-98.
- Shah, F., Khan, M., Sharif, M., Tariq, U., Khan, A., Kadry, S., and Thinnukool, O. (2021). A cascaded design of best features selection for fruit diseases recognition. *Computers, Materials and Continua*, 70, 1491–1507.
- Shibly, M. M. A., Tisha, T. A., Tani, T. A., and Ripon, S. (2021). Convolutional neural network-based ensemble methods to recognize Bangla handwritten character. *PeerJ Computer Science*, 7, 1–30.
- Simonyan, K., and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Simonyan, K., and Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*.
- Simopoulos, A. (2004). Health effects of eating walnuts. *Food Reviews International*, 20(1), 91–98.
- Singh, S., et al. (2022). *ECS Sens. Plus*, 1, 023401.
- Song, P., Gao, H., Zhao, B., Zhang, A., and Liu, F. (2019). Classification of different walnut varieties using low-field nuclear magnetic resonance technology and cluster analysis. *International Journal of Agricultural and Biological Engineering*, 12(6), 116–121.
- Snoek, J., Larochelle, H., and Adams, R. P. (2012). Practical Bayesian optimization of machine learning algorithms. In *Advances in Neural Information Processing Systems* (pp. 2951–2959).
- Sun, Z., et al. (2020). Deep learning classification for crop types in North Dakota. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2200–2213.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818–2826).
- Tsai, C., Leitzmann, M., Hu, F., Willett, W. C., and Giovannucci, E. (2004). Frequent nut consumption and decreased risk of cholecystectomy in women. *American Journal of Clinical Nutrition*, 80, 76–81.
- Türkoğlu, M., et al. (2021). Derin evrişimsel sinir ağı kullanılarak kayısı hastalıklarının sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 334–345.

- Ucuzal, H. (2020). *Yapay zekâya dayalı anlamsal video işleme yöntemlerinin tıpta kullanılabilirliğinin araştırılması* (Master's thesis, İnönü Üniversitesi Sağlık Bilimleri Enstitüsü).
- Yu, L., et al. (2023). An improved YOLOv5 model: Application to mixed impurities detection for walnut kernels. *Foods*, 12(3), 624.
- Zhu, H., Li, J., and Xu, J. (2020). Authentication and provenance of walnut combining Fourier transform mid-infrared spectroscopy with machine learning algorithms. *Molecules*, 25(21), 4987.
- Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2017). Learning transferable architectures for scalable image recognition. *arXiv preprint arXiv:1707.07012*.



ÖZGEÇMİŞ

Adı-Soyadı : Barış ATEŞ

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

1-) S. Harmancı, Y. Ünal, B. Ateş, “Classification of Hazelnut Species with Pre-Trained Deep Learning Models”, Intell Methods Eng Sci, vol. 2, no. 2, pp. 58–66, Jun. 2023, doi: [10.58190/imiens.2023.14](https://doi.org/10.58190/imiens.2023.14).

2-) B. Ateş, Y. Ünal, M. Kara, S. Harmancı, “Classification of Walnut Species with Pre-Trained Deep Learning Models” 9. Uluslararası 19 Mayıs Yenilikçi Bilimsel Yaklaşımlar Kongresi Samsun 2023.