

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

DERİN TRANSFER ÖĞRENME YAKLAŞIMLARI İLE
AFLATOKSİNLİ KURU İNCİRLERİN TAHRİBATSIZ
GERÇEK ZAMANLI TESPİTİ

CİHAN KILIÇ

KOCAELİ 2023

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

DERİN TRANSFER ÖĞRENME YAKLAŞIMLARI İLE
AFLATOKSİNLİ KURU İNCİRLERİN TAHRİBATSIZ
GERÇEK ZAMANLI TESPİTİ

CİHAN KILIÇ

Dr.Öğr.Üyesi Alpaslan Burak İNNER

Danışman, Kocaeli Üniversitesi

.....

Prof.Dr. Adnan KAVAK

Jüri Üyesi, Kocaeli Üniversitesi

.....

Prof.Dr. Hüseyin Metin ERTUNÇ

Jüri Üyesi, Kocaeli Üniversitesi

.....

Prof.Dr. Nevcihan DURU

Jüri Üyesi, Kocaeli Sağlık ve Teknoloji Üniv.

.....

Dr.Öğr.Üyesi Ekin EKİNCİ

Jüri Üyesi, Sakarya Uygulamalı Bilimler Üniv.

.....

Tezin Savunulduğu Tarih: 18.01.2023

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

☐ Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.

☒ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler TÜBİTAK UME, TÜBİTAK MAM Gıda Bilimleri ve TÜBİTAK BİLGEM UEKAE Enstitülerinden alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Cihan KILIÇ

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanımı bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- ☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- ☐ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
- ☒ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Cihan KILIÇ

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışması, ülke ekonomisinde ve ihracatında önemli bir yeri bulunan kuru incirde oluşan aflatoksinin tahribatsız bir şekilde tespitini sağlayarak, hem insan sağlığı açısından aflatoksinli incirlerin tüketiminin önlenmesi hem de ülke ekonomisi açısından fayda sağlanması amacıyla gerçekleştirilmiştir.

Tez çalışmam süresince bilgi, deneyim ve görüşleri ile çalışmalarına katkıda bulunan, danışmanım Dr. Öğr. Üyesi Alpaslan Burak INNER'e teşvikleri ve destekleri için teşekkür ederim.

Ayrıca tez çalışmama bilgi ve tavsiyeleri ile katkıda bulunan saygıdeğer jüri hocalarım Prof. Dr. Adnan KAVAK ve Prof. Dr. Hüseyin Metin ERTUNÇ'a,

Laboratuvar ve cihaz alt yapısı kullanımı için TÜBİTAK Ulusal Metroloji Enstitüsü ve TÜBİTAK BİLGEM Ulusal Elektronik ve Kriptoloji Araştırma Enstitüsüne, referans cihaz ölçümleri için TÜBİTAK Marmara Araştırma Merkezi Gıda Bilimleri Enstitüsü'ne, Dr. Hayrettin ÖZER'e ve yardımlarından dolayı çalışma arkadaşım Yakup GÜLMEZ'e,

Tüm dünyayı olumsuz etkileyen pandemi dönemi de dahil olmak üzere, tüm tez çalışmam süresince desteklerini esirgemeyen eşim Hatice KILIÇ ve kızlarım Zeynep Buse, Elifnaz ve İpek KILIÇ'a en içten dileklerle teşekkür ederim.

Ocak – 2023

Cihan KILIÇ

İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vi
TABLolar DİZİNİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ	viii
ÖZET	x
ABSTRACT	xi
1. GİRİŞ	1
1.1. Aflatoksin	1
1.2. İncir.....	3
1.3. İncirde Aflatoksin Oluşumu	5
1.4. İncirde Aflatoksinin İlk Ortaya Çıkışı	5
1.5. Problem Tanımı ve Motivasyon	6
2. AFLATOKSİN TESPİT YÖNTEMLERİ	8
2.1. Kromatografik Yöntemler	8
2.2. Spektroskopik Yöntemler	8
2.2.1. Floresans Spektroskopisi ve BGYF Metodu.....	9
2.2.2. Hiperspektral Görüntüleme.....	9
2.2.3. Yakın Kızılötesi Spektroskopisi	10
2.2.4. Raman Spektroskopisi	11
3. İLGİLİ ÇALIŞMALAR.....	12
4. MATERYAL VE METODLAR.....	17
4.1. Aflatoksin Tespitinde Sınıflandırma Öncesi İşlemler	17
4.1.1. Ürün Örneklerinin Temin Edilmesi ve Aflatoksin	
Kontaminasyonu	18
4.1.2. Optik Ortamın Hazırlanması ve Örneklerin İncelenmesi	19
4.1.3. Referans Ölçümlerin Yapılması ve Veri Setinin Oluşturulması.....	20
4.1.4. Veri Ön işleme	21
4.1.5. Öznitelik Çıkarımı	23
4.2. Veri Çoğaltma.....	23
4.2.1. Orijinal Verilerin Dönüştürülmesi	25
4.2.1.1. Geometrik Dönüşümler	25
4.2.1.2. Piksel Düzeyinde Dönüşümler	25
4.2.1.3. Elastik Dönüşümler	26
4.2.2. Sentetik Verilerin Üretilmesi	27
4.3. Kullanılan Sınıflandırma ve Görüntü İşleme Yöntemleri	27
4.3.1. Rastgele Orman.....	27
4.3.2. Destek Vektör Makineleri.....	28
4.3.2.1. Doğrusal SVM	29
4.3.2.2. Doğrusal Olmayan SVM	30
4.3.3. Eşikleme.....	31
4.4. Evrişimli Sinir Ağları	32
4.4.1. CNN Katmanları	33
4.4.1.1. Evrişim Katmanı	33

4.4.1.2. Aktivasyon Katmanı	33
4.4.1.3. Havuzlama Katmanı	34
4.4.1.4. Tam Bağlantılı Katman.....	34
4.4.2. Evrişimli Sinir Ağlarının Normalizasyonu ve Optimizasyonu.....	34
4.4.3. Hiperparametreler	35
4.4.3.1. Öğrenme Hızı.....	36
4.4.3.2. Aktivasyon Fonksiyonu	36
4.4.3.3. Optimizasyon Algoritması.....	38
4.4.3.4. Epok (Eğitim Dönem) Sayısı ve Paket Boyutu	42
4.4.3.5. Ağırlık Başlatma	43
4.4.3.6. Başarım İyileştirme.....	43
4.5. Transfer Öğrenme	45
4.5.1. Öznitelik Çıkarma.....	46
4.5.2. Model Uyarlama (İnce Ayar).....	47
4.6. Önceden Eğitilmiş Derin Öğrenme Modelleri.....	48
4.6.1. AlexNet.....	49
4.6.2. GoogleNet (InceptionV1)	49
4.6.3. VGGNet	50
4.6.4. InceptionV3.....	50
4.6.5. ResNet.....	50
4.6.6. Inception-ResNet	51
4.6.7. Xception.....	51
4.6.8. MobileNet	51
4.6.9. DenseNet.....	52
4.6.10. NasNet.....	53
4.6.11. EfficientNet.....	53
5. DENEYSEL BULGULAR VE TARTIŞMA	54
5.1. Veri Setinin Oluşturulması	55
5.1.1. İncir Numunelerinin Temini	55
5.1.2. Görüntülerin Elde Edilmesi	55
5.1.3. Referans Cihaz Ölçümleri.....	57
5.1.4. Örneklerin Etiketlenmesi	61
5.2. Performans Metrikleri.....	61
5.3. Geliştirme Ortamı ve Veri Çoğaltma.....	62
5.4. BGYF Tespit Çalışmaları	63
5.4.1. Eşikleme Yöntemi ile Tespit.....	63
5.4.2. SVM ile Sınıflandırma.....	65
5.4.3. Transfer Öğrenme ile Sınıflandırma	66
5.5. BGYF ve Aflatoksin Arasındaki Korelasyon	70
5.6. Farklı Dalga Boyundaki Işık Kaynakları ile Aflatoksin Tespit Çalışmaları	71
5.6.1. CNN Modellerinde İnce Ayar.....	71
5.6.2. CNN Modellerine Dayalı Öznitelik Çıkarma	72
6. SONUÇLAR VE ÖNERİLER.....	80
KAYNAKLAR.....	84
KİŞİSEL YAYIN VE ESERLER.....	94
ÖZGEÇMİŞ.....	95

ŞEKİLLER DİZİNİ

Şekil 2.1.	Kuru incir örneklerinin UV ışık altındaki görünüşleri.....	10
Şekil 4.1.	Aflatoksin tespiti ve sınıflandırma çalışma basamakları.....	18
Şekil 4.2.	Destek Vektör Makinesi	29
Şekil 4.3.	CNN mimari modeli	32
Şekil 4.4.	Transfer Öğrenme Mekanizması	46
Şekil 4.5.	Transfer Öğrenme Yaklaşımları	47
Şekil 5.1.	İncir görüntülerinin alındığı optik sistem	56
Şekil 5.2.	BGYF ışması yapan ve yapmayan incir örnekleri.....	57
Şekil 5.3.	Farklı ışık kaynakları altında örnek incir görüntüsü.....	58
Şekil 5.4.	Ölçümler esnasında kullanılan terazi ve karıştırıcı cihaz	58
Şekil 5.5.	Karışımın homojenize edilmesi ve Whatman filtre kağıdından süzülmesi	59
Şekil 5.6.	Referans ölçümlerin yapıldığı HPLC cihazı.....	60
Şekil 5.7.	Veri setindeki incirlerin aflatoksin konsantrasyon değerleri	60
Şekil 5.8.	Kuru incir görüntüleri ön işleme adımları	64
Şekil 5.9.	Eşikleme yöntemiyle BGYF ışması tespiti yapılan incir örnekleri.....	65
Şekil 5.10.	BGYF tespiti için farklı transfer öğrenme modelleriyle elde edilen doğruluk değerleri.....	66
Şekil 5.11.	BGYF sınıflandırması için DenseNet modeli kullanılarak inşa edilen mimari	67
Şekil 5.12.	BGYF tespiti için önerilen modelin doğruluk ve kayıp grafikleri	69
Şekil 5.13.	BGYF ve aflatoksin arasındaki korelasyon.....	71
Şekil 5.14.	Aflatoksin tespiti için farklı transfer öğrenme modelleriyle elde edilen doğruluk değerleri.....	72
Şekil 5.15.	Öznitelik çıkarma, birleştirme, boyut azaltma ve sınıflandırma mimarisi	72
Şekil 5.16.	Aflatoksin tespiti için önerilen modelin mimarisi	75
Şekil 5.17.	Aflatoksin tespiti için önerilen yöntemin akış diyagramı	77
Şekil 5.18.	Aflatoksin tespiti için önerilen sistemin örnek tasarımı	78

TABLolar DİZİNİ

Tablo 1.1. Bazı gıda ürünleri için aflatoksin yasal limitleri.....	3
Tablo 1.2. Sarılop çeşidi kuru incirin besin değeri içeriği	4
Tablo 1.3. 2021 yılı dünya incir ihracat rakamları.....	5
Tablo 3.1. Farklı gıda türlerinde optik yöntemler ile sınıflandırma yapılarak aflatoksin tespitini bildiren araştırma çalışmalarının özeti	14
Tablo 4.1. Sık kullanılan çekirdek fonksiyonları.....	31
Tablo 4.2. Aktivasyon fonksiyonları.....	37
Tablo 4.3. Gradyan azalma optimizasyon algoritmaları	40
Tablo 4.4. Önceden eğitilmiş derin öğrenme modelleri.....	48
Tablo 5.1. Veri çoğaltma parametreleri	63
Tablo 5.2. DenseNet169 modeli ile yapılan çalışmada elde edilen performans metrikleri	68
Tablo 5.3. DenseNet201 modeli ile yapılan çalışmada elde edilen performans metrikleri	68
Tablo 5.4. DenseNet169 ve DenseNet201 modellerinin karışıklık matrisleri	69
Tablo 5.5. BGYF tespiti için önerilen metot ile diğer yöntemlerin karşılaştırması	70
Tablo 5.6. DeneySEL çalışma sonucu elde edilen doğruluk değerleri.....	74
Tablo 5.7. Tüm veri setleri için en iyi modellerin performans metrikleri	75
Tablo 5.8. Önerilen modelin karışıklık matrisi	76
Tablo 5.9. Önerilen modelin farklı eğitim:test veri oranlarındaki performans metrikleri	76
Tablo 5.10. İncirlerin iç ve dış yüzey görüntüleri ile yapılan deneySEL çalışma sonucu elde edilen doğruluk değerleri.....	77

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ADAM	: Adaptive Moment Estimation (Uyarlamalı Moment Tahmini)
AF(-)	: Aflatoksin kontamine olmıyan kuru incir numuneleri
AF(+)	: Aflatoksin kontamine kuru incir numuneleri
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
AOAC	: Association of Official Agricultural Chemists (Analitik Kimyagerler Birliğı)
BGYF	: Bright Greenish Yellow Fluorescent (Parlak Yeşilimsi Sarı Floresans)
BGYF(-)	: BGYF ışıması yapmayan kuru incir numuneleri
BGYF(+)	: BGYF ışıması yapan kuru incir numuneleri
CART	: Classification and Regression Tree (Sınıflandırma ve Karar Ağacı)
CEN	: European Committee for Standardization (Avrupa Standardizasyon Komitesi)
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağları)
DA	: Discriminant Analysis (Diskriminant Analiz)
DF	: Discriminant Function (Diskriminant Fonksiyonu)
DS-365	: HPLC referans cihaz ölçüm sonuçları ve 365nm ışık kaynağı altında alınan incir görüntüleri kullanarak oluşturulan veri seti
DS-395	: HPLC referans cihaz ölçüm sonuçları ve 395nm ışık kaynağı altında alınan incir görüntüleri kullanarak oluşturulan veri seti
DS-405	: HPLC referans cihaz ölçüm sonuçları ve 405nm ışık kaynağı altında alınan incir görüntüleri kullanarak oluşturulan veri seti
DS-420	: HPLC referans cihaz ölçüm sonuçları ve 420nm ışık kaynağı altında alınan incir görüntüleri kullanarak oluşturulan veri seti
DS-BGYF	: BGYF ışıması sonuçlarına göre etiketlenen veri seti
DS-W	: HPLC referans cihaz ölçüm sonuçları ve beyaz ışık kaynağı altında alınan incir görüntüleri kullanarak oluşturulan veri seti
ELISA	: Enzyme-Linked ImmunoSorbent Assay (Enzime Bağlı İmmünosorbent Testi)
ELU	: Exponential Linear Unit (Üstel Doğrusal Birim)
FCL	: Fully Connected Layer (Tam Bağlantılı Katman)
FDA	: Factorial Discriminant Analysis (Faktöriyel Diskriminant Analizi)
FS	: Floresans Spektroskopisi
GAP	: Global Average Pooling (Küresel Ortalama Havuzlama)
GAN	: Generative Adversarial Network (Çekişmeli Üretici Ağ)
HPLC	: High-Performance Liquid Chromatography (Yüksek Performanslı Sıvı Kromatografisi)
HSI	: Hyperspectral Imaging (Hiperspektral Görüntüleme)
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması)
ISO	: International Organization for Standardization (Uluslararası Standardizasyon Örgütü)
k-NN	: k-Nearest Neighbors (k-En Yakın Komşu)
LC-MS/MS	: Liquid Chromatography-Tandem Mass Spectrometry (Sıvı Kromatografi Tandem Kütle Spektroskopisi)

LDA	: Linear Discriminant Analysis (Doğrusal Diskriminant Analizi)
LDC	: Linear Discriminant Classifier (Doğrusal Diskriminant Sınıflayıcı)
LS-SVM	: Least square support vector machine (En Küçük Kareler Destek Vektör Makineleri)
MLP	: Multi layer perceptrons (Çok Katmanlı Algılayıcı)
MDT	: Multivariate Decision Tree (Çok Değişkenli Katrar Ağacı)
MSI	: Multispectral Imaging (Multispektral Görüntüleme)
NIRS	: Near-Infrared Spectroscopy (Yakın Kızılötesi Spektroskopi)
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
PLS	: Partial Least Squares (Kısmi En Küçük Kareler)
PLS-DA	: Partial Least-square principal component analysis (Kısmi En Küçük Kareler Diskriminat Analiz)
RELU	: Rectified Linear Unit (Doğrultulmuş Lineer Birim)
RF	: Random Forest (Rastgele Orman)
RMSE	: Root Mean Squared Error (Hata kareler ortalamasının karekökü)
ROI	: Region of Interest (İlgi Alanı)
SAM	: Spectral Angle Mapper (Spektral Açık Haritalama)
SGD	: Stochastic Gradient Descent (Olasılıksal Gradyan Azalma)
SGDM	: Stochastic Gradient Descent with Momentum (Momentumlu Stokastik Gradyan)
SELU	: Scaled Exponential Linear Unit (Ölçekli Üstel Doğrusal Birim)
SNV	: Standard Normal Variate (Standart Normal Dağılım)
SVC	: Support Vector Classifier (Destek Vektör Sınıflayıcı)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TLC	: Thin-Layer Chromatography (İnce Tabaka Kromatografisi)
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
UV	: Ultraviyole

DERİN TRANSFER ÖĞRENME YAKLAŞIMLARI İLE AFLATOKSİNLİ KURU İNCİRLERİN TAHRİBATSIZ GERÇEK ZAMANLI TESPİTİ

ÖZET

Aflatoksinler, *Aspergillus* mantar türlerinin ürettiği en tehlikeli mikotoksindir ve insanlarda karaciğer kanseri de dahil olmak üzere çeşitli sağlık sorunlarına neden olabilir. İncir ve birçok tarım ürünü aflatoksinlerden etkilenir. Aflatoksini kontamine gıdalardan temizlemek mümkün olmadığından tüketimden önce tespit edilmesi çok önemlidir. Kromatografik yöntemler, aflatoksin tespiti için altın standart olarak kabul edilir, ancak bu yöntemler oldukça pahalı, zaman alıcı ve ürünün parçalanmasını gerektirir. Bu nedenle aflatoksin tespiti için spektroskopik yöntemler kullanılarak oluşturulan bilgisayarlı görü tabanlı sistemlerle yapılmaya başlanmıştır. Tez çalışması iki aşamalı olarak gerçekleştirilmiştir. Birinci aşamada Ege Bölgesi'ndeki incir üretim tesislerinden temin edilen kuru incir numuneleri kullanılarak, farklı dalga boyundaki ışık kaynakları altında elde edilen incir görüntülerinden dengeli ve özgün veri setleri oluşturulmuştur. İkinci aşamada ise, bilgisayarlı görü tabanlı bir sistem oluşturularak hızlı, tahribatsız ve etkili aflatoksin tespit sistemi oluşturma çalışmaları yapılmış ve bu amaçla iki farklı yöntem önerilmiştir. İlk yöntem, incir üretim tesislerinde halihazırda kullanılmakta olan Parlak Yeşilimsi Sarı Floresans (BGYF) kontrolünü otomatik olarak yapabilecek bir sistemin geliştirilmesine yöneliktir. Derin transfer öğrenmede model uyarlama yaklaşımı ile DenseNet169 modeli kullanılarak %97,50 doğruluk elde edilmiştir. Önerilen ikinci yöntemde ise, farklı dalga boylarındaki ışık kaynakları ile çekilmiş incir görüntüleri ile oluşturulan veri setleri üzerinde transfer öğrenme modelleriyle elde edilen öznitelik vektörleri kullanılarak sınıflandırma çalışmaları yapılmaktadır. 365nm ışık kaynağı altında alınan görüntülerde MobileNetV2, ResNet101V2 ve InceptionResNetV2 modelleri kullanılarak çıkarılan öznitelik vektörlerinin SVM ile sınıflandırılması sonucunda kontamine incirler %100, kontamine olmayan incirler ise %92,3 doğrulukla tespit edilmektedir. Yapılan çalışmalar, transfer öğrenme yaklaşımlarının aflatoksinle kontamine olmuş incirleri otomatik, hızlı ve etkili bir şekilde tespit etmek için kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Aflatoksin Tespiti, Evrişimli Sinir Ağları, Gıda Güvenliği, Spektroskopik Yöntemler, Transfer Öğrenme.

NON-INVASIVE REAL-TIME DETECTION OF AFLATOXIN CONTAMINATED DRIED FIGS WITH DEEP TRANSFER LEARNING APPROACHES

ABSTRACT

Aflatoxins are the most dangerous mycotoxin produced by *Aspergillus* fungal species and can cause various health problems, including liver cancer, in humans. Figs and many agricultural products are affected by aflatoxins. It is crucial to detect it before consumption since it is impossible to clean aflatoxin from contaminated foods. Chromatographic methods are considered the gold standard for aflatoxin detection, but these methods are pretty expensive, time-consuming, and destructive. Therefore, aflatoxin detection started with computer vision-based systems created using spectroscopic methods. The thesis study was carried out in two stages. In the first stage, balanced and original data sets were created from the fig images obtained under light sources of different wavelengths by using dried fig samples obtained from the fig production facilities in the Aegean Region. In the second stage, studies were carried out to create a fast, non-invasive and successful aflatoxin detection system with a computer vision-based system, and for this purpose, two different methods have been proposed. The first proposed method is to develop a system that automatically detects the Bright Greenish Yellow Fluorescent (BGYF) control currently used in fig production facilities. With the fine-tuning approach in deep transfer learning, an accuracy of 97.50% is obtained using the DenseNet169 model. In the second proposed method, classification studies are carried out using feature vectors obtained by transfer learning models on the data sets created with fig images taken with light sources of different wavelengths. Contaminated figs are detected with 100% accuracy and uncontaminated figs with 92.3% accuracy due to the classification with SVM of the feature vectors extracted using the MobileNetV2, ResNet101V2, and InceptionResNetV2 models in the images taken under a 365 nm light source. This study shows that transfer learning approaches can automatically, rapidly, and effectively detect aflatoxin-contaminated figs.

Keywords: Aflatoxin Detection, Convolutional Neural Network, Food Safety, Spectroscopic Methods, Transfer Learning.

1. GİRİŞ

Mikotoksinler, *Aspergillus*, *Fusarium*, *Penicillium*, *Claviceps* ve *Alternaria* türü mantarlar tarafından üretilen toksik bileşikler olup, hem hayvan yemlerinde hem de insanlar tarafından tüketilen gıda ürünlerinde önemli bir kontaminasyon riski oluşturmaktadırlar (Cinar ve Onbaşı, 2020; Gimeno ve Martins, 2006). Tüketilen mikotoksinli ürünler, hem insanlarda hem de hayvanlarda alerjik reaksiyonlardan ölüme kadar değişen sağlık riskleri oluşturmaktadır (Haque vd., 2020). Günümüzde 100'den fazla mantar türü tarafından üretilen yaklaşık 400 çeşit mikotoksin tespit edilmiştir (Janik vd., 2020). İnsan sağlığı, tarım ve hayvancılık açısından en zehirli mikotoksin çeşitleri, aflatoksinler, okratoksinler, trikotesenler, zeranol, fumonisinler, patulin ve sitrinin olarak sıralanabilir (Gürhayta ve Çağındı, 2016).

Mikotoksin kontaminasyonu küresel bir sorundur ve hasat öncesi ve esnasında, kurutma, paketlenme ve depolama aşamalarının herhangi birinde gerçekleşebildiği için, üretim teknolojileri ve depolama koşulları önem arz etmektedir. Mikotoksijenik küf gelişimi, mikotoksin üretimi için gereklidir ancak küfün varlığı toksin üretiminin olacağını göstermez. Mikotoksin salgılanması için özel koşullar gereklidir. Sıcaklık, su aktivitesi, pH, oksijen ve substrat bileşimi mikotoksin üretimini etkiler (Adeyeye, 2016; Kumar vd., 2017). Toprak ve hava, bazı küf türleri için doğal ortamlardır ve bu da mikotoksin kontaminasyonuna karşı korumayı sorunlu hale getirir (Valencia-Quintana vd., 2020). Gıdaların kurutulması saklanması eski çağlardan beri kullanılan önemli bir saklama yöntemidir. Kurutma işlemi esnasında çoğunlukla güneşten faydalanılmakla beraber kurutma fırınları gibi yapay kurutma teknikleri de geliştirilmiştir. Toplama ve kurutma esnasında ürünlerin toprakla temas etmesi, yüksek nem oranı ve böcek istilası mikotoksin riskini artırır. Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) raporuna göre, dünya mahsulünün %25'i mikotoksinlerden etkilenmekte ve bu da ekonomik kayıplara neden olmaktadır (Janik vd., 2020).

1.1. Aflatoksin

Bilinen mikotoksinler arasında aflatoksinler en yüksek akut ve kronik toksisiteye sahip olduğu için insan sağlığı açısından en tehlikeli olanlardır (Valencia-Quintana vd., 2020).

Aflatoksinler, *A. flavus* ve *A. parasiticus* gibi *Aspergillus* mantar türleri tarafından üretilen bir mikotoksin türüdür. Bilinen 20'den fazla aflatoksin türü vardır, ancak toksik etki derecesi en fazla olan 4 aflatoksin türü, aflatoksin B₁ (AFB₁), aflatoksin B₂ (AFB₂), aflatoksin G₁ (AFG₁) ve aflatoksin G₂ (AFG₂)'dir. AFB₁ ve AFB₂ ultraviyole ışık altında mavi floresans verirken, AFG₁ ve AFG₂ yeşil floresans verdiği bildirilmiştir (Kumar vd., 2017). AFB₁ en zehirli aflatoksin türü olup güçlü bir kanserojendir ve birçok hayvan türünde ve insanda olumsuz sağlık etkilerine sebep olmaktadır (Adeyeye, 2016). Aflatoksinler gıdalara bulaştığında normal pişirme, kavurma, çekirme (ekstrüzyon) işlemleriyle yok edilemezler (Gürhayta ve Çağındı, 2016; Kumar vd., 2017).

Aflatoksinler, bu toksik maddelere maruz kalmış insanlarda karaciğer kanserine sebep olmakta, bağışıklık sistemine zarar vermekte, tümör oluşumunu tetiklemekte ve enfeksiyon direncini düşürücü etki göstermektedir (Kumar vd., 2017; Schrenk vd., 2020). Ayrıca, aflatoksin kontaminasyonu mahsul ve hayvansal üretimi olumsuz etkileyerek yalnızca doğal kaynak israfına değil, aynı zamanda önemli ekonomik kayıplara da neden olmaktadır (Mitchell vd., 2016). Bu etkileri sebebiyle, bir takım ülkeler ve uluslararası kuruluşlar, gıda ve yemlerdeki aflatoksin kontaminasyonunu kontrol etmek ve ayrıca kontamine ürünlerin ticaretini yasaklamak için katı düzenlemeler oluşturmuştur. İnsan tüketimi için belirlenen güvenli aflatoksin sınırı 4–30 µg/kg (ppb) aralığındadır (Udomkun vd., 2017). Çeşitli ülkeler ve uluslararası kuruluşlar, aflatoksin bulaşmış ürünleri kontrol etmek ve ticaretini yasaklamak için katı düzenlemeler getirmiştir. Gıda maddesine göre farklılık göstermekle birlikte, Avrupa Birliği kabul edilebilir maksimum aflatoksin miktarını 4 µg/kg (ppb) olarak belirlerken, ABD 20 µg/kg (ppb) olarak belirlemiştir (European Commission-EC, 2010; Shabeer vd., 2022). Doğrudan insan tüketimine sunulan veya gıda bileşeni olarak kullanılan bazı gıda ürünlerinde Türk Gıda Kodeksi'ne ve Avrupa Birliği standartlarına göre kabul edilen aflatoksin üst seviyeleri Tablo 1.1'de verilmiştir.

Tahıllar ve tahıl ürünleri, fındık, yer fıstığı, badem, pul biber, kuru incir, kuru üzüm ve diğer kurutulmuş meyveler, hindistan cevizi, mısır, kakao, patates, mercimek, muz, şarap, süt ve süt ürünleri gibi gıda maddeleri aflatoksin açısından riskli grup içerisinde yer almaktadır (Zain, 2011).

Tablo 1.1. Bazı gıda ürünleri için aflatoksin yasal limitleri

Gıda Ürünü	Kabul edilebilir üst limit (Türkiye) ($\mu\text{g} / \text{kg}$) Toplam Aflatoksin		Kabul edilebilir üst limit (Avrupa Birliği) ($\mu\text{g} / \text{kg}$) Toplam Aflatoksin	
	AFB ₁	(AFB ₁ +AFB ₂ + AFG ₁ +AFG ₂)	AFB ₁	(AFB ₁ +AFB ₂ + AFG ₁ +AFG ₂)
Kuru incir	8	10	2	4
Kurutulmuş meyveler (Kuru incir hariç)	5	10	2	4
Antepfıstığı, badem ve kayısı çekirdeği	8	10	8	10
Fındık	5	10	5	10
Yerfıstığı, diğer yağlı tohumlar ve bunların işlenmiş ürünleri	5	10	2	4
Sert kabuklu meyveler ve bunların işlenmiş ürünleri	5	10	2	4
Mısır ve pirinç	5	10	5	10
Baharat	5	10	5	10
Tahıllar, tahıllardan elde edilen ürünler ve bunların işlenmiş ürünleri	2	4	2	4
Tahıl ve tahıl ürünlerini içeren bebek gıdaları	0,10	-	0,10	-

1.2. İncir

İncir, insanlık tarihi kadar eski çağlara dayanan ve kutsal kitaplarda kendisinden bahsedilen en önemli kültür meyvesidir (Anaç, 2012). Toprak yapısı, iklim koşulları ve coğrafi koşullar açısından Türkiye incirin anavatanı olup, buradan diğer ülkelere yayılmıştır. Subtropikal iklim kuşağı meyvesi olan incirin kendine has yetiştirilme ve kurutma şartları olması sebebiyle yetiştiği bölgeler sınırlı kalmaktadır. Yerli ve yabancı birçok uzman incir yetiştiriciliği açısından en ideal ekolojik koşullara sahip yöre olarak Büyük Menderes ve Küçük Menderes Havzalarını işaret etmektedir. İşte bu sebeple incir, Ege Bölgesi ve ülkemiz ekonomisi için en önemli tarımsal gelir kaynaklarından biridir.

Türkiye’de yetişen incirler arasında “Sarılop” adı verilen incir çeşidi, tadı, büyüklüğü, açık renkli ve yumuşak kabuklu olması sebebiyle dünyada kurutmaya en uygun türlerden birisidir. Toplanan taze incirler güneşin altında 2–4 gün bekletilerek kurutulur. Kurutma işlemi incirin depolama süresini ve besin değerini artırmaktadır. İncirler taze durumda iken şeker oranı yaklaşık %12 iken, kurutulduktan sonra %50’ye yükselmektedir. Ülkemizde üretilen incirin % 30’u taze olarak iç pazarda, % 70’i kuru incir olarak dış ve

iç pazarda tüketilmektedir. Dünyanın en büyük incir üreticisi olmamıza rağmen, kuru incirin ülkemizdeki kişi başına yıllık tüketimi 200-250 gram civarındadır.

İncirin insan sağlığı açısından birçok faydası bulunmaktadır. Lif açısından zengin olduğu için sindirimi kolaylaştırır, kilo kontrolü sağlar ve obezite tedavisinde kullanılır. Kan basıncını dengeler, kalp ve damar hastalıklarına yakalanma riskini düşürür. Ayrıca kemik ve diş sağlığını olumlu etkileyip meme kanseri oluşumunu önleyici etkiye sahiptir. Kuru incir vitamin ve mineraller bakımından mükemmel bir besin kaynağıdır. Sarılop çeşidi kuru incire ait besin değerleri Tablo 1.2’de verilmiştir.

Tablo 1.2. Sarılop çeşidi kuru incirin besin değeri içeriği (Konak, 2017)

Bileşen İsmi	Birimi	İncirde Bulunan Değer
Enerji	kcal	303
Su	g	20,12
Kül	g	0,59
Protein	g	3,12
Azot	g	0,5
Yağ	g	0,6
Karbonhidrat	g	66,8
Diyet lif	g	12,4
Glukoz	g	34,47
Fruktoz	g	32,5
Tuz	mg	20
Demir	mg	0,97
Fosfor	mg	34
Kalsiyum	mg	97
Magnezyum	mg	61
Potasyum	mg	970
Sodyum	mg	8
Çinko	mg	0,24

Türkiye, dünyanın en büyük ve kaliteli incir üreticisi olup, Tarım Orman Bakanlığı’nın 2022 Temmuz ayı Tarım Ürünleri Piyasaları incir raporuna göre dünya taze incir üretiminin % 25,3’ünü, dünya kuru incir üretiminin % 58’ini gerçekleştirmektedir.

Türkiye dünya incir üretiminde ilk sırada olup yaş ve kuru incirde en büyük ihracatçı konumundadır. Tablo 1.3’de görüldüğü üzere Türkiye 2021 yılında yapılan dünya incir ihracatından %44,4 ile en yüksek payı (331,4 milyon dolar) elde etmiştir.

Tablo 1.3. 2021 yılı dünya incir ihracat rakamları

Ülke	İhracat Payı (%)	İhracat Rakamı (Milyon dolar)
Türkiye	44,4	331,4
Afganistan	22,4	167,3
Avusturya	4,7	35
İspanya	3,4	25,2
İran	2,1	15,4
Diğer	23	171,5

1.3. İncirde Aflatoksin Oluşumu

İncirin pH değerinin (4,7-5,0) aflatoksin üretimine uygun olması ve tek bir incirdeki aflatoksin kontaminasyonunun temas eden diğer incirlere de bulaşabilmesi inciri aflatoksin açısından yüksek riskli bir ürün haline getirmektedir. İncirde aflatoksin kontaminasyonu tarlada olgunlaşma evresinden başlayarak, hasatta, kurutma aşamasında ve ağırlıklı olarak da depolanma evresinde meydana gelir. Hasar gören incirler küf misellerinin iç tarafa geçişine ve aflatoksin oluşturmaya olanak sağlar.

İncire aflatoksin üreten mantarın bulaşması aflatoksin oluşumu için yeterli değildir. Mantarın varlığının yanında, mantarın gelişmesi ve aflatoksin üretebilmesi için uygun çevre koşullarının (oksijen, sıcaklık, nem) ve su aktivitesinin oluşması gerekir. Yeterince oksijen bulunmayan ortamlarda küf gelişemeyeceği için toksin de oluşmaz. 13-40 °C arası sıcaklık (optimum gelişme sıcaklığı 25-35°C), 0.95 a_w su aktivitesi ve %85 gibi yüksek bağıl nem koşulları *Aspergillus* cinsi küflerin gelişerek aflatoksin oluşturabilmesi için uygun şartlardır.

1.4. İncirde Aflatoksinin İlk Ortaya Çıkışı

İncirde aflatoksin sorunu ilk olarak 1972 yılında Danimarka’ya yapılan kuru incir ihracatında ortaya çıkmış ve yapılan incelemede 938 ppb aflatoksin tespit edilmiştir. 1973-1974 yıllarında ABD’ye gönderilen kuru incirlerde yapılan analizler sonucunda 38

parti ürününden aflatoksin tespit edilen 3 parti ürün geri gönderilmiştir. 1986 ve 1987 yıllarında İsviçre ve Almanya'ya yapılan incir ihracatında limitlerin üzerinde aflatoksin tespit edilerek ürünlerin geri gönderilmesi sonrası aflatoksin konusu daha fazla önem kazanmıştır (Karaca ve Nas, 2004).

Kasım 1988 ve Ocak 1989 tarihleri arasında İngiltere'ye ihraç edilen kuru incir ve incir ezmesi örneklerinin % 24'ünde toplam aflatoksin seviyesi limit değerlerin üzerinde çıkmış ve 14 sevkiyatın İngiltere'ye girişine izin verilmemiştir (Sharman vd., 1991).

1.5. Problem Tanımı ve Motivasyon

Aflatoksin hem insanlarda hem de hayvanlarda çok çeşitli sağlık sorunlarına neden olabilmektedir. Kirlenmiş kuru incirden aflatoksini temizlemek mümkün değildir. Bu nedenle kontamine incirlerin doğru ve hızlı bir şekilde tespiti ve tüketiminin önlenmesi insan sağlığı açısından büyük önem taşımaktadır.

Ülkemiz ekonomisi açısından önemli bir gelir kaynağı olan incirdeki en önemli sorun aflatoksin oluşumudur. İhracat aşamasında geri gönderilen incirlerin büyük bir kısmı, yapılan kontroller sonucunda aflatoksin tespit edilmesi kaynaklıdır. Bu durum, ihracatçı firmalara ekonomik olarak zarar vermesinin yanı sıra, Türk kuru incirinin dış pazarda itibar kaybetmesine neden olmaktadır.

Yurt dışına gönderilen incirler dikkatli bir şekilde aflatoksin kontrolünden geçirilirken, yurt içinde incir pazarlayan birçok kuruluş, herhangi bir kontrol yapmadan ürünü iç pazara sürmektedir (Ticaret Bakanlığı, 2020). Ülkemizde 1993-1997 yılları arasında Tarım ve Köy İşleri Bakanlığı tarafından yapılan iki farklı çalışmada piyasadan toplanan kuru incir örnekleri üzerinde yapılan incelemede örneklerin %9,8 ve %9,2'sinin aflatoksin kontaminasyonu sınır değerlerini aştığı tespit edilmiştir (Karaca, 2005).

Aflatoksin tespitinde kullanılan ve altın standart olarak kabul edilen mevcut kromatografik yöntemler pahalı, zaman alıcı ve analiz sonrası numunenin tekrar kullanımını engeller. Bu nedenle, gerçek zamanlı, hızlı ve tahribatsız tespit sistemleri oluşturmaya ihtiyaç duyulmaktadır. İncir üretim tesislerinde aflatoksinli incirler, uzman çalışanlar tarafından ultraviyole (UV) ışık altında parlak yeşilimsi sarı floresans (Bright-Greenish-Yellow Fluorescence, BGYF) yöntemi kullanılarak elle ayıklanmaktadır.

Bununla birlikte, doğru ve güvenli manuel ayıklama çalışanların uzmanlığına bağlıdır ve UV radyasyonuna uzun süre maruz kalma, çalışanların cilt kanserine ve göz rahatsızlıklarına neden olabilir.

Bu tez çalışmasında, aflatoksin bulaşmış incirlerin insan sağlığına zarar vermeyecek şekilde tespiti için, uzman çalışanlar kadar etkili ve sağlam yöntemlerin geliştirilmesini sağlayacak çalışmalar yürütülmüştür. Çalışmamızın temel amacı, incir üretim tesisi gibi gerçek dünya ortamında aflatoksinli incirlerin otomatik, tahribatsız, çevrimiçi ve hızlı bir şekilde tespit edilerek ayıklanmasını sağlayacak yapay zeka tabanlı yöntemde katkıda bulunmaktır. Kuru incir için aflatoksinle kontamine olmuş halka açık bir veri seti yoktur. Bu çalışma için Türkiye'nin Ege Bölgesi'ndeki üretim tesislerinden kuru incir örnekleri toplanmış ve farklı dalga boylarındaki ışık kaynakları altında alınan incir görüntüleri ve HPLC referans cihaz sonuçları kullanılarak özgün ve yeni veri setleri oluşturulmuştur. Bu yeni veri setleri üzerinde farklı transfer öğrenme yaklaşımları kullanılarak sınıflandırma çalışmaları yapılmış ve en etkili yöntemler değerlendirilmiştir. Farklı dalga boylarındaki ışık kaynaklarının aflatoksin tespitindeki etkinliği araştırılmıştır. Literatürdeki mevcut çalışmalardan farklı olarak kuru incirde aflatoksin tespiti için derin transfer öğrenme yaklaşımları kullanılarak yapılan ilk ve daha başarılı çalışmadır. Tez kapsamında ayrıca, mevcut durumda incir üretim tesislerinde aflatoksinli incirlerin ayıklanması için kullanılmakta olan BGYF yönteminin, aflatoksin tespitindeki etkinliğini araştırmak için çalışma yapılmıştır. Aflatoksinle kontamine olmuş kuru incir numunelerinin tahribatsız tespiti için yeni, etkili ve sağlam yöntemler sunulmuştur.

2. AFLATOKSİN TESPİT YÖNTEMLERİ

2.1. Kromatografik Yöntemler

Aflatoksinlerin gıda ve yemlerde tespit edilebilmesi için kullanılan hassas ve güvenli birçok yöntem bulunmaktadır. Mevcut teknikler arasında; ince tabaka kromatografisi (Thin-Layer Chromatography, TLC), sıvı kromatografi-tandem kütle spektroskopisi (Liquid Chromatography-Tandem Mass Spectrometry, LC-MS/MS), yüksek performanslı sıvı kromatografisi (High-Performance Liquid Chromatography, HPLC), enzime bağlı immünosorbent testi (Enzyme-Linked ImmunoSorbent Assay, ELISA) vb. yöntemler bulunmaktadır (Chavez vd., 2020; Nazhand vd., 2020; Schrenk vd., 2020; Wacoo vd., 2014; Yao vd., 2015). Tarımsal ve gıda ürünlerinde aflatoksin tespiti için Analitik Kimyagerler Birliği (Association of Official Agricultural Chemists, AOAC), Avrupa Standardizasyon Komitesi (European Committee for Standardization, CEN) ve Uluslararası Standardizasyon Örgütü (International Organization for Standardization, ISO) tarafından onaylanan mevcut analitik yöntemler esas olarak bu metotlara dayanmaktadır (Mahato vd., 2019; Tao vd., 2018).

Aflatoksin kontaminasyonun belirlenmesine yönelik TLC ve HPLC gibi kromatografik yöntemler altın standart olarak kabul edilir ve bu nedenle yaygın olarak kullanılan teknikler olmakla birlikte, iyi donanımlı bir laboratuvar ve personel gerektirmektedir (Cheng vd., 2019; Tao vd., 2018; Wacoo vd., 2014). Bu yöntemler pahalı, zaman alıcı ve üretim bantlarında uygulanamayacağı için çevrimdışıdır. Ayrıca numunenin parçalanmasını gerektirdiği için, ürün analiz sonrası satışı veya tüketimi yapılamayacak hale gelmektedir.

2.2. Spektroskopik Yöntemler

Spektroskopi, bir maddedeki atom, molekül veya iyonların, ışık ile uyarılması neticesinde bir enerji düzeyinden başka bir enerji düzeyine geçişleri sırasında absorbe edilen veya yayılan elektromanyetik ışımanın ölçülmesi ve yorumlanmasıdır. Böylece madde ile ışık arasındaki etkileşimin boyutları incelenerek, maddenin özellikleri tam olarak belirlenebilir. Optik tabanlı spektroskopik yöntemler aflatoksin tespitinde, numune hazırlamaya çok az zaman duyulması ya da hiç gerektirmemeleri, hızlı sonuç vermeleri

ve üretim bantlarında uygulanabilirliği nedeniyle geleneksel yöntemlere alternatif olarak dikkat çekmektedir.

2.2.1. Floresans Spektroskopisi ve BGYF Metodu


Floresans, florofor olarak adlandırılan bir floresan molekül veya alt yapının ultraviyole (UV) veya görünür (Vis) ışığını absorbe etmesinin ardından ışık yayılmasıdır. Florofor, belirli bir dalga boyunda ışık şeklinde enerji emer ve daha uzun bir dalga boyunda ışık salımı şeklinde enerjiyi serbest bırakır (Sauer vd., 2011). Floresans Spektroskopisi (FS)'nin gıda analizindeki uygulamaları son yirmi yılda önemli ölçüde artmıştır. Floresans emisyonu esnasında oluşan düşük sinyal seviyesi, FS'nin aflatoksin tespitinde uygulama zorluğunu artırmaktadır (Zhang vd., 2012).

Aflatoksin ile kontamine olmuş bazı gıda türlerinde, aflatoksin oluşumuna sebep olan küf ve bakteriler tarafından sentezlenen kojik asit ve peroksidaz enzimlerinin etkisiyle UV ışık altında BGYF özellik tespit edilmiştir. BGYF ve *Aspergillus* mantarı arasındaki ilişki ilk olarak (Marsh vd., 1969) tarafından bildirilmiştir. (Steiner vd., 1988), BGYF'nin incirde aflatoksin kontaminasyonu oluşumu ile güçlü bir şekilde ilişkili olduğuna dair kanıtları ayrıntılı olarak sunmuştur. Bazen kojik asitten dolayı BGYF ışıması görüldüğü halde gerçekte gıdada aflatoksin olmayabilir veya aflatoksin mevcut olmasına rağmen peroksidaz enziminin olmaması BGYF ışımasının görülmesini engelleyebilir. (Doster ve Michailides, 1998), aflatoksin ile kontamine olmuş incir örneklerinin, incirin cinsine ve üretim yerine bağlı olarak %7 ile %59 arasında değişen oranlarda BGYF ışıması yapmadığını belirtmişlerdir. Fakat aralarındaki güçlü korelasyondan dolayı BGYF ışıması, aflatoksin içeren (veya içerme olasılığı yüksek olan) ürünlerin tespitinde varsayımsal bir test yöntemi olarak kullanılmaktadır (Hruska vd., 2017). Şekil 2.1'de UV ışık altında BGYF ışıması yayan (BGYF(+)) ve yaymayan (BGYF(-)) incir örnekleri verilmiştir.

2.2.2. Hiperspektral Görüntüleme

Hiperspektral görüntüleme (Hyperspectral Imaging, HSI), test edilen örneğin hem spektral hem de uzaysal bilgisini aynı anda sağlamak için, spektroskopik ve görüntüleme tekniklerini birleştiren bir yöntemdir (Mishra, 2022). HSI ile elektromanyetik spektrum

bandının hem görünür hem de kızılötesi bölgesinde birçok dalga boyunda görüntüler elde edilebilmektedir. Bu sebeple daha az sayıda dalga boyunda görüntüler elde edebilen multispektral görüntülemeye (Multispectral Imaging, MSI) göre daha fazla ve anlamlı özellikler içermektedir. Son zamanlarda, HSI tekniği hızlı ve tahribatsız bir yöntem olarak gıda kalitesi ve güvenliğinin değerlendirilmesi için giderek daha önemli hale gelmekte ve yapılan çalışmalar aflatoksin kontaminasyonun hızlı tespitinde etkinliğini göstermektedir (Chakraborty vd., 2020; Han ve Gao, 2019; Zhongzhi ve Limiao, 2020).



Şekil 2.1. Kuru incir örneklerinin UV ışık altındaki görünüşleri

2.2.3. Yakın Kızılötesi Spektroskopisi

Aflatoksin analizinde faydalı bir başka spektroskopik yöntem de yakın kızılötesi spektroskopisidir (Near-Infrared Spectroscopy, NIRS). NIRS, kızılötesi radyasyonlarla (750 nm - 2500 nm) ışınlama üzerine, nesnede oluşan moleküler titreşimlerdeki değişikliğe dayanır (Chelladurai ve Jayas, 2014). Atom boyutu, bağ uzunluğu ve bağ kuvveti molekülden moleküle büyük ölçüde değiştiğinden, belirli bir bağın kızılötesi radyasyonu emme hızı bağdan bağa ve titreşim modunda farklı olacaktır. Hiçbir iki organik bileşik aynı kızılötesi spektruma sahip değildir ve bu nedenle saf bileşikler, kızılötesi spektrumlarının incelenmesi ile tanımlanabilir. NIRS tekniklerindeki gelişmeler, tarım ve gıda ürünlerinin analizleri için de kullanılmasını sağlamıştır. Mikotoksinler gibi nispeten küçük molekülleri NIRS yöntemiyle tespit etmek, mikotoksinlerin kızılötesi ışık altında yaydığı sinyalin zayıflığından dolayı bir takım

zorluklar oluşturmaktadır. Dezavantajlarına rağmen yapılan çalışmalar yakın kızılötesi bölgenin aflatoksin içeren gıda ürünlerini tespit edebildiğini göstermiştir (Gunes, Kalkan, vd., 2013; Tripathi ve Mishra, 2009).

2.2.4. Raman Spektroskopisi

Raman spektroskopisi, bir numunenin monokromatik (tek bir dalga boyuna sahip) ışıktan oluşan güçlü bir ışık kaynağıyla aydınlatılmasıyla saçılan ışının belirli bir açıdan ölçümü prensibine dayanır (Mishra, 2022). Optik teknolojilerindeki gelişmeler, Raman spektroskopisini, gıda teknolojilerindeki farklı sorunlara çözüm sağlamak için kullanılan bir araç haline getirmektedir. Numunede oluşabilecek floresans ışımadan dolayı Raman spektrumunu gizleyebilmesi veya yüksek enerjili lazer ışınlarının numuneyi ısıtarak bozulmasına sebep olması gibi bir takım dezavantajları bulunmaktadır (Mishra, 2022). Yapılan bazı çalışmalar, farklı Raman spektroskopisi yöntemlerinin mikotoksin tespitinde tercih edilen bir araç haline geldiğini doğrulamaktadır (Lee vd., 2014).

3. İLGİLİ ÇALIŞMALAR

Aflatoksin tespiti konusunda yapılan araştırmalar, veri analizi ile birlikte tespit veya sınıflandırma yöntemlerinin, kontamine olan numuneleri tanımlayan algılama modellerinin oluşturabildiğini kanıtlamıştır. Çeşitli gıda ve yem türlerindeki aflatoksin kontaminasyonu, farklı optik teknikler kullanılarak tespit edilebilmektedir. Örneğin, aflatoksinle kirlenmiş mısırın tespiti için HSI, NIRS ve Raman optik yöntemleri ile çalışmalar yapılmıştır (Chakraborty vd., 2020; Cheng vd., 2019; Gao vd., 2021; Lee vd., 2014). Aflatoksin bulaşmış incirleri tespit etmek için (Kalkan vd., 2014; Kılıç ve İner, 2022; Ö. Özlüoymak, 2014) BGYF yöntemini kullanırken, (Gunes, Kalkan, vd., 2013) NIRS yöntemini kullanmışlardır. Fındık, kaju, mısır, yer fıstığı ve Antep fıstığında aflatoksin tespiti için HSI, NIRS, FS ve Raman yöntemlerinin kullanıldığı görülmektedir. Aflatoksin bulaşmış ürünler, kullanılan optik yöntemden elde edilen veriler kullanılarak sınıflandırılır. HSI, MSI ve BGYF gibi yöntemler görüntü üretirken, NIRS, FS ve Raman spektral veriler üretir. (Zhongzhi ve Limiao, 2020) HSI yöntemiyle elde ettiği yer fıstığı görüntü verileri üzerinde SVM kullanarak %96 sınıflandırma başarısı elde etmiştir. (Cheng vd., 2019), kontamine mısır çekirdeklerini analiz etmek için NIRS yöntemiyle her bir numune için reflektans ve floresans spektrumlarını toplamış ve toplanan bu verilerin rastgele orman sınıflandırıcısı ile eğitilmesi sonucu oluşan model ile %95'lik bir doğruluk oranıyla kontamine mısır çekirdeklerinin tespitini yapmışlardır.

Sınıflandırma çalışmalarının dışında kantitatif ölçüm için spektroskopik yöntemler kullanılarak yapılan tahmin çalışmaları da bulunmaktadır. (H. Zhu vd., 2022), yer fıstığında kantitatif AFB₁ tespiti için bir alt piksel modeli uygulayarak derin öğrenmeye dayalı bir regresyon yöntemi önermişler ve sonuç olarak 0,8898 R², 0,0138'lik RMSE değeri elde etmişlerdir. (Deng vd., 2022), yemeklik yağda AFB₁ kontaminasyon derecesini tespit edebilmek için Raman spektroskopisi ile RNN modelini birleştirerek 0,92 R² değeriyle doğru tahmin yapabilmışlardır. (Zhongzhi ve Limiao, 2020), 365 nm ışık altında bir hiperspektral görüntüleme sistemi kullanarak elde ettiği yer fıstığı görüntü verileri üzerinde Destek Vektör Makinesi (Support Vector Machine, SVM) kullanarak yaptıkları regresyon çalışmasında 0,0223 RMSE ve 0,9785 R² değeri elde etmişlerdir.

Doğrudan aflatoksin tespiti yerine, aflatoksin üreten mantarların tespit edildiği çalışmalar da bulunmaktadır. (Ziyaee vd., 2021), aflatoksin üreten mantarla enfekte olmuş yer fıstığı

tohumlarını tespit etmek ve ayırmak için yapay sinir ağlarını kullanarak yaptıkları çalışmada, mantar enfeksiyonundan 72 saat sonra yer fıstığı üzerindeki mantar gelişimini %99,7 doğrulukla tespit ettiklerini bildirmişlerdir. (Durmuş vd., 2014) tarafından mantar bulaşmış kuru incir numuneleri üzerinde yapılan bir çalışmada ise NIRS yöntemi kullanılarak elde edilen spektral veriler doğrusal diskriminant sınıflayıcı (Linear Discriminant Classifier, LDC) ile sınıflandırılarak, küflü incirler %100 başarıyla tespit edilmiştir. Fakat aynı çalışmada küflü incirlerin yaklaşık %7'sinin aflatoksin içermediği, küflü olmayan incirlerin %4'ünün aflatoksin içerdiği bildirilmiştir. Aflatoksin üreten mantarın bulaşması aflatoksin oluşumu için yeterli olmadığından, mantar tespiti için elde edilen yüksek başarı oranları aflatoksin tespiti için geçerli olmayacaktır.

Farklı gıda türlerinde aflatoksin tespiti için mevcut sınıflandırma çalışmalarının bir özeti Tablo 3.1'de verilmiştir. Tabloda çalışmanın hangi tarımsal ürün için yapıldığı, sınıflandırma çalışmaları için ne kadar örnek ürün kullanıldığı, hangi aflatoksin türünün tespiti için yapıldığı (AFB₁, AFB₂ ve toplam AF), örneklerdeki aflatoksin kontaminasyonunun ne şekilde sağlandığı, optik inceleme için hangi optik yöntemin hangi optik aygıtlar kullanılarak hangi spektral bölgede yapıldığı, inceleme neticesinde elde edilen anahtar spektral bölgenin ne olduğu, veri setinin oluşturulması ve etiketleme için örneklerin hangi yöntem kullanılarak kantitatif olarak ölçüldüğü, hangi veri ön işleme, boyut azaltma ve sınıflandırma yöntemleri kullanılarak sınıflandırma işleminin yapıldığı, sınıflandırmanın hangi eşik değerlere göre yapıldığı ve sınıflandırma sonucunda elde edilen başarı oranları verilmiştir.

Tablo 3.1. Farklı gıda türlerinde optik yöntemler ile sınıflandırma yapılarak aflatoksin tespitini bildiren araştırma çalışmalarının özeti

Ürün	Veri Sayısı	AF Türü	Kontamine Şekli	Kullanılan Aygıtlar	Optik Yöntem	Spektral Aralık	Anahtar Spektral Bölge	Referans Yöntem	Veri Önileme, Boyut Azaltma	Sınıflandırma Yöntemi	Kullanılan Eşik Değerleri ve Doğruluk	Ref.
Mısır	504	AF	Mantar Aşılama	Kamera, spektrograf, UVA ışık kaynağı	HSI	400-600 nm	469, 480 nm	VICAM AflaTest	ROI	SAM	20 ppb için %86 100 ppb için %88	(Yao, Hruška, Kincaid, Ononye, vd., 2010)
Fındık, (Fındık), Pul biber (Fındık), Doğal (Pul Biber)	285	AF	Mantar Aşılama (Fındık), Doğal (Pul Biber)	Kamera, optik filtre UVA ışık kaynağı	MSI	400-600 nm	400,410,460,470 nm (fındık) 480,490nm (pul biber)	Kimyasal Analiz	LDB	PCA, LDA	Eşik : 4ppb (Fındık), 10ppb (Pul Biber) Doğruluk : %92 (Fındık), %79 (Pul biber)	(Kalkan vd., 2011)
Pul Biber	53	AF	Doğal	Kamera, optik filtre UVA ve Halojen ışık kaynağı	HSI	400-720 nm	400,410,490, 500,540,580, 620,650,660 nm	HPLC	Medyan filtre, PCA, MLP	ANN	Eşik : 10 ppb Doğruluk : %91	(Atas vd., 2011)
Pul biber	53	AF	Doğal	Kamera, optik filtre, UVA ve Halojen ışık kaynağı	HSI	400-720 nm	400,420,540,550, 560,590,640,650 nm	HPLC	Fisher discrimination power, Medyan filtreleme, PCA	MLP	Eşik : 10 ppb Doğruluk : %88	(Ataş vd., 2012)
Mısır	100	AF	Mantar Aşılama	Kamera, Spektrograf	HSI	400-600 nm	460-490 nm	VICAM AflaTest	ROI	SVM	20 ppb için %88 100 ppb için %91	(Yao vd., 2012)
İncir	569	AF	Doğal	Kamera, UVA Işık Kaynağı	FS/BGYF	365	365 nm	BGYF Işıması	Görüntü maskeleme	SVM	Doğruluk : %89	(Gunes, Durmus, vd., 2013)
Mısır	504	AF	Mantar Aşılama	Kamera, Spektrograf, Optik filtre, UVA ışık kaynağı	HSI	400-600 nm		VICAM AflaTest		SVM	Eşikler : 0,1,20,100ppb Doğruluk : %84	(Samiappan vd., 2013)
İncir	179	AF	Doğal	FT-NIR Spektrometre, Halojen ışık kaynağı	NIRS	780-2500 nm	1970-2180, 2500 nm	BGYF Işıması	Mahalanobis mesafe sınıflandırıcısı	LDC	Doğruluk : %90	(Gunes, Kalkan, vd., 2013)
Mısır	179	AF	Mantar Aşılama	Kamera, Spektrograf, Optik filtre, UVA ve Halojen ışık kaynağı	HSI	400-700 nm	450-500 nm	VICAM AflaTest	LDA	DA	20 ppb için %79 100 ppb için %94	(Yao vd., 2013)
Yer Fıstığı 168 ve Kaju (Kaju)	184	AF	AF çözeltisi Aşılama	Kamera, Optik filtre, UVA ışık kaynağı	MSI	410-600 nm	480-520nm (Fıstık) 440-600nm (Kaju)	HPLC	Görüntü işleme	FSP-DF DA	Eşikler : 20, 100 ppb Doğruluk : Fıstık için %92 Kaju için %82	(Lunadei vd., 2013)
İncir	192	AF	Doğal	Kamera, optik filtre UVA ışık kaynağı	MSI	410-720 nm	475-575 nm	HPLC	Görüntü maskeleme	SVC	Eşik : 4 ppb Doğruluk : %88	(Kalkan vd., 2014)
Mısır	150	AFB ₁	AF çözeltisi Aşılama	Kamera, optik filtre Halojen ışık kaynağı	HSI	1000-2500 nm	1459,1706,1729, 1934,2057,2344, 2384 nm	HPLC	SNV, PCA	Stepwise FDA	Eşikler : 10,20,100,500 ppb Doğruluk : %88	(Wang vd., 2014)

Tablo 3.1. (Devam) Farklı gıda türlerinde optik yöntemler ile sınıflandırma yapılarak aflatoksin tespitini bildiren araştırma çalışmalarının özeti

Ürün	Veri Sayısı	AF Türü	Kontamine Şekli	Kullanılan Aygıtlar	Optik Yöntem	Spektral Aralık	Anahtar Spektral Bölge	Referans Yöntem	Veri Önileme, Boyut Azaltma	Sınıflandırma Yöntemi	Kullanılan Eşik Değerleri ve Doğruluk	Ref.
Mısır	132	AF	Doğal	CCD Dedektör, 785nm lazer	Raman	785 nm	686,760,828, 956 cm ⁻¹	HPLC	Savitzky-Golay	LDA	Eşikler : 20, 20-200, 300-450, 550-700, 850 ppb Doğruluk : %94-%100	(Lee vd., 2014)
İncir	400	AF	Doğal	2 Kamera, UVA ışık kaynağı	FS/BGYF	365 nm	365,490 nm	BGYF Işması	Görüntü maskeleme	Görüntü eşikleme	Doğruluk : %98	(Ö. Özlüoymak, 2014)
Mısır	300	AF	Mantar Aşılama	Kamera, spektrograf, optik filtre, UVA ve Halojen ışık kaynağı	HSI	365-1000 nm	700-800 nm	HPLC	PCA	LS-SVM	20 ppb için %93 100 ppb için %94	(F. Zhu vd., 2016)
Mısır	150	AFB ₁	AF çözeltisi Aşılama	Kamera, optik filtre, Halojen ışık kaynağı	HSI	1000-2500nm	1146,1729, 2274,2344 nm	HPLC	Görüntü maskeleme, PCA	Mahalanobis Distance	Eşikler : 10,20,100,500 ppb	(Kimuli vd., 2017)
İncir	172	AF	Doğal	Spektrometre, Halojen ışık kaynağı	FT-NIRS	780-2500 nm		HPLC		LDC	Eşik : 4ppb Doğruluk : %100	(Durmüş vd., 2017)
Mısır	378	AF	Doğal, Mantar Aşılama	Fotodiyot, 9 farklı dalga boyunda ışık kaynağı	FT-NIRS	470-1550 nm	500, 1200 nm	HPLC, ELISA	PCA	LDA	Eşikler : 1,10,100 ppb Doğruluk : %83	(Stasiewicz vd., 2017)
Fıstık Yağı	90	AFB ₁	Mantar Aşılama	FTIR spektrometre	FT-NIRS	4000-650 cm ⁻¹	1743, 1710 cm ⁻¹	LC-MS/MS	Discriminant Function	MDT	Eşik : 20ppb Doğruluk : %100	(Yang vd., 2018)
Mısır	600	AFB ₁	AF çözeltisi Aşılama	Kamera, spektrograf, Halojen ışık kaynağı	Vis-NIR HSI	400-1000 nm	710,735, 750,790 nm	HPLC	SNV	PCA/FDA	Eşikler : 10,20,100,500 ppb Doğruluk : %96 - %100	(Kimuli vd., 2018)
Mısır	180	AF	Mantar Aşılama	VIS-NIR Spektrometre, NIR Işık Kaynağı	NIRS	400-2500 nm	592, 1415 nm	VICAM AflaTest	SNV	PLS-DA	20 ppb için %87, 100 ppb için %84	(Tao vd., 2019)
Yer Fıstığı	73	AFB ₁	AF çözeltisi Aşılama	Kamera, Spektrometre, UVA ve Halojen ışık kaynakları	HSI	300-900 nm	432,514 nm		Görüntü önileme, Fisher, PCA	CNN	Eşikler : 20,60,100 ppb Doğruluk : %95	(Han ve Gao, 2019)
Mısır	480	AF	Mantar Aşılama	Spektrometre, UVA-VIS-NIR Işık kaynakları	UV-Vis-NIRS	304-1086 nm	390, 540, 1050 nm	ELISA	Ortalama Normalizasyon	Random Forest	Eşik : 20ppb Doğruluk : %95	(Cheng vd., 2019)
Yer Fıstığı	250	AFB ₁	AF çözeltisi Aşılama	Spektrometre, optik filtre, 360 nm lazer	FS	400-800 nm	669,711 nm		PCA, SNV	SVM	Eşikler : 5,10,20,50 ppb Doğruluk : %98	(Wu vd., 2019)

Tablo 3.1. (Devam) Farklı gıda türlerinde optik yöntemler ile sınıflandırma yapılarak aflatoksin tespitini bildiren araştırma çalışmalarının özeti

Ürün	Veri Sayısı	AF Türü	Kontamine Şekli	Kullanılan Aygıtlar	Optik Yöntem	Spektral Aralık	Anahtar Spektral Bölge	Referans Yöntem	Veri Önileme, Boyut Azaltma	Sınıflandırma Yöntemi	Kullanılan Eşik Değerleri ve Doğruluk	Ref.
Mısır	240	AFB ₁	AF çözeltisi Aşılama	Kamera, Halojen ışık kaynağı	HSI	400-1000 nm	508 nm	HPLC	Ham Veri	k-NN	Eşikler: 25,40,70,200,300,500 ppb Doğruluk : %98	(Chakraborty vd., 2020)
Yer Fıstığı	250	AFB ₁	AF çözeltisi Aşılama	Kamera, optik filtre, UVA ışık kaynağı	HSI	400-720 nm	410-430 nm		Pseudo,ROI,fish erkontrast geliştirme	SVM	Eşikler : 10,20,50,100,1000 ppb Doğruluk : %93	(Zhongzhi ve Limiao, 2020)
Badem	1 kg	AFB ₁ AFB ₂	Mantar Aşılama	VIS-Spektrometre, optik filtre, UVA ışık kaynağı	FS	340-850 nm	410 nm	HPLC		SVM	2 ppb için 88%, 4 ppb için 89%, 6 ppb için 94%, 8 ppb için 86%, 10 ppb için %73	(Bertani vd., 2020)
Mısır		AFB ₁	AF çözeltisi Aşılama	Kamera, Spektrometre, UVA ışık kaynağı	HSI	292-865 nm	390, 440, 540, 710 nm		PCA	Random Forest	Eşik : 20 ppb Doğruluk : %99	(Gao vd., 2020)
Mısır, Yer Fıstığı	-	AFB ₁	AF çözeltisi Aşılama	Kamera, Spektrometre, UVA ışık kaynağı	HSI	292-865 nm	430 nm		ROI	CNN	Doğruluk : Mısır için %92 Yer fıstığı için %96	(Gao vd., 2021)
Yer Fıstığı	150	AFB ₁	Doğal	Kamera, spektrograf, Halojen ışık kaynağı	HSI	400-1000 nm	470, 600, 680, 800 ve 820 nm	ELISA	Savitzky-Golay SNV, PLS-DA	SVM	Eşik : 20 ppb Doğruluk : %94	(X. He vd., 2021)
Mısır	450	AFB ₁	AF çözeltisi Aşılama	Kamera, Spektrometre, Halojen ışık kaynağı	NIR HSI	1100-2000 nm	1160, 1392, 1701, 1828 ve 1981 nm		Savitzky-Golay, PCA	LDA	Eşikler : 0, 10, 20, 50 ve 100 ppb Doğruluk : %88	(Zhou vd., 2021)
Mısır	122	AFB ₁	Doğal	Kamera, spektrograf, UVA ışık kaynağı	HSI	438-718 nm		HPLC	Ortalama	SVM	Doğruluk : %95,7	(Kim vd., 2022)
Mısır	450	AFB ₁	AF çözeltisi Aşılama	Kamera, spektrograf, Halojen ışık kaynağı	HSI	500-2000 nm	1644, 1656, 1581, 1543, 1524, 1866, 1796, 1809, 1461 ve 1732 nm		Savitzky-Golay	LDA	Eşikler : 10, 20, 50 ve 100 ppb Doğruluk : %94	(Zhou vd., 2022)
Fıstık Yağı	125	AFB ₁	AF çözeltisi Aşılama	Raman spektrometresi 532 nm lazer ışık kaynağı	Raman	50-3400 cm ⁻¹		LC-MS/MS		CNN, RNN	Doğruluk : %100	(Deng vd., 2022)
İncir	400	AF	Doğal	Kamera, UVA ışık kaynağı	FS/BGYF	365 nm		BGYF ışıması	Görüntü önileme	DenseNet169	Doğruluk : %97,5	(Kılıç ve İnnar, 2022)

4. MATERYAL VE METODLAR

4.1. Aflatoksin Tespitinde Sınıflandırma Öncesi İşlemler


Bir sınıflandırma modeli oluşturmak, optik tabanlı, tahribatsız bir aflatoksin tespit sisteminde son ve en kritik süreçtir. Oluşturulan sistem, optik yöntem verileri ile referans cihaz ölçüm verileri arasındaki ilişkiyi genelleştirmek ve kontamine numuneleri temiz numunelerden ayırt etmek için iyi eğitilmiş ve optimize edilmiş bir sınıflandırma modeli kullanılmalıdır.

Aflatoksin bulaşmış ürünlerin makine veya derin öğrenme yöntemleri ile sınıflandırılması esnasında, kullanılan optik yöntemlerden elde edilen veriler kullanılmaktadır. Görüntü verileri HSI, MSI, BGYF gibi yöntemlerle elde edilirken, spektral veriler NIRS, FS ve Raman'dan elde edilmektedir. Görüntü tabanlı yöntemlerde kamera yardımı ile görüntü verileri elde edilebilmektedir. Spektral veriler, spektrometre adı verilen optik cihazlarla elde edilir. Spektrometreler, bir fiber kablo yardımıyla mikron düzeyinde bir yüzeyden yansıyan sinyalin spektrum verilerini elde eder. Bu nedenle incirin tüm yüzeyinin ölçülmesi zaman alan bir işlemdir. Bu nedenle incir üretim tesislerinde gerçek zamanlı aflatoksin tespiti için incirin tüm yüzeyini hızlı bir şekilde inceleyebilen görüntü tabanlı yöntemler kullanılmalıdır.

Farklı gıda türlerinde oluşabilen aflatoksinin tespiti için kullanılan optik yöntemler, farklı şekillerde uygulanmaktadır. Örneğin; kuru incirde aflatoksin tespiti, kojik asitten dolayı BGYF yöntemiyle yapılabilenken, fındıkta aynı yöntem başarılı olmamaktadır. HSI yöntemiyle yapılan tespit çalışmalarında ise, mısır için 508 nm (Chakraborty vd., 2020), yer fıstığı için 430 nm (Zhongzhi ve Limiao, 2020) dalga boyunda aflatoksin seçiciliğinin yüksek olduğu bildirilmiştir. Bu durum her bir gıda türünün farklı optik karakteristiğe sahip olmasından kaynaklanmaktadır. Bu sebeple yapılan çalışmaların her biri genelde tek bir gıda türünü ele almıştır. Örneğin; (Zhou vd., 2022) mısır, (X. He vd., 2021) yer fıstığı, (Bertani vd., 2020) badem, (Ataş vd., 2012) kırmızı pul biber ve (Kalkan vd., 2014) incir numuneleri üzerinde tespit ve sınıflandırma çalışmaları yapmışlardır.

Tahribatsız aflatoksin tespiti için yapılan çalışmalarda ilk aşama ürün örneklerinin temin edilme aşamasıdır. Daha sonra, referans cihaz ölçümleri esnasında numuneler tahribata

uğrayacağı için, kullanılacak olan optik yöntemle göre numunenin görüntü veya spektral verileri elde edilir. Sonraki aşamada, numunelerin referans cihaz ölçümleri yapılarak elde edilen kontaminasyon miktarları ve optik yöntemden elde edilen veriler kullanılarak veri seti oluşturulur. Son aşamada ise, oluşturulan veri setleri kullanılarak sınıflandırma işlemi gerçekleştirilir. Optik yöntemlerle yapılan tahribatsız aflatoksin tespiti ve sonrasındaki sınıflandırma çalışmalarının basamaklarını oluşturan süreçler Şekil 4.1’de verildiği şekilde özetlenebilir.



Şekil 4.1. Aflatoksin tespiti ve sınıflandırma çalışma basamakları

4.1.1. Ürün Örneklerinin Temin Edilmesi ve Aflatoksin Kontaminasyonu

Yapılan çalışmanın performansını doğrudan etkileyeceği için örnek ürünlerin temin edilmesi yüksek önem arz etmektedir. Aflatoksin kontaminasyonlu ürünler, ürüne *Aspergillus Flavus* mantarının aşılması sonrası aflatoksin oluşumu için gerekli ortam şartlarında bekletilmesi neticesinde elde edilebildiği gibi (Tao vd., 2019), direkt aflatoksin çözeltisi kullanılarak da ürün kontaminasyonu sağlanabilmektedir (Han ve Gao, 2019). Bunların dışında, tarlada, bahçede vb. doğal yollarla kontamine olmuş ürünler de kullanılabilir (Ö. Özlüoymak, 2014). Örnekler arasındaki farkı belirlemek için hem kontamine hem de kontamine olmayan sınıflardan örnekler alarak veri setinin homojenize edilmesi gerekir. Netice itibarıyla aflatoksin içermeyen, değişik

miktarlarda aflatoksin içeren ve farklı üretim yerlerinden elde edilen fazla sayıda ürün üzerinde yapılan çalışmalar sınıflandırma performansına doğrudan etkilemektedir.

4.1.2. Optik Ortamın Hazırlanması ve Örneklerin İncelenmesi

Aflatoksin tespiti için optik yöntemler ile yapılmasında seçilecek optik bileşenler ve ortam önemlidir. Optik analizlerde kullanılan kamera, spektrometre, filtre, lens, ışık kaynakları gibi optik bileşenlerin türü ve teknik özelliklerinin doğru seçilmesinin yanında, analizin yapılacağı ortamın farklı ışık kaynaklarının girişini engelleyecek şekilde kapalı ve karanlık bir ortam olmasına dikkat edilmelidir. Kullanılan ışık kaynaklarının güçlü olması, kullanılan detektörün (kamera, spektrometre vb.) entegrasyon süresinin daha kısa olmasını ve daha güçlü sinyal elde edilebilmesini sağlayacaktır (Zhongzhi ve Limiao, 2020)

Gıda ürünlerinde aflatoksin varlığının tahribatsız tespiti için optik yöntemler kullanılarak yapılan çalışmalarda, FS, HSI, MSI, NIRS, RAMAN gibi yöntemler kullanılmıştır. Optik inceleme esnasında her bir örnek aynı optik koşullar altında incelenerek verileri alınmalıdır. Görüntüleme esaslı çalışan, kamera ve ışık kaynağı kullanılarak yapılan HSI ve MSI gibi optik yöntemlerle yapılan incelemelerde, örneklerin her biri için veriler alınmadan önce, kameranın konumu, RGB değerleri, ışık kaynaklarının konumu ve şiddeti gibi görüntüler üzerinde değişikliğe sebep olabilecek parametrelerin değerlerinin aynı olmasına dikkat edilmelidir. Benzer şekilde spektrometre ve spektrograf gibi optik bileşenler kullanılarak yapılan incelemelerde de mesafe, konum, ışık şiddeti, entegrasyon süresi gibi alınan spektrum değerini etkileyecek parametrelere dikkat edilmelidir. Aksi takdirde örnekleme hataları oluşacaktır.

Işık tayfı üzerindeki elektromanyetik spektrum değerleri 100-400 nm arası UV bölgesi (100-280 UVC, 280-315 UVB, 315-400 UVA), 400-700 nm arası görünür bölge ve 700-2500 nm arası NIR bölge olarak tanımlanmaktadır (Manickavasagan ve Jayasuriya, 2014). Aflatoksin tespiti için üç bölgede de farklı optik yöntemlerle tespit çalışmalarının yapıldığı bilinmektedir. Elde edilen spektrum grafiklerinde tepe bölgelerin incelenen gıda ürününün türüne ve optik yönteme göre değiştiği görülmüştür. Örneğin; mısırdaki HSI optik yöntemiyle yapılan aflatoksin tespitinde tepe noktası 508 nm çıkarken (Chakraborty

vd., 2020), yer fıstığında HSI optik yöntemiyle yapılan aflatoksin tespitinde tepe noktası 430 nm olarak bildirilmiştir (Zhongzhi ve Limiao, 2020).

İncelenen çalışmalarda aynı tür ürünlerde aynı optik yöntemler ve bileşenler kullanılıp aynı spektral bölgede inceleme yapılmasına rağmen, anahtar spektral bölgeler bir çalışmada 450-500 nm arası çıkarken (Yao vd., 2013), diğer çalışmada 400-450 nm arası bulunmuştur (Yao, Hruska, Kincaid, Brown, vd., 2010). Bu durum aflatoksin kontaminasyon şekline göre dolaylı olarak olabileceği gibi optik ortamın farklı şekilde oluşturulması ve optik parametrelerin farklı kullanımından kaynaklanıyor olabilir.

4.1.3. Referans Ölçümlerin Yapılması ve Veri Setinin Oluşturulması

Optik incelemenin ardından, aflatoksin kontaminasyon miktarlarının belirlenmesi için her bir örnek HPLC gibi referans kabul edilen kromatografik yöntemlerle analiz edilmelidir. Optik yöntemle yapılan tespit çalışmalarını etiketleyebilmek adına referans yöntemler kullanılarak elde edilen kantitatif sonuçlar önemlidir. Veri seti örnekleme hatalarından arındırılmış bir şekilde oluşturulmalıdır (Khadka, 2019). Veri seti içerisinde belirlenen eşik değerlerine uygun şekilde yeterli sayıda örnekler bulunmalıdır.

Bir veri setini eğitim ve test kümelerine bölmek, makine öğreniminde bir modelin performansını değerlendirmek için önemlidir. Eğitim seti modeli eğitmek, test seti ise modelin görünmeyen veriler üzerindeki performansını değerlendirmek için kullanılır. Bu, modelin yeni verilere genelleştirme yeteneğinin daha doğru bir şekilde değerlendirilmesine ve ayrıca bir model çok karmaşık olduğunda ve eğitim setinde iyi, ancak yeni verilerde zayıf performans gösterdiğinde ortaya çıkan aşırı uydurmayı belirlemeye olanak tanır. Başka bir deyişle, veri setini eğitim ve test setlerine bölmek, modelin gerçek dünya senaryolarında ne kadar iyi genelleştirdiğini ve performans gösterdiğini kontrol etmenin bir yoludur.

Oluşturulan sınıflandırma modellerinin performansı eğitim verilerinin kalitesine, miktarına ve dengeli dağılımına bağlıdır. Az sayıda veriden oluşan veri setleri ile hazırlanan modeller verinin ezberlenmesine neden olur. Bu sebeple Bölüm 4.2’de belirtilen veri çoğaltma teknikleri ile veri sayısı artırılarak, oluşturulmak istenen modelin daha isabetli tahminler yapması sağlanır. Veri setini oluşturan verilerin dengeli şekilde

dağılmış verilerden oluşması önemlidir. Sınıf dengesizliği, veri setini oluşturan verilerin çoğunluğunun aynı sınıftan örneklerden oluştuğu yaygın bir sorundur. Bu, açık bir çoğunluk-azınlık sınıfı ayrımının olduğu bir ikili sınıflandırma probleminde kendini gösterebilir. Dengesiz veri kümeleri, modelleri çoğunluk sınıfı tahminlerine doğru yönlendirir ve bu durum doğruluğu yanıltan bir performans ölçüsü olarak kendini gösterir. Veri çoğaltma, sınıf dengesizliği için veri düzeyinde bir çözüm sağlar.

4.1.4. Veri Ön işleme

Uygun optik yöntemle yapılan görüntülemelerden elde edilen veriler, aflatoksin kontaminasyonunu tahmin edebilecek sınıflandırma modelleri için bir yapı taşı sunmaktadır. Bununla birlikte, spektral veriler veya görüntüler, sistematik ve sistematik olmayan hataların veya gürültülerin varlığını ortadan kaldırmak ve sınıflandırmayı kolaylaştırabilecek bazı özellikleri güçlendiren ön işleme adımları gerektirir (Engel vd., 2013). Veri ön işleme, veri analizinin önemli bir aşamasıdır. Bu aşamada ham veri, istenmeyen hata ve gürültülerden arındırılarak temizlenmiş veriye dönüştürülmekte ve veri analizine hazır hale getirilmektedir. Ham veriler genellikle tutarsızlıklar, eksik değerler, gürültü ve/veya fazlalıklar gibi pek çok kusurla birlikte gelir. Veri ön işleme, veri seti üzerinde yapılan eksik veriyi tamamlama, tekrarlanan verileri kaldırma, normalizasyon, bütünleştirme, dönüştürme, temizleme gibi işlemlerdir. Düşük kaliteli verilere uygulanacak öğrenme algoritmalarının performansı zayıflayacaktır. Aykırı değerler ve tutarsız veri noktaları genellikle modelin genel öğrenmesini bozarak yanlış tahminlere yol açar. Bu sebeple, uygun veri ön işleme adımlarının uygulanmasıyla veri setinde istenmeyen varyasyonların oluşması engellenebilir ve öğrenme algoritmalarının performansı artırılabilir (Gerretzen vd., 2016).

Veri setinde görüntü verileri kullanıldığında görüntü işleme gerçekleştirilir. Görüntü işleme, görüntüyü dijital form haline getirmek ve bazı işlemleri gerçekleştirmek için geliştirilmiş, spesifik görüntü elde etmek veya ondan bazı yararlı bilgiler çıkarmak için kullanılan bir yöntemdir. Ön işlemenin amacı, görüntüyü daha etkin bir şekilde analiz edebilmek için görüntünün kalitesini yükseltmektir. Ön işleme, istenmeyen bozulmaları ortadan kaldırmaya ve üzerinde çalışılan uygulama için gerekli olan belirli nitelikleri geliştirmeye olanak tanır. Görüntü ön işleme, model eğitim süresini kısaltabilir ve model çıkarımını hızlandırabilir. Giriş görüntüleri çok büyükse, bu görüntülerin boyutunu

küçültmek, model performansını önemli ölçüde etkilemeden modeli eğitmek için gereken süreyi büyük ölçüde azaltır. Evrimsel sınır ağlarındaki tam bağlı katmanlar, tüm görüntülerin aynı boyutta diziler olmasını gerektirir. Görüntüler aynı boyutta değilse, model beklendiği gibi çalışmayabilir.

Görüntü verilerini iyileştirmek amacıyla aşındırma (erosion), genişletme (dilation), açma (opening) ve kapama (closing) gibi morfolojik işlemler uygulanır. Morfolojik görüntü işleme teknikleri, görüntü içerisinde yer alan gürültüleri yok edebilmek ve şekillerin biçimsel yapısı ile ilgilenerek nesnelerin sınır, kenar gibi görüntü bileşenlerinin ayrıştırılması amacıyla kullanılır. Matematiksel kavramlara dayalı olarak gerçekleştirilen bu işlemler genellikle siyah-beyaz (binary) görüntüler üzerinde kullanılır. Görüntülerdeki değişiklikler, yapılandırma ögesi olarak bilinen küçük bir ikili filtre veya çekirdek tarafından yapılır. Aşındırma ve genişletme, morfolojik işleme kapsamında iki ana ve zıt tekniktir. Diğer teknikler de bu tekniklerin bir araya gelmesiyle görüntüye uyma ya da çarpma durumuna göre türetilmiştir. Aşındırma işlemi, görüntüdeki bir nesnenin kenarlarında bulunan pikselleri veya nesnelerdeki gürültü ve ilgisiz şekil ayrıntılarını ortadan kaldırır. İkili bir görüntüde beyaz pikselleri azaltırken siyah pikselleri artırdığı için görüntüleri küçültür. Genişletme işlemi ise aşındırmanın tersi olarak orijinal görüntüye ekleme yapar. İkili bir görüntüde beyaz pikselleri artırıp siyah pikselleri azalttığı için görüntüleri büyütür.

Çoğu morfolojik işlem, genişleme veya aşındırmayı ayrı ayrı yapmak yerine birleşik olarak yapar. En yaygın olarak kullanılan iki birleşik işlem, açma ve kapama işlemleridir. Açma, önce aşındırma işlemi ardından genişletme işlemi yapılarak gerçekleştirilir. Böylece görüntüdeki iki bölge arasındaki dar bağlantılar ve çizgiler açılarak giderilir. Açma işlemi görüntüdeki daha büyük nesnelerin şeklini ve boyutunu korurken küçük nesneleri bir görüntüden çıkarmak için kullanılabilir. Kapamada ise, önce genişletme işlemi ve ardından aşındırma işlemi uygulanır. Böylelikle görüntüdeki küçük siyah alanlar veya delikler doldurur. Kapama, genellikle bozuk görüntünün konturunu yumuşatmak ve dar aralıkları ve uzun ince boşlukları birleştirmek için kullanılır.

4.1.5. Öznitelik Çıkarımı

Öznitelik çıkarımı (feature extraction), büyük bir veri kümesini temsil eden özelliklerin daha iyi analiz edilebilmesi için çok boyutlu bir veriyi daha düşük boyutlu bir uzaya indirmektedir. Bu büyük veri kümelerinin en önemli özelliği çok sayıda değişkene sahip olmalarıdır. Bu değişkenler hem büyük bir bellek alanı hem de işlenmesi için çok fazla bilgi işlem kaynağı gerektirir. Ayrıca sınıflandırma algoritmalarının eğitim kümesine aşırı uymasına sebep olarak tahmin performansını düşürür. Öznitelik çıkarma, veriyi yeterli bir doğrulukta açıklayabilen değişkenleri seçerek en iyi özelliği elde etmeye yardımcı olur. Amaç, yüksek boyuttan kaynaklanan olumsuzlukları (curse of dimensionality) azaltmak ve orijinal verinin ayırt edici tüm özelliklerini içerecek şekilde ana veriyi özetleyen düşük boyutlu veri kümesi oluşturmaktır.

Öznitelik çıkarımı, N boyutlu veri uzayının M boyutlu öznitelik uzayına ($M < N$) çeşitli yöntemler kullanılarak dönüştürülmesi olarak tanımlanmaktadır. Boyuttaki azalma, öğrenme algoritmalarının daha hızlı çalışmasına izin verse de bu durum orijinal verilerin tamamının veya çoğunluğunun temsil edilmesini ortadan kaldırabilir. Öznitelik çıkarma algoritmaları daha çok probleme ve veri setine bağlı olarak geliştirilmektedir.

Temel bileşen analizi (Principal Component Analysis, PCA), orijinal verilere daha düşük boyutlu öznitelik vektörleri ile yaklaşmayı amaçlayan en çok kullanılan boyut azaltma tekniklerinden biridir. Orijinal girdilerin kovaryans matrisinin öz vektörlerini hesaplayarak yüksek boyutlu bir girdi vektörünü, bileşenleri ilintisiz olan düşük boyutlu bir vektöre dönüştürür. Dönüşüm sonrasında elde edilen değişkenler temel bileşenler olarak adlandırılır. Temel bileşenler, ilk temel bileşen veri kümesindeki olası en büyük varyansı açıklayacak şekilde oluşturulur. Temel bileşenler varyans değeri en büyük olan ilk temel bileşen olacak şekilde sıralanır. Temel bileşenlerin sayısı, orijinal öznitelik değişkenlerinin sayısından az veya ona eşittir.

4.2. Veri Çoğaltma

Makine öğrenmesi ve derin öğrenme modellerinin performansı eğitim verilerinin kalitesine, miktarına ve dengeli dağılımına bağlıdır. Bununla birlikte yetersiz veriye sahip olmak derin sinir ağlarında en yaygın karşılaşılan zorluklardan biridir. Bunun nedeni,

fazla sayıda veri elde etmenin birçok durumda maliyetli ve zaman alıcı olabilmesidir. Veri çoğaltma (Data Augmentation), eldeki verileri hafifçe değiştirerek veya yeni, sentetik veriler üreterek yeni eğitim verileri oluşturma sürecidir (Shorten ve Khoshgoftaar, 2019). Sinir ağlarının küçük veri kümeleri ile modellenmesi verinin ezberlenmesine neden olur. Böylelikle oluşturulmak istenen modelin yeterince veri ile desteklenerek daha isabetli tahminler yapması sağlanır.

Veri çoğaltma yöntemleri, nesne algılama, görüntü sınıflandırma, görüntü tanıma, doğal dil anlama, anlamsal bölümlendirme gibi hemen hemen her derin öğrenme uygulamasında yaygın olarak kullanılmaktadır. Veri çoğaltma, eğitim veri kümeleri için yeni ve çeşitli örnekler oluşturarak aşırı öğrenme sorununun önüne geçerek derin öğrenme modellerinin performansını ve sonuçlarını iyileştirir. Sınıf dengesizliği, bir sınıftan örneklerin çok daha fazla olduğu veri kümelerinde oluşan yaygın bir sorundur. Aşırı örnekleme, dengesiz sınıf dağılımlarını yeniden örnekleme için kullanılan bir tekniktir ve veri çoğaltma aşırı örnekleme uygulamalarında da başarılı bir şekilde kullanılmaktadır.

Performansı yüksek derin öğrenme modelleri oluşturmak için doğrulama hatası, eğitim hatasıyla birlikte azalmaya devam etmelidir. Veri çoğaltma bunu başarmanın çok güçlü bir yoludur. Çoğaltılan veriler, daha kapsamlı bir olası veri noktaları kümesini temsil edecek, böylece eğitim ve doğrulama kümesi ile gelecekteki test kümeleri arasındaki mesafeyi en aza indirecektir.

Geleneksel veri büyütme teknikleri, yeniden yapılandırılan görüntünün etiketini ve özelliklerini koruduğu için etiket koruyucu veri büyütme teknikleri olarak adlandırılır. Mevcut görüntü büyütme teknikleri orijinal verilerin dönüştürülmesi ve sentetik verilerin üretilmesi şeklinde iki kategoride sınıflandırılmaktadır. Orijinal verilerden dönüştürme işlemi, geometrik dönüşümleri, piksel düzeyinde dönüşümleri ve elastik dönüşümleri içerirken, sentetik verilerin üretilmesi çekişmeli üretici ağ (Generative Adversarial Network, GAN) veri büyütme, PCA tabanlı büyütme, otomatik kodlayıcı tabanlı üretici modelleri ve görüntü kaydını içerir (Nalepa vd., 2019).

4.2.1. Orijinal Verilerin Dönüştürülmesi

4.2.1.1. Geometrik Dönüşümler

Eğitim örneklerinin sayısını artırmak amacıyla, mevcut görüntü verilerine döndürme, ölçekleme (yakınlaştırma/uzaklaştırma), kırpma, çevirme veya öteleme gibi geometrik dönüşümler uygulanabilir.

Çevirme, görüntünün dikey veya yatay eksenini boyunca aynalanması yani piksel satırları veya sütunların tersine çevrilmesi anlamına gelir. Genellikle doğal görüntüler yatay eksen boyunca çevrilebilirken, görüntünün yukarı ve aşağı kısımları her zaman değiştirilebilir olmayacağı için dikey ekseninde çevirme her uygulamada kullanılamayabilir.

Döndürme, görüntüyü 1° ile 359° arasında bir ekseninde sağa veya sola döndürerek yapılır. Rotasyon artırımlarının güvenliği, büyük ölçüde rotasyon derecesi parametresi tarafından belirlenir. 1 ile 20 veya -1 ile -20 arası gibi hafif döndürmeler, rakam tanıma görevlerinde faydalı olabilir, ancak fazla döndürme sonucunda verilerin etiketi korunamayabilir.

Kaydırma, görüntü boyutunu değiştirmeyip görüntünün tüm piksellerini yatay veya dikey yönde hareket ettirmektir. Görüntüleri sola, sağa, yukarı veya aşağı kaydırmak, verilerde konumsal sapmayı önlemek için çok yararlı bir dönüşüm olabilir.

Görüntüleri kırpma, her görüntünün merkezi bir yamasını kırparak karışık yükseklik ve genişlik boyutlarına sahip görüntü verileri için pratik bir işleme adımı olarak kullanılabilir. Bu işlem şekilleri deforme edebileceği için etiketi koruyan bir dönüşüm olmayabilir.

4.2.1.2. Piksel Düzeyinde Dönüşümler

Geometrik dönüşümler sonucunda elde edilen yeni görüntüler asıl görüntüye benzer ve tanımlanabilir olduğundan veri kümelerini zenginleştirir. Ancak bazı yaklaşımlar, görüntülerin özelliklerini parçalayarak doğal olmayan ve düzensiz görüntüler üretir. Bir görüntünün geometrik şeklini değiştirmeyen (bu nedenle, büyütme işlemi sırasında tüm geometrik özellikler değişmeden kalır) ancak piksel yoğunluğu değerlerini (yerel olarak veya tüm görüntü boyunca) etkileyen büyütme teknikleri vardır.

Piksel düzeyinde büyütme sırasında, piksel yoğunlukları genellikle ya rastgele ya da sıfır ortalamalı Gauss gürültüsü (uygun veri boyutuna karşılık gelen standart sapma ile) kullanılarak belirli bir olasılıkla (önceki işlem rastgele yoğunluk olarak adlandırılır) bozular. Gürültü enjeksiyonu, genellikle bir Gauss dağılımından çizilen rastgele değerler matrisinin enjekte edilmesinden oluşur. Görüntülere gürültü eklemek, evrişimli sinir ağlarının daha sağlam özellikler öğrenmesine yardımcı olabilir.

Dijital görüntü verileri genellikle boyutun bir tensörü olarak kodlanır (yükseklik×genişlik×renk kanalları). Renk kanalları alanında büyütme yapmak, uygulanması çok pratik olan başka bir stratejidir. Çok basit renk büyütme işlemleri, R, G veya B gibi tek bir renk kanalının izole edilmesini içerir. Bir görüntü, bu matrisi izole ederek ve diğer renk kanallarından 2 sıfır matrisi ekleyerek bir renk kanalındaki temsiline hızla dönüştürülebilir. Ek olarak, görüntünün parlaklığını artırmak veya azaltmak için RGB değerleri basit matris işlemleriyle kolayca değiştirilebilir. Daha gelişmiş renk büyütme işlemleri, görüntüyü tanımlayan bir renk histogramının türetilmesinden gelir. Bu histogramlardaki yoğunluk değerlerinin değiştirilmesi, fotoğraf düzenleme uygulamalarında kullanılanlar gibi aydınlatma değişikliklerine neden olur.

Diğer piksel düzeyindeki dönüşümler arasında piksel yoğunluğu değerlerinin kaydırılması ve ölçeklenmesi (ve görüntü parlaklığının değiştirilmesi), gama düzeltmesi ve bunun çoklu varyantlarının uygulanması, keskinleştirme, bulanıklaştırma ve benzeri işlemler vardır. Seçilen boyutlara uygun bir şekilde uygulanabildiğinden, genellikle yüksek boyutlu veriler için kullanılır (Nalepa vd., 2019).

4.2.1.3. Elastik Dönüşümler

Elastik dönüşüm, doğrusal olmayan yollarla pikselleri rastgele bozarak mevcut görüntülerden yeni görüntüler oluşturmak için kullanılan bir veri çoğaltma tekniğidir. Bu yöntem, rastgele bir deformasyon matrisinden üretilen bir yer değiştirme alanını kullanarak piksellere rastgele bir yer değiştirme uygulamayı içerir. Ortaya çıkan dönüştürülmüş görüntüler, modele daha çeşitli örnekler sağlayarak ve verilerdeki dönüşümlerin sağlamlığını geliştirerek eğitim veri setini büyütme için kullanılabilir.

4.2.2. Sentetik Verilerin Üretilmesi

Temel veri büyütme yaklaşımlarıyla ilgili sorunları hafifletmek için, yapay veri oluşturmaya yönelik çeşitli yaklaşımlar önerilmiştir. Üretken modelleme, orijinal kümeye benzer özellikleri koruyacak şekilde bir veri kümesinden yapay örnekler oluşturmayı kapsar. GAN tabanlı veri büyütme tekniği, bir üretici ve ayırt edici işlevi kullanarak mevcut veri kümelerinden yeni sentetik görüntüler oluşturmayı içerir. Üretici fonksiyonu, sahte ve gerçek görüntüler arasında ayırım yapmak üzere eğitilmiş ayırmacı fonksiyonu kandırmak için fotogerçekçi bir görüntü oluşturur. Yapay olarak görüntü oluşturmanın diğer teknikleri arasında otomatik kodlayıcılar, PCA ve görüntü kaydı bulunur.

4.3. Kullanılan Sınıflandırma ve Görüntü İşleme Yöntemleri

4.3.1. Rastgele Orman

Rastgele orman (Random Forest, RF), eğitim aşamasında çok sayıda karar ağacı oluşturarak problemin tipine göre sınıflandırma veya regresyon tahmini yapan denetimli bir makine öğrenme yöntemidir (Breiman, 2001). Karar ağaçları, eğitim verilerinin sınıflarını analiz eder ve eğitim verilerinden çıkarttığı kurallara göre test verilerinin hangi sınıfa ait olduğunu belirler. RF, birçok sınıflandırma ağacını bir veri kümesine sığdırır ve ardından tüm ağaçlardan gelen tahminleri birleştirir. Bir ağaç oluşturmak için her bir düğümde kullanılan öznitelik sayısı (m) ve büyütülecek ağaç sayısı (N), rastgele bir orman sınıflandırıcısı oluşturmak için gereken kullanıcı tanımlı iki parametredir (Breiman, 2001). Her düğümde, en iyi bölünme için yalnızca seçilen özellikler aranır. Yeni bir veri kümesini sınıflandırmak için, veri kümelerinin her durumu N ağacın her birine aktarılır.

Algoritma, verilerden çok sayıda önyükleme (bootstrap) örneğinin seçilmesiyle başlar. Tipik bir önyükleme örneğinde, veri setinin % 66'sı öğrenme verisi (inBag) ve geriye kalanı test verisi (out-of-bag (OOB)) olarak belirlenir. Sonra her önyükleme örneği için ağaç gelişimi başlar. Her düğümde, ikili bölünme için m sayıda rastgele seçilmiş değişken kullanılarak en iyi dallanma belirlenir. Bunun için sınıflandırma ve regresyon ağacı (Classification and Regression Tree, CART) algoritması kullanılır (Gislason vd., 2006). RF sınıflandırıcısı öznitelik seçim ölçüsü olarak Gini indeksini kullanır. Gini

İndeksinin en küçük değerine sahip olan öznitelikler tercih edilir. Gini İndeksi, her bir sınıfın olasılıklarının karelerinin toplamının birden çıkarılmasıyla belirlenir ve matematiksel olarak şu şekilde ifade edilebilir:


$$Gini = 1 - \sum_{i=1}^n (p_i)^2 \quad (4.1)$$

Burada p_i , bir nesnenin belirli bir sınıf için sınıflandırılma olasılığını gösterir. Algoritmanın her düğümde rastgele seçtiği değişkenler için Gini indeksi hesaplanır ve indeks değerinin en küçük olduğu değişkeni seçerek diğer düğüme geçer. Gini indeksi 0 ile 1 değerleri arasında değişir. Değerin sıfır olması ilgili düğümün tamamen homojen olduğu anlamına gelir ve dallanma orada biter (Pal, 2007). Ağaçlar tamamen oluşturulduktan sonra her biri torbadan çıkan gözlemleri tahmin etmek için kullanılır. OOB test verileri kullanılarak her gözlem için doğruluklar ve hata oranları hesaplanır ve ardından tüm gözlemlerin ortalaması alınır. OOB hatası yüksek olan ağaç düşük ağırlık değeri alırken, OOB hatası düşük olan ağaç yüksek ağırlık değeri alır. (Casella vd., 2013).

4.3.2. Destek Vektör Makineleri

Destek vektör makinesi (Support Vector Machine, SVM), Vapnik-Chervonenkis istatistiksel öğrenme teorisine dayalı denetimli bir öğrenme algoritmasıdır (Cortes ve Vapnik, 1995). Bir makine öğrenimi yöntemi olarak SVM, görüntü ve sinyal işleme ve tanımda büyük bir rol oynar. Şekil 4.2’de gösterildiği gibi temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırmak için kullanılır. İki sınıfı ayırmak için çok boyutlu özellik uzayında bir hiper düzlem bulmaya çalışır ve bu hiper düzlem, altdüzlem ile marjin adı verilen iki sınıf arasındaki mesafeyi maksimize eden en iyi karar doğrusudur. Genel olarak, marjin ne kadar büyükse sınıflandırıcı o kadar iyidir.

SVM, sınırlı eğitim setiyle yüksek boyutlu veriler için en uygun sınıflandırıcılardan biridir. Eğitim verisi az ve özellik sayısı çok olduğunda bile sınıflandırma ve regresyon problemlerinde iyi performans gösterir. Veri setinin doğrusal olarak ayrılabilme ve ayrılammama durumuna göre ikiye ayrılmaktadır.



Şekil 4.2. Destek Vektör Makinesi

4.3.2.1. Doğrusal SVM

SVM, iki sınıfa ait örnekleri çizilen en uygun hiper düzlem veya karar doğrusu yardımıyla birbirinden ayırmayı amaçlar. Eğitim verilerini iki sınıfa ayırabilen hiper düzlemin denklemi Denklem (4.2)'deki gibidir.

$$w \cdot x + b = 0 \quad (4.2)$$

Burada w ağırlık matrisi, x girdi matrisi ve b ise sapmayı gösterir. SVM aslında w ve b 'nin seçimi olarak özetlenebilir. Daha sonra veri noktalarımızı Denklem (4.3)'de belirtildiği şekilde iki sınıftan birine böleriz.

$$\forall i \text{ için } y_i(w \cdot x_i + b) - 1 \geq 0 \quad (4.3)$$

Dolayısıyla, bir veri parçası karar sınırının üzerindeyse '1' sınıfı olarak, karar sınırının altında kalıyorsa '-1' sınıfı olarak sınıflandırılır.

Doğrusal olarak ayrılabilen durumlar için kullanılan Sabit Marjlı SVM ve Esnek Marjlı SVM olmak üzere iki tür SVM mevcuttur. Sabit marjlı SVM, verilerin tamamının doğrusal olarak ayrılabilmesi durumunda çalışır ve aykırı değerlere karşı çok duyarlıdır. Sabit marjlı SVM'de veri noktaları Denklem (4.3)'de belirtilen kısıtlamayı karşılaması gerekir.

Esnek marjlı SVM, eğitim verilerinin hatasız olarak sınıflandırılmadığı durumlarda kullanılır. Sınıflandırma işleminin en az hata ile yapılabilmesi için hatalı sınıflandırılan veriler eğitim veri setinden çıkarılır (Cortes ve Vapnik, 1995). Bazen veriler doğrusal olarak ayrılabilir, ancak marjın o kadar küçüktür ki, model aşırı uydurmaya veya aykırı değerlere karşı çok hassas olmaya eğilimli hale gelir. Ayrıca, bu durumda, modelin daha iyi genelleştirilmesine yardımcı olmak için esnek marjlı SVM kullanarak daha büyük bir marj seçilebilir. SVM'lerde sabit marjın ile esnek marjın arasındaki fark verilerin ayrılabilirliğinde yatmaktadır. Veriler doğrusal olarak ayrılabilirse, sabit marjın kullanılır. Ancak doğrusal bir sınıflandırıcı bulmayı imkansız kılan veri noktalarının varlığında, esnek marjlı bir SVM kullanmak uygundur. Esnek marjlı SVM'de veri noktaları Denklem (4.4)'de belirtilen kısıtlamayı karşılaması gerekir.

$$y_i(w \cdot x_i + b) \geq 1 - C_i \quad (4.4)$$

Burada C_i , her x_i veri noktası için esnek değişkeni belirtir. C_i 'nin değeri, x_i 'nin marjın yanlış tarafında olması durumunda x_i 'nin karşılık gelen sınıfın marjından uzaklığıdır, aksi takdirde bu değer sıfırdır. C_i değeri ne kadar büyükse marjın o kadar dardır. Burada $y_i(w \cdot x_i + b) \geq 1$ ise sınıflandırıcının noktayı doğru sınıflandırdığı, aksi durumda sınıflandırıcının noktayı hatalı şekilde sınıflandırdığı anlaşılır.

4.3.2.2. Doğrusal Olmayan SVM

Doğrusal olmayan bir veri kümesinde SVM'ler doğrusal bir hiper düzlem çizemez. Bu durumda SVM, doğrusal olmayan verileri doğrusal olarak ayrılabilir olduğu daha yüksek bir boyuta dönüştürerek ele alır. Fakat yüksek boyutlarda işlem yapmak zordur. Ayrıca boyut değişikliğini gerçekleştiren dönüştürme fonksiyonu bilinmemektedir. Bu sebeple çekirdek düzenlemesi (kernel trick) denilen düzenlemeler yapılır. Böylelikle dönüştürme fonksiyonu yerine, doğrudan girdi uzayındaki verilerin kullanımını sağlayan çekirdek fonksiyonları işleme dâhil edilerek, sınıflar arasında doğrusal bir hiper düzlem oluşturulabilir. Çekirdek fonksiyonunun kullanımı, doğrusal olmayan verilerin sınıflandırma başarısını yüksek oranda arttırmaktadır. Literatürde çok sayıda çekirdek fonksiyonu olmakla birlikte; en sık kullanılanları Tablo 4.1'de verilmiştir.

Tablo 4.1. Sık kullanılan çekirdek fonksiyonları

Fonksiyon Adı	Formül	Açıklama
Doğrusal Fonksiyon	$K(x_i, x_j) = x_i x_j$	Veriler doğrusal olarak ayrılabilir olduğunda kullanılır.
Polinom Fonksiyon	$K(x_i, x_j) = (a + x_i x_j)^d$	Çekirdekte kullanılan orijinal değişkenlerin polinomları üzerinden, özellik uzayındaki vektörlerin benzerliğini temsil eder ve böylece doğrusal olmayan modellerin öğrenilmesine olanak tanır. d : Çekirdek derecesi a : Sabit terim
Sigmoid Fonksiyon	$K(x_i, x_j) = \tanh(\alpha x_i x_j + c)$	Sigmoid çekirdek fonksiyonu birçok uygulamada iyi performans göstermektedir. α : eğim ve c : kesme sabiti olmak üzere iki ayarlanabilir parametresi vardır.
Radyal Tabanlı Fonksiyon (RBF)	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$	Radyal çekirdek çok lokaldır ve iki boyutlu uzayda kapalı çokgenler gibi özellik alanı içinde karmaşık bölgeler oluşturabilir. $\ x_i - x_j\ $: x_i ve x_j arasındaki Öklid mesafesi γ : Gama (yalnızca RBF çekirdeği için kullanılır). γ değeri arttıkça model aşırı uyarlanır, azaldıkça model yetersiz kalır

4.3.3. Eşikleme

Eşikleme (Thresholding) işleminin amacı, görüntüdeki nesneleri görüntü arka planından ayırmaktır. Bir nesne ile arka plan arasındaki farkı anlamanın en kolay yolu, görüntüdeki piksel değerlerini seçilen bir eşik, T , değeri ile karşılaştırmaktır. Görüntüdeki herhangi bir (x, y) noktası için $f(x, y) > T$ ise nesne noktası belirlenir; aksi takdirde bu nokta arka plan noktası olarak belirlenir. Eşikleme fonksiyonu şu şekilde gösterilebilir:

$$g(x, y) = \begin{cases} 1 & \text{Eğer } f(x, y) > T \\ 0 & \text{Eğer } f(x, y) \leq T \end{cases} \quad (4.5)$$


Burada $g(x, y)$ işlenmiş görüntü, $f(x, y)$ görüntünün piksel değeri, T ise seçilen eşik değeridir. Eşikleme fonksiyonunun aldığı ilk girdi değeri gri uzaydaki görüntüdür. Görüntü eşikleme işlemi öncesinde görüntünün renk uzayı gri renk uzayına çevrilmelidir. Bunun için RGB ve HSV (Hue, Saturation, Value) renk uzayları kullanılmaktadır. RGB renk uzayında renkler üç ana rengin (kırmızı, yeşil, mavi) karışımı ile tanımlanır. HSV renk uzayı ise renk özü (hue), doygunluk (saturation) ve parlaklık (value) terimleri ile

rengi tanımlar. Renk özü rengin baskın dalga uzunluğunu, doygunluk rengin canlılığını ve parlaklık ise rengin aydınlığını ifade eder. HSV uzayında siyah renk için renk ve doygunluk değerleri 0 ile 255 arasında herhangi bir değer alabilirken parlaklık değeri sıfırdır. Beyaz renkte ise parlaklık değeri 255'dir.

Eşikleme yöntemi her ne kadar hızlı ve kullanımı kolay olsa da, her görüntü için uygun eşikleme yoğunluğu değerlerinin seçilmesi hesaplama açısından maliyetlidir. Ayrıca bazen bir eşik değeri görüntünün bir bölümü için iyi sonuç verirken geri kalanı için yetersiz olabilir ya da bir görüntü için geliştirilen eşikleme algoritması diğer görüntüler için iyi sonuçlar vermeyebilir.

4.4. Evrişimli Sinir Ağları

Evrişimli Sinir Ağları (Convolutional Neural Network – CNN), canlıların doğal görsel algılama mekanizmasından ilham alarak tasarlanmış bir derin öğrenme mimarisidir. CNN'ler, art arda yerleştirilmiş ve her biri verinin farklı özelliklerini algılamayı öğrenen onlarca veya yüzlerce katmana sahiptir. Katmanlardaki girdi verilerine evrişim işlemi uygulanarak öznitelik haritası otomatik olarak çıkarılır ve bu öznitelikler sonraki katmanlara gönderilir. CNN'i oluşturan katmanların her birinde verinin farklı özellikleri öğrenilir ve katmanların sırayla uygulanmasıyla eğitim süreci gerçekleştirilir. Örnek bir CNN mimari modeli Şekil 4.3'de görülmektedir. Evrişimli katmanlar, giriş görüntülerinden öznitelik çıkarıcılar olarak işlev görürken, tam bağlantı katmanlar sınıflandırıcı olarak işlev görür. Tam bağlantılı katmanlar, girdi görüntülerini önceden tanımlanmış sınıflara ayırmak için öğrenilen üst düzey özniteliklerden yararlanır.



Şekil 4.3. CNN mimari modeli

CNN, ağırlık paylaşımı ve kullanılan daha karmaşık modeller nedeniyle karmaşık sorunları özellikle hızlı öğrenebilir. Evrişimli sinir ağları, sorunu açıklamak için yeterince büyük veri kümeleri olması koşuluyla, doğru sınıflandırma olasılıklarını artırabilir. CNN modellerinin son derece hiyerarşik yapısı ve büyük öğrenme kapasitesi, çok çeşitli karmaşık zorluklara esnek ve uyarlanabilir olarak sınıflandırma ve tahminleri özellikle iyi gerçekleştirmelerine olanak tanır. Evrişimli sinir ağları, ses, video, görüntü, konuşma ve doğal dil gibi herhangi bir veri biçimini girdi olarak alabilir

4.4.1. CNN Katmanları

Bir CNN, bir girdi katmanı, bir çıktı katmanı ve bunların arasındaki birçok gizli katmandan oluşur. Tipik bir mimari, evrişim katmanları, aktivasyon katmanı, havuzlama katmanları ve tamamen bağlı katmandan oluşur. Girdi verilerinin bu katmanlar aracılığıyla çıktıya dönüştürüldüğü adıma ileri yayılım denir.

4.4.1.1. Evrişim Katmanı

Evrişim katmanı, bir CNN'nin temel yapı taşıdır ve hesaplamaların çoğunun gerçekleştiği yerdir ve özellik çıkarıcı görevi görür. 2×2 , 3×3 , 5×5 , 7×7 gibi farklı boyutlarda olabilen filtrelerin tüm görüntü üzerinde dolaştırılması işlemi ile bir dönüşüm sağlar. Evrişim işlemi sonunda, görüntü hakkında bilgiler veren özellik haritası elde edilir. Daha sonra, bu özellik haritası, giriş görüntüsünün diğer birkaç özelliğini öğrenmek için diğer katmanlara verilir.

4.4.1.2. Aktivasyon Katmanı

Aktivasyon fonksiyonunun gerçekleştiği katmandır. Aktivasyon katmanı ağırlık doğrusal olmayan eşlemeleri öğrenmesini sağlayarak karmaşık işlemlere karşı daha dayanıklı olmasını sağlar. CNN'lerde kullanılan en yaygın aktivasyon fonksiyonları sigmoid, Tanh, ReLU, LeakyReLU ve softmax'tır. Aktivasyon katmanları, doymuş aktivasyon katmanları ve doymamış aktivasyon katmanları olarak sınıflandırılabilir. Aktivasyon katmanının çıktısı sonlu sınırlar arasındaysa, doymuş olarak sınıflandırılır; aksi takdirde, sonsuz olma eğilimindeyse, doymamış bir aktivasyon fonksiyonu olarak kabul edilir. Doymamış aktivasyon fonksiyonları, doymuş aktivasyon katmanlarına kıyasla birçok avantaja sahiptir. Örneğin, doymamış katmanlar, geri yayılım algoritmasının CNN

eđitimi esnasındaki ana sorunlardan biri olan kaybolan gradyan probleminin özümüne önemli ölçüde yardımcı olabilir (Xu vd., 2015).

4.4.1.3. Havuzlama Katmanı

Havuzlama (Pooling) katmanı aktivasyon fonksiyonlarının sonrasına yerleřtirilen ve isteęe baęlı kullanılan bir katmandır. Havuzlamanın amacı, bir sonraki evriřim katmanı için derinlik boyutunu etkilemeksizin giriř boyutunu azaltmaktır. Buna ařaęı örnekleme de denilmektedir. Giriř boyutunun azaltılması, hesaplama yükünün ve sistemin ezberleme potansiyelinin azaltılmasını saęlar. Evriřim katmanında olduęu gibi bu katmanda da belirli filtreler tanımlanır ve kullanılır. Havuzlama filtre sayısını etkilemez. Yaygın olarak kullanılan havuzlama yöntemleri maksimum havuzlama ve ortalama havuzlamadır. Maksimum havuzlama, filtreyi önceki evriřim katmanının ıktı özellik haritası üzerinde kaydırır ve her ızgaranın maksimum deęerini döndürür. Ortalama havuzlama ise, filtreyi önceki evriřim katmanının ıktı özellik haritası üzerinde kaydırır ve ızgaranın ortalamasını alır.

4.4.1.4. Tam Baęlantılı Katman

Tam baęlantılı katman (Fully Connected Layer, FCL), önceki katmanlardan ve bunların farklı filtrelerinden ıkarılan özniteliklere dayalı olarak sınıflandırma görevini gerçekleştirir. Evriřim ve havuzlama katmanları Doğrultulmuş Lineer Birim (Rectified Linear Unit, ReLU) aktivasyon fonksiyonlarını kullanma eğilimindeyken, FCL genellikle girdileri uygun şekilde sınıflandırmak için bir softmax aktivasyon fonksiyonundan yararlanarak 0'dan 1'e kadar bir olasılık üretir. FCL'deki her düęüm, hem önceki hem de sonraki katmandaki her düęüme doğrudan baęlıdır. FCL'nin en büyük dezavantajı, eğitim örneklerinde karmařık hesaplama gerektiren birok parametre içermesidir. Bu nedenle performans artışı için dropout (seyreltme) teknięi kullanılarak düęüm ve baęlantı sayısı ortadan kaldırılmaya alışılır.

4.4.2. Evriřimli Sinir Ağlarının Normalizasyonu ve Optimizasyonu

CNN aęında normalizasyon işleminin uygulanması performansı etkilemektedir. Normalizasyondaki amaç katmanlardan elde edilen verileri düzenli hale getirmektedir.

Katmanlara girdi olan verilerin normalize edilerek belirli bir aralıkta temsil edilmesi ağın performansının artırılmasını sağlar.

Sinir ağının derinliği, ağdaki giriş ve çıkış katmanları dışında bulunan gizli katmanların sayısını ifade eder. Az sayıda katman kullanmak yetersiz olabileceği gibi, çok sayıda gizli katman kullanmak da aşırı öğrenmeye neden olabilir. Katman sayısı arttıkça geri yayılım (backpropagation) etkisi ilk katmanlara daha az ulaşabileceğinden, kurulacak olan modelin temeli çoklu katman sayısına uygun olarak tasarlanmalıdır. Evrimsel sinir ağlarında her bir katmanda matris üzerinde işlem yapan filtreler kullanılmaktadır. Filtre boyutu ile ne kadar genişlikte verinin birbirini etkileyeceğine karar verildiği için, filtrelerin boyutu öğrenme üzerinde etkilidir. Büyük boyutlu filtre kullanılması, evrişim uygulandıktan sonra oluşacak resmin küçük olmasına neden olur. Bu durum bilgi kaybına yol açacağından genelde 3×3 gibi küçük boyutlu filtre kullanılmaktadır. Ağın genişliği ise, evrişim katmanlarındaki filtre sayılarını ifade eder. Her bir filtre yardımıyla görüntü üzerindeki bir özellik öğrenildiği için, ne kadar fazla filtre varsa o kadar fazla özellik keşfedilir ve böylece ağı genişliği artar.

Nöron sayısı hafızada tutulan bilgi sayısını gösterir. Nöron sayısının fazla olması bellek ihtiyacı ve hesaplama zamanını artırır. Nöron sayısının az olması ise yetersiz uyuma (underfitting) sebep olur. Nöron sayısının katmanlar arasında farklı dağılması (ilk katmanlarda fazla nöron kullanılırken ilerleyen katmanlarda azaltılarak devam edilmesi) başarıyı iyileştirme (regularization) etkisi yaratır.

4.4.3. Hiperparametreler

CNN’de, eğitim aşamasında doğrudan eğitim verisinden öğrenilen model parametreleri olduğu gibi, önceden tanımlanması gereken parametreler bulunmaktadır. Tasarımcı tarafından tanımlanan örnek sayısı, sınıf sayısı, filtre boyutu ve sayısı, aktivasyon fonksiyonu, paket boyutu, öğrenme hızı ve görüntü ön işleme gibi tercihlere hiperparametre denilmektedir. Uygun hiperparametre seçimi CNN eğitiminin daha az maliyetle ve yüksek başarıyla gerçekleşmesini sağlar. Hiperparametreleri optimize etmek için kullanılan bazı yaygın stratejiler şunlardır:

Manuel Arama: Geliştiricinin model için farklı hiperparametre kombinasyonlarını denediği ve en iyi performansı gösteren modeli seçtiği arama şeklidir.

Izgara Arama: En iyi performans gösteren hiperparametre için manuel olarak önceden belirlenmiş bir dizi hiperparametre değeri üzerinden yapılan kapsamlı bir aramadır.

Rastgele Arama: Izgara aramaya benzer, ancak kapsamlı arama yapmak yerine ızgara alanını rastgele arayarak rastgele seçilmiş parametre kombinasyonlarını dener. Algoritmayı optimize etmek için az sayıda hiperparametreye ihtiyaç duyulduğunda ızgara aramasından daha iyi performans gösterir.

Bayes Optimizasyonu: Hiperparametreleri amaç fonksiyonuna eşlemek için olasılıksal bir model oluşturur. Amaç fonksiyonunun sonsal dağılımını oluşturmak için verilere dayalı olarak öncelikleri günceller ve optimumun yerini bulmaya çalışır. Değerlendirilmesi pahalı olan işlevler için uygundur.

Gradyan Tabanlı Optimizasyon: Hiperparametreleri kullanarak gradyanı hesaplar ve ardından gradyan azalma algoritmasını kullanarak hiperparametreleri optimize eder.

Evrimsel Optimizasyon: Olası hiperparametrelerin uzayını aramak için evrimsel algoritmaları (Örn. genetik fonksiyonlar) kullanır.

4.4.3.1. Öğrenme Hızı






Öğrenme hızı (learning rate), bir ağıın parametrelerini ne kadar hızlı güncellediğini tanımlar. Hata düzeltme katsayısı olarak da bilinir. Model ağırlıkları her güncellendiğinde tahmini hataya yanıt olarak modelin ne kadar değiştirileceğini kontrol eden bir hiperparametredir. Düşük öğrenme hızı, modelin daha optimal bir ağırlık kümesini öğrenmesini sağlayabilir fakat öğrenme sürecini yavaşlatır ve bellek kapasitesi ihtiyacını artırır. Daha büyük öğrenme hızı ise öğrenmeyi hızlandırır fakat kararsız bir eğitim sürecine neden olabilir.

4.4.3.2. Aktivasyon Fonksiyonu





Aktivasyon fonksiyonu, bir sinir ağının her katmanında lineer olmayan özellikleri öğrenen fonksiyonları ifade eder. Basit bir sinir ağında, her düğümün doğrusal bir fonksiyonu ve aktivasyon fonksiyonu ile elde edilen doğrusal olmayan bir fonksiyonu

olmak üzere iki ana işlemi vardır. Aktivasyon fonksiyonları, ağıın veri kümesinin doğrusal olmayan özelliklerini öğrenmesine yardımcı olur. ReLU genellikle gizli katmanlar için en popüler seçimdir. Sinir ağından ihtiyaç duyulan çıktı türüne bağlı olarak uygun bir aktivasyon fonksiyonu seçilebilir. Yapay sinir ağlarının karmaşık problemleri çözmesi için Tablo 4.2’de belirtilen aktivasyon fonksiyonları geliştirilmiştir.

Tablo 4.2. Aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Grafik	Fonksiyon	Açıklama
Doğrusal		$f(x) = x$	Doğrusal aktivasyon fonksiyonu, etkinleştirmenin girdiyle orantılı olduğu fonksiyondur.
Sigmoid		$f(x) = \frac{1}{1 + e^{-x}}$	Bu fonksiyon herhangi bir gerçekteğer girdi olarak alır ve 0 ile 1 aralığındaki değerleri verir. Fonksiyon sürekli ve türevlenebilir olduğu için düzgün bir gradyan sağlar, yani çıktı değerlerinde sıçramaları önler.
Tanh		$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Tanh aktivasyon fonksiyonunun çıktısı sıfır merkezlidir; bu nedenle, çıktı değerlerini güçlü bir şekilde negatif, nötr veya güçlü bir şekilde pozitif olarak kolayca eşleyebilir.
Doğrultulmuş Lineer Birim (ReLU)		$f(x) = \max(0, x)$	ReLU bir türev fonksiyonudur. Tüm nöronları aynı anda etkinleştirmez. Doğrusal dönüşümün çıktısı 0'dan küçükse nöronlar devre dışı bırakılır. Yalnızca belirli sayıda nöron etkinleştirildiğinden, sigmoid ve tanh fonksiyonların göre hesaplama açısından çok daha verimlidir.
Sızıntı (Leaky) ReLU		$f(x) = \max(0.1x, x)$	Sızıntı ReLU, ReLU'ya dayalı bir aktivasyon fonksiyonu türüdür, ancak negatif değerler için düz bir eğim yerine küçük bir eğime sahiptir. Eğim katsayısı eğitimden önce belirlenir. ReLU'dan farklı olarak, negatif kısımda fonksiyonun türevi sıfırdan farklı olduğu için negatif bölgede de öğrenme işlemi gerçekleştirilebilir.
Parametrik ReLU (PReLU)		$f(x) = \max(ax, x)$	PReLU, geleneksel ReLU'yu negatif değerler için bir eğimle genelleştiren bir aktivasyon fonksiyonudur. PReLU, fonksiyonun negatif kısmının eğimini a argümanı olarak sağlar. Geri yayılım yapılarak a'nın en uygun değeri öğrenilir.

Tablo 4.2. (Devam) Aktivasyon fonksiyonları

Aktivasyon Fonksiyonu	Grafik	Fonksiyon	Açıklama
Üstel Doğrusal Birim (Exponential Linear Unit, ELU)		$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases}$	ReLU'ların aksine, ELU'lar, ortalama birim aktivasyonlarını toplu normalleştirme gibi sifıra yaklaştırmalarına, ancak daha düşük hesaplama karmaşıklığına sahip olmalarına izin veren negatif değerlere sahiptir. Sıfıra doğru ortalama kaymalar, azaltılmış sapma kaydırma etkisi nedeniyle normal gradyanı birim doğal gradyana yaklaştırarak öğrenmeyi hızlandırır.
Softmax		$softmax(z_i) = \frac{\exp(z_i)}{\sum \exp(z_i)}$	Softmax aktivasyon fonksiyonu, sigmoid fonksiyonuna benzer yapıdadır. Sınıflandırma işlemi sırasında giriş değerinin hangi sınıfa ait olduğunu ve olasılık olarak hangi sınıfta olduğunu tespit etmek için kullanılmaktadır.
Swish		$f(x) = x * sigmoid(x)$	Swish, görüntü sınıflandırması ve makine çevirisi gibi çeşitli zorlu alanlara uygulanan derin ağlarda sürekli olarak ReLU ile aynı veya ondan daha iyi performans gösterir. Parçalı doğrusal bir fonksiyon olan ReLU'nun aksine Swish düzgün sürekli bir fonksiyondur.
Ölçekli Üstel Doğrusal Birim (Scaled Exponential Linear Unit, SELU)		$f(\alpha, x) = \lambda \begin{cases} \alpha(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases}$	SELU, kendi kendini normalleştiren ağlarda tanımlanmıştır ve her katmanın önceki katmanlardan ortalamayı ve varyansı koruduğu anlamına gelen dahili normalleştirme ile ilgilenir. SELU, ortalama ve varyansı ayarlayarak bu normalleştirmeyi sağlar.

4.4.3.3. Optimizasyon Algoritması

Optimizasyon, maksimum ve minimum fonksiyon değerlendirmesiyle sonuçlanan modeli yinelemeli olarak eğittiğimiz süreçtir. Eniyileme, model tarafından üretilen sonuç değeri ile gerçek değer arasındaki farkı minimize etmek için kullanılan yöntemdir. Optimizasyon algoritmasının performansı, modelin eğitim verimliliğini doğrudan etkiler. En popüler algoritmalarından biri gradyan azalmasıdır (gradient descent). Bu algoritmanın amacı, fonksiyona ait parametreleri devamlı güncelleyerek fonksiyonun minimum değerine ulaşmaktır. Tipik olarak gradyan azalmanın üç türü vardır.

4.4.3.3.1. Toplu Gradyan Azalma

Toplu gradyan azalma (Batch Gradient Descent), bir fonksiyondaki rastgele bir noktadan başlayan ve o fonksiyonun en alt noktasına ulaşana kadar kademeli olarak eğiminden aşağı inen yinelemeli bir algoritmadır. Gradyan azalmanın her yinelemesinde maliyet fonksiyonunun gradyanını hesaplamak için tüm veri kümesi kullanılır ve ardından ağırlıklar güncellenir. Tüm veri setini tek seferde kullandığı için yavaştır ve bellek problemlerine yol açar. Hesaplama maliyeti yüksek olmasına rağmen diğer gradyan azalma türlerine göre daha karardır. Maliyet fonksiyonunun θ parametresine bağı olarak gradyanının hesaplaması Denklem (4.6)'da gösterilmiştir (Ruder, 2016).

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t) \quad (4.6)$$

$\theta \in \mathbb{R}^d$ model parametreleri, η öğrenme katsayısı ve $\nabla_{\theta} J(\theta)$ parametrelere bağı hedef fonksiyon eğimini belirtmektedir.

4.4.3.3.2. Olasılıksal Gradyan Azalma

Olasılıksal gradyan azalma (Stochastic Gradient Descent, SGD), her eğitim örneğı $x^{(i)}$ ve etiket $y^{(i)}$ için bir parametre güncellemesi yapar. Tüm eğitim verisi yerine sadece eğitim örneğini alarak ağırlık güncellemesi yaptığı için toplu gradyan azalmaya göre çok daha verimlidir. SGD, hesaplamaları büyük ölçüde azaltmak için her yinelemede tüm veri kümesinden rastgele bir veri noktası seçer. Matematiksek olarak Denklem (4.7)'de olduğu gibi ifade edilebilir (Ruder, 2016).

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t; x^{(i)}; y^{(i)}) \quad (4.7)$$

SGD'de, her yineleme için veri kümesinden yalnızca bir örnek rastgele seçildiğinden, minimuma ulaşmak için algoritmanın izlediğı yol genellikle toplu gradyan azalmadan daha gürültülüdür. Bu sebeple minimuma ulaşmak için genellikle daha fazla sayıda yineleme gerektirir. Buna rağmen toplu gradyan azalmaya göre hesaplama açısından çok daha ucuzdur.

4.4.3.3.3. Mini Toplu Gradyan Azalma

Mini toplu gradyan azalma (Mini-Batch Gradient Descent), model hatasını hesaplamak ve model katsayılarını güncellemek için eğitim veri setini küçük gruplara bölen gradyan

azalma algoritmasının bir varyasyonudur. Modelin güncellenme sıklığı toplu gradyan azalma yöntemine göre daha fazladır. Mini toplu gradyan azalma, SGD'nin sağlamlığı ile toplu gradyan azalmanın verimliliği arasında bir denge kurmaya çalışır. Hesaplama işlemi Denklem (4.8)'de olduğu gibi ifade edilebilir (Ruder, 2016):

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} J(\theta_t; x^{(i,i+n)}; y^{(i,i+n)}) \quad (4.8)$$

4.4.3.3.4. Gradyan Azalma Optimizasyon Algoritmaları

Bu gradyan azalma türleri ile birlikte çeşitli optimizasyon algoritmaları kullanılabilir. Gradyan azalma optimizasyon algoritmalarında kullanılan fonksiyonlar Tablo 4.3'de verilmiştir.

Tablo 4.3. Gradyan azalma optimizasyon algoritmaları

Optimizasyon Algoritması	Fonksiyon ¹	Açıklama
Momentum	$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta)$ $\theta_{t+1} = \theta_t - v_{t+1}$	Momentum, önceki adımların bilgisini kullanarak bir sonraki adımın yönünü bilmeye ve salınımları önlemeye yardımcı olur. Bu yöntem, gradyanların üstel ağırlıklı ortalamasını dikkate alarak gradyan azalma algoritmasını hızlandırmak için kullanılır. Ortalamaları kullanmak, olağandışı yönlere doğru olan gradyanlar iptal edildiğinden, algoritmanın minimuma daha hızlı yakınsamasını sağlar.
Nesterov Hızlandırılmış Gradyan (NAG)	$v_{t+1} = \gamma v_t + \eta \nabla_{\theta} J(\theta - \gamma v_t)$ $\theta_{t+1} = \theta_t - v_{t+1}$	Standart momentum yöntemi öncelikle mevcut konumdaki gradyanı hesaplar ve ardından düzeltilmiş toplam gradyan yönünde büyük bir sıçrama yapar. Buna karşılık NAG momentumu, önce bir önceki toplam gradyan yönünde büyük bir sıçrama yapar ve ardından bittiği yerde gradyanı ölçer ve bir düzeltme yapar.
Adagrad	$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} g_{t,i}$	Adagrad algoritması, sık sık meydana gelen özelliklere dayalı olarak ağırlıklarda küçük güncellemeler yaptığından, seyrek verilerle uğraşırken iyi çalışır. Adagrad'da her zaman adımında her parametre güncellemesi için farklı öğrenme oranları kullanılmaktadır. Algoritma, sık olmayan özellikler için daha büyük öğrenme oranları ve sık görülenler için küçük öğrenme oranları kullanır. Adagrad optimize ediciyi kullanmanın en büyük avantajı, öğrenme hızının manuel olarak ayarlanmasına gerek olmamasıdır.

Tablo 4.3.(Devam) Gradyan azalma optimizasyon algoritmaları

Optimizasyon Algoritması	Fonksiyon ¹	Açıklama
RMSprop	$E[g^2]_t = 0,9E[g^2]_{t-1} + 0,1g_t^2$ $\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t$ $g_t = \nabla_{\theta_t} J(\theta_t)$	RMSprop (Root Mean Square Propagation) optimize edici, momentumlu gradyan azalmaya ve Adagrad optimize ediciye benzer, ancak parametre güncellemesi için farklı bir yöntem kullanır. RMSprop'ta dikey yöndeki salınımlar, algoritmanın yatay yönde daha büyük adımlar atabilmesi için sınırlandırılmıştır. Algoritma, en son gözlemlenen gradyanlara odaklanmasına izin veren bir azalan hareketli ortalama kullanır. Ayrıca, RMSprop uyarlanabilir bir öğrenme hızı kullanır, bu da öğrenme hızının bir hiperparametre olmadığı ve zamanla değiştiği anlamına gelir.
Adadelata	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t$	Adadelata, SGD için boyut başına öğrenme oranı yöntemine izin veren stokastik bir optimizasyon tekniğidir. Agresif ve monoton bir şekilde azalan öğrenme oranını düşürmeye çalışan Adagrad'ın bir uzantısıdır. Adadelata, geçmişteki tüm eğimlerin karelerini toplamak yerine, birikmiş geçmiş eğimlerin karelerini sabit bir boyutla sınırlar. Matematiksel olarak RMSprop ile aynı görünse de, Adadelata her adımda öğrenme hızını güncellemez.
Uyarlamalı Moment Tahmini (Adam)	$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t$ $v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$ $\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$ $\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t$	Adam, hem Adagrad hem de RMSprop optimizasyon algoritmalarının avantajlarını miras alan klasik olasılıksal gradyan azalma algoritmasının gelişmiş versiyonudur. Ortalama birinci momentuma (ortalama) ve ortalama ikinci momentuma (varyans) dayalı öğrenme oranlarını uyarlar. Adam, makine öğrenmesi ve derin öğrenme alanında popüler bir algoritmadır ve çoğu problem için başarılı sonuçlar verir. Birçok durumda olağanüstü performansı nedeniyle varsayılan algoritma olarak kullanılır. Varsayılan değerler β_1 için 0.9, β_2 için 0.999 ve ϵ için 10^{-8} olarak belirtilmiştir.
Adamax	$u_t = \beta_2^\infty v_{t-1} + (1 - \beta_2^\infty) g_t ^\infty$ $= \max(\beta_2 \cdot v_{t+1}, g_t)$ $\theta_{t+1} = \theta_t - \frac{\eta}{u_t} \hat{m}_t$	Adamax algoritması, optimizasyon için sonsuzluk veya maksimum norm kullanan Adam optimize edicinin bir varyasyonudur. Adamax, gradyan güncellemeleri açısından geleneksel olarak kararsız olan verilerle Adam'dan daha iyi performans gösterir.
Nadam	$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \left(\beta_1 \hat{m}_t + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right)$	Bu algoritma Adam ile NAG algoritmasının bir kombinasyonudur. NAG momentumlu Adam'dır ve Adam'dan biraz daha hızlı eğitim süresi sağlar.

Tablo 4.3.(Devam) Gradyan azalma optimizasyon algoritmaları

Optimizasyon Algoritması	Fonksiyon ¹	Açıklama
AdamW	$\theta_{t+1} = \theta_t - \eta \left(\frac{1}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t + g_t \theta_t \right)$	ADAMW (Decoupled Decay Regularization) optimize edici, Sinir Ağlarının optimizasyon sürecinde ağırlıkların bozulmasına dayalı bir düzenleme eklemeye çalışır. Düzenleme, yeni veriler mevcut olduğunda başarıyla kullanılabilir daha basit modeller üretmek için kayıp fonksiyonuna bir ceza eklenmesinden oluşur.
QHAdam	$\theta_{t+1} = \theta_t - \eta \left[\frac{(1 - v_1) \cdot g_t + v_1 \cdot \hat{m}_t}{\sqrt{(1 - v_2)g_t^2 + v_2 \cdot \hat{v}_t + \epsilon}} \right]$	QHAdam (Quasi-Hyperbolic Adam), momentum güncellemesini ve kare gradyan güncellemesini, mevcut güncelleme mekanizmasından ayırır ve bunun yerine yarı hiperbolik bir formülasyonu kullanır. Bu, paydada bir sabit tarafından indirgenen mevcut ve önceki gradyanların ağırlıklı ortalamasını ve başka bir sabit tarafından indirgenen mevcut ve önceki kare gradyanların başka bir ağırlıklı ortalamasını kullanır.

¹ $\theta \in \mathbb{R}^d$: Model parametreleri; η : Öğrenme katsayısı; $\nabla_{\theta} f(\theta)$: Hedef fonksiyonunun eğimi; $G_{t,ii}$: her bir diyagonal elemanı, θ_i parametresine göre, t. iterasyona kadar hesaplanmış eğim değerlerinin kareleri toplamı; ϵ : öğrenme katsayısının 0'a bölünmesini engellemek için atanan sabit değer; g_t : Kayıp fonksiyonu ve t anındaki ağırlıkların türevinin oranı; m_t : Gradyanların 1.momentinin (ortalama) tahmini; v_t : Gradyanların 2.momentinin (merkezlenmemiş varyans) tahmini; β_1 : 1.momentin bozulma oranı; β_2 : 2.momentin bozulma oranı; $\hat{m}_t$: 1.momentin sapması düzeltilmiş değeri; $\hat{v}_t$: 2.momentin sapması düzeltilmiş değeri

4.4.3.4. Epok (Eğitim Dönem) Sayısı ve Paket Boyutu

Bir epok, tüm eğitim veri kümesinin sinir ağı üzerinden yalnızca bir kez ileri ve geri yönde geçirildiği zamandır. Epok sayısı bu işlemin kaç kez yapılacağını belirten bir hiperparametredir ve değeri problem türüne göre değişiklik gösterir. Epok sayısı arttıkça modelin başarısı büyük oranda artmaktadır. Eğer modelin başarısı belli bir epoktan sonra çok az artış gösterirse veya hiç artış göstermezse bu noktalarda eğitim sonlandırılabilir.

Paket boyutu (batch size), dahili model parametrelerini güncellemeden önce üzerinde çalışılacak örnek sayısını tanımlayan bir hiperparametredir. Tüm veri setini bir defada sinir ağından geçirmek yerine, paket boyutu kadar parçalara bölerek geçirmek daha verimli olabilir. Bir epok bir veya birden fazla paketten oluşur. Paket boyutu arttıkça, ihtiyaç duyulan hafıza miktarı da artar. Yüksek paket boyutu seçilmesi her iterasyon (yineleme sayısı) için kullanılacak eğitim örneğinin de büyümesi demektir. İterasyon, bir epogu tamamlamak için belirlenen paket boyutuna göre gereken parti sayısıdır. 1000 adet

veriden oluşan bir veri seti için paket boyutu 200 seçilirse, bir epoğu tamamlamak için beş iterasyon gereklidir.

4.4.3.5. Ağırlık Başlatma

Sinir ağlarını kurarken ve eğitirken, yüksek doğrulukta bir model sağlamak için ağırlıkları uygun şekilde başlatmak çok önemlidir. Sinir ağlarındaki düğümler, girdilerin ağırlıklı toplamını hesaplamak için kullanılan ağırlıklar olarak adlandırılan parametrelerden oluşur. Sinir ağı modelleri, kayıp fonksiyonunu en aza indirmek için ağırlıklarını kademeli olarak değiştiren bir optimizasyon algoritması kullanır. Bu optimizasyon algoritması, optimizasyon sürecine başlamak için olası ağırlık değerleri alanında bir başlangıç noktası gerektirir. Ağırlık başlatma, bir sinir ağının ağırlıklarını, sinir ağı modelinin optimizasyonu (öğrenme veya eğitim) için başlangıç noktasını tanımlayan küçük rastgele değerlere ayarlamak için bir prosedürdür. Ağırlık başlatmanın amacı, derin bir sinir ağı boyunca ileri geçiş sırasında katman aktivasyon çıktılarının patlamasını veya kaybolmasını önlemektir.

Tüm ağırlıkları 0 veya sabit bir değerle başlatmak, nöronlar her yineleme esnasında aynı özellikleri öğrendiği için oldukça etkisizdir. Ağırlıkların rastgele değerler olarak başlatılması ise, farklı güncelleme değerlerinin üretilmesini ve ağırlıkların birbirlerinden farklı şekillerde ağıra adapte olmalarını sağlayacaktır. Fakat bu durumda da aşırı öğrenme, kaybolan gradyan veya patlayan gradyan gibi problemler oluşabilir. Sabit ve rastgele ağırlık başlatma dışında Xavier/Glorot (Glorot vd., 2011), He düzgün, He normal (K. He vd., 2014) gibi farklı ağırlık başlatma teknikleri bulunmaktadır.

4.4.3.6. Başarım İyileştirme

Başarım iyileştirme (Regularization) teknikleri, aşırı öğrenmeyi önleyerek modelin başarısını artırmak amaçlı kullanılmaktadır. Ağıra aşırı öğrenme durumu, girdinin gürültüsü ile birlikte öğrenilmesiyle meydana gelir. Başarım iyileştirme teknikleri, aynı zamanda modelin başarısını düşürmeden karmaşıklığını azaltmak için de kullanılmaktadır. Aşırı öğrenmeyi azaltmak için en sık kullanılan tekniklerden biri veri sayısını artırmaktır. Bunun dışında L1 ve L2 düzenlemesi, dropout, ağırlık sıfırlama gibi farklı başarım iyileştirme teknikleri de bulunmaktadır.

4.4.3.6.1. L1 ve L2 Düzenlemesi

L1 ve L2 düzenlemesi en çok kullanılan başarımları iyileştirme yöntemleridir. L1 düzenleme yönteminde, parametrelerin mutlak değerlerinin toplamını azaltmak için fonksiyona düzenleme terimi eklenir. L2 tekniğinde ise, parametrelerin karelerinin toplamını azaltmak için düzenleme terimi eklenir. Eklenen yeni terimler sayesinde, daha küçük ağırlık matrislerine sahip bir sinir ağı daha basit modellere yol açtığı için ağırlık matrislerinin değerleri azalır. Bu nedenle, aşırı öğrenme de büyük ölçüde azaltılmış olur.

4.4.3.6.2. Seyreltme

Seyreltme (Dropout), eğitim sırasında rastgele seçilen nöronların aktivasyon değerlerini sıfırlayan bir düzenleme tekniğidir. Bu değer, ağı, ağıdaki küçük bir nöron alt kümesinin tahmin yeteneğine güvenmek yerine daha sağlam özellikler öğrenmeye zorlar. Tam bağlı katmanlarda belli eşik değerinin altındaki düğümlerin seyriltilmesi ya da farklı bir deyişle zayıf bilgilerin unutulmasının sağlanması öğrenimi arttırmaktadır. Dropout değeri [0,1] aralığında bir değer olarak tanımlanmaktadır. Tüm katmanlarda aynı dropout değeri kullanılması zorunlu değildir, farklı değerler kullanılabilir.

4.4.3.6.3. Ağırlık Sıfırlama

Ağırlık sıfırlama (Dropconnect), olasılıklı aktivasyonlar yerine ağırlıkları rastgele düşürerek dropout işlemini genelleştirir. Ağırlık sıfırlama ve dropout, model içinde dinamik seyriltilme sağladığı için birbirlerine benzerler. Fakat dropout, her katmanda rastgele seçilen bir aktivasyon alt kümesini sıfıra ayarlarken, ağırlık sıfırlama, ağı içinde rastgele seçilen bir ağırlık alt kümesini sıfıra ayarlar. Ağırlık sıfırlama işlemi ile tam bağlantılı katman, eğitim aşamasında bağlantıların rastgele seçildiği seyrek bağlantılı bir katman haline gelir.


4.4.3.6.4. Erken Durdurma

Erken durdurma (Early Stopping), veri setini eğitim ve test setlerine bölerek ve ardından eğitim setinde çapraz doğrulama kullanarak veya veri setini eğitim, doğrulama ve test setlerine bölerek yapılabilir. Erken durdurmada, algoritma eğitim seti kullanılarak eğitilir ve eğitimin durdurulacağı nokta doğrulama setinden belirlenir. Doğrulama setindeki

performansın kötüleşmeye başladığı anda model üzerindeki eğitimin erken durdurulması, modelin eğitim verilerine fazla uymaya başlamasını veya gürültüyü öğrenmesini engeller.

4.5. Transfer Öğrenme

Transfer öğrenme (transfer learning), daha önce bir alanda öğrenilen bilginin, sınıflandırma ve öznitelik çıkarma amacıyla başka bir alana aktarılması olarak tanımlanmaktadır. Ağırlıklarının sıfırdan başlatılmadığı bir CNN'i hızlı ve doğru bir şekilde eğitmek için kullanılan derin öğrenme tekniğidir. Transfer öğrenme daha evvel büyük bir veri kümesiyle eğitilmiş derin CNN modeli kullanılarak gerçekleştirilir. VGG, Inception, ResNet, DenseNet gibi önceden eğitilmiş (pre-trained) CNN modelleri milyonlarca görüntü kullanılarak eğitilmiş oldukları için sahip oldukları bilgiyi (ağırlıklar, parametreler) kullanarak küçük veri kümeleri başarılı bir şekilde eğitebilir (Zhuang vd., 2021). Transfer öğreniminin başlıca avantajları arasında sınırlı veriye sahip veri kümeleri üzerinde dahi çalışması, eğitim süresini kısaltması ve sinir ağları için daha iyi performans sağlaması yer alır. Transfer öğrenme birçok derin öğrenme uygulamasında kullanılmaktadır. Çünkü önceden eğitilmiş bir CNN modeline ince ayar yapmak genellikle sıfırdan rastgele başlatılan ağırlıklara sahip bir CNN modelini eğitmekten çok daha hızlı ve kolaydır. Genel olarak CNN modellerinde, başlangıç katmanlarında kenarlar, eğriler, köşeler, renk tonları, gölgeler ve dokular gibi özellikler öğrenilirken, son katmanlarda soyut ve spesifik özellikler gibi daha karmaşık özellikler öğrenilir (Zhuang vd., 2021). Transfer öğrenme mekanizması, Şekil 4.4'de gösterildiği gibi büyük veri setleri üzerinde önceden eğitilmiş bir modelin ağırlık ve parametreler gibi öğrenim bilgilerinin yeni oluşturulacak modele aktarımı şeklinde olmaktadır. Yeni tasarlanan modelde, önceden eğitilmiş CNN modelinin ilk katmanlarındaki ağırlıklar sabit tutularak son katmanların yeniden eğitilmesi ve veri setine uygun şekilde eğitim parametreleri üzerinde ince ayarlar yaparak performansın artırılması hedeflenmektedir. Veri kümesi boyutu sıfırdan yeni bir modeli eğitmek için yetersiz olduğunda, aktarılan modelin belirli katmanlarını sabit tutmak ve diğerlerini yeniden eğitmek verimli olabilir. Böylece, aktarılan model zaten büyük veri kümeleriyle eğitilmiş olduğundan, çok daha küçük eğitim verileriyle sağlam bir makine öğrenimi modeli oluşturulabilir. Ayrıca, yeni bir derin sinir ağı eğitmek için gereken süreyi azalttığı için eğitim süresi en aza indirilir.




Şekil 4.4. Transfer Öğrenme Mekanizması (Kılıç ve İner, 2022)

Transfer öğreniminin amacı, bir kaynak etki alanı kullanarak bir hedef görevin performansını artırmaktır. Fakat transfer öğrenme her zaman performansı artırmayabileceği gibi mevcut performansın düşmesine de neden olabilir. Bu duruma negatif aktarım denir. Burada model performansının düşmesinin çeşitli sebepleri olabilir. Kaynak model ile hedef modelin görevleri birbirinden çok farklı olabilir veya transfer edilen yöntemle kaynak ve hedef modeller arasındaki ilişki tam olarak ifade edilemiyor olabilir. Transfer öğrenmenin başarılı olabilmesi için kaynak ve hedefin bir şekilde ilişkili olduğu varsayılır. Ne kadar az ilişkili olurlarsa, etki alanları arası gürültü o kadar fazla yaşanır ve daha az performans artırıcı bilgi tanımlanır. (Rosenstein vd., 2005), farklı alanlar arasında aktarımın nasıl performans kaybına neden olduğunu ve etiketli eğitim örneklerinin sayısı arttıkça negatif aktarım şansının da azaldığını göstermiştir. Transfer öğrenmede, Şekil 4.5’de de gösterildiği üzere, öznitelik çıkarıcı ve model uyarlama (ince ayar) şeklinde iki ana yaklaşım bulunmaktadır.

4.5.1. Öznitelik Çıkarma

Transfer öğrenme bir öznitelik çıkarıcı olarak kullanılabilir. Bu yaklaşım, sınıflandırıcı görevi gören orijinal tam bağlantılı katmanları kaldırmak, tüm ağ ağırlıklarını dondurmak, önceden eğitilmiş katmanları öznitelik çıkarımı amaçlı kullanmak ve ardından tam bağlantılı bir katman veya başka bir sınıflandırma katmanı

eklemektir. Bu durumda, önceden eğitilmiş bir CNN modelinin evrişim katmanları ağırlık değerleri, öznitelik vektörleri olarak sınıflandırma katmanına verilir. Sınıflandırma katmanı, bir yapay sinir ağı veya SVM gibi doğrusal bir sınıflandırıcı olabilir. Bir modeli eğitmek için çok az verinin olduğu durumlarda, bu tür transfer öğrenimi, bir modeli overfitting (aşırı öğrenme) olmadan eğtmek için en önemli seçenek olabilir. Çünkü eğitilecek daha az parametreye sahip olmak aynı zamanda aşırı öğrenme riskini de azaltır. Öznitelik çıkarıcı olarak kullanım, bir sinir ağının eğitimine ihtiyaç duymaması ve çıkarılan özniteliklerin mevcut görüntü analiz süreçlerine entegre edilmesini kolaylaştırması açısından kolaylık sağlamaktadır (Cheplygina vd., 2019).



Şekil 4.5. Transfer Öğrenme Yaklaşımları

4.5.2. Model Uyarlama (İnce Ayar)

Model uyarlama, önceden eğitilmiş bir modelin farklı bir göreve uygun hale getirilmesi için model ağırlıklarının düzenlenmesidir. Model uyarlama yaklaşımında iki strateji vardır. Birinci strateji, orijinal tam bağlantılı katmanları kaldırmak, çok küçük bir öğrenme oranı kullanarak tüm ağ ağırlıklarına ince ayar (fine tuning) yapmak ve yeni

göreve uyan yeni bir sınıflandırma katmanı eklemektir. İkinci strateji ise, tam bağlantılı katmanları kaldırmak, alt katmanları donmuş halde tutarken yalnızca üst katmanlarda ince ayar yapmak ve ardından yeni göreve uygun yeni bir sınıflandırma katmanı eklemektir.

4.6. Önceden Eğitilmiş Derin Öğrenme Modelleri

ImageNet, bilgisayarlı görü ve derin öğrenme araştırma çalışmaları için tasarlanmış, açıklamalı fotoğraflardan oluşan geniş bir veri setidir. Bu veri seti, yaklaşık 14 milyon görüntü, 21000'den fazla grup veya sınıf ve sınırlayıcı kutu açıklamalarına sahip 1 milyondan fazla görüntüden oluşur. Dünya çapında bir yarışma olan ImageNet büyük ölçekli görsel tanıma yarışması (ImageNet Large Scale Visual Recognition Challenge, ILSVRC) ile başarılı derin öğrenme mimarilerinin sayısı artmaktadır. Tablo 4.4, önceden eğitilmiş derin öğrenme modellerinin boyutunu, derinliğini, parametre sayısını ve girdi boyunu göstermektedir.

Tablo 4.4. Önceden eğitilmiş derin öğrenme modelleri

Model	Yıl	Boyut (MB)	Parametre Sayısı (Milyon)	Derinlik	Girdi Boyutu
AlexNet	2012	217	61	8	224 × 224
ZFNet	2013		62	7	224 × 224
Googlenet (InceptionV1)	2014	40	7	27	224 × 224
VGG16	2014	528	138.4	16	224 × 224
VGG19	2015	549	143.7	19	224 × 224
InceptionV3	2015	92	23.9	189	299 × 299
ResNet50	2015	98	25.6	107	224 × 224
ResNet101	2015	171	44.7	209	224 × 224
ResNet152	2015	232	60.4	311	224 × 224
NASNetLarge	2015	343	88.9	533	331 × 331
Resnet50V2	2016	98	25.6	103	224 × 224
Resnet101V2	2016	171	44.7	205	224 × 224
Resnet152V2	2016	232	60.4	307	224 × 224
InceptionResNet	2016	215	55.9	449	299 × 299
Xception	2017	88	22.9	81	299 × 299
MobileNet	2017	16	4.3	55	224 × 224

Tablo 4.4.(Devam) Önceden eğitilmiş derin öğrenme modelleri

Model	Yıl	Boyut (MB)	Parametre Sayısı (Milyon)	Derinlik	Girdi Boyutu
DenseNet169	2017	57	14.3	338	224 × 224
DenseNet121	2017	33	8.1	242	224 × 224
DenseNet201	2017	80	20.2	402	224 × 224
NASNetMobile	2018	23	5.3	389	224 × 224
MobileNetV2	2018	14	3.5	105	224 × 224
EfficientNetB0	2019	29	5.3	132	224 × 224
EfficientNetB4	2019	75	19.5	258	224 × 224
EfficientNetB7	2019	256	66.7	438	224 × 224
EfficientNetV2S	2021	88	21.6	-	224 × 224
EfficientNetV2M	2021	220	54.4	-	224 × 224
EfficientNetV2L	2021	479	119	-	224 × 224

4.6.1. AlexNet

(Krizhevsky vd., 2012) tarafından geliştirilen AlexNet, 2012 yılında yapılan ILSVRC yarışmasında birinci olmuş, örüntü tanımada hata oranını %26'lardan %15'lere düşürmüştür. Beş evrişim katmanına ve üç yoğun katmana sahip AlexNet mimarisinde her evrişim katmanından sonra bir aktivasyon katmanı olan ReLU katmanı kullanılmaktadır. Bu ağın ana avantajı, dikkate alınan diğer ağlara kıyasla eğitim sürecinin hesaplama açısından verimli olmasıdır.

4.6.2. GoogleNet (InceptionV1)

Geleneksel CNN'lere kıyasla hesaplama karmaşıklığını azaltmayı amaçlayan ve InceptionV1 olarak da bilinen GoogleNet, (Szegedy vd., 2015) tarafından geliştirilmiştir. Başlangıç (inception) bloğu adı verilen temel bir modül kullanır. Başlangıç modülleri, boyutsallığını azaltmak için evrişimli bir katman içinde kısmi bağlantılar sunar. GoogleNet, havuzlama katmanları da dahil olmak üzere toplam 27 katman derinliği ve yedi milyon parametre ile geniş bir mimari sunar. Girdi olarak kullanılan görüntü 224×224×3 boyutundadır. Evrişim katmanında değişken boyutlu filtreler (1×1, 3×3 ve 5×5) kullanılır. Tam bağlantılı katmanda dropout düzenlemesini kullanır ve tüm evrişim katmanlarında ReLU aktivasyonunu uygular.

4.6.3. VGGNet

VGG, Oxford Üniversitesi'nden (Simonyan ve Zisserman, 2015) tarafından önerilen popüler bir sinir ağı mimarisidir. Ağın girdisi 224×224 boyutlarından oluşan RGB formatında bir görüntüdür. Ön işleme katmanı, 0–255 aralığında piksel değerlerine sahip RGB görüntüsünü alır ve tüm eğitim seti üzerinden hesaplanan ortalama görüntü değerlerini çıkarır. Ön işleme tamamlandıktan sonra görüntüler, küçük alıcı alan filtreleri (3×3) ile bir evrişimli katman yığına geçirilir. Birkaç konfigürasyonda, filtre boyutu 1×1 olarak ayarlanır ve bu, giriş kanallarının doğrusal bir dönüşümü olarak tanımlanabilir. Evrişim işleminin adımı 1'e sabitlenmiştir. Uzamsal havuzlama, birkaç evrişim katmanını takip eden beş maksimum havuzlama katmanı tarafından gerçekleştirilir. Maksimum havuzlama, adım boyutu 2 olarak ayarlanmış bir 2×2 piksel penceresi üzerinde gerçekleştirilir. Tam bağlantılı katmanların konfigürasyonu her zaman aynıdır; ilk iki katmanın her biri 4096 kanala sahiptir, son katman olan softmax katmanında ise 1000 adet nöron kullanılmıştır. VGG ağı için tüm gizli katmanları ReLU aktivasyon fonksiyonu takip eder. VGG mimarisi katman sayısına göre VGG16 (13 evrişim, 3 tam bağlı katman) ve VGG19 (16 evrişim, 3 tam bağlı katman) olmak üzere iki versiyona sahiptir.

4.6.4. InceptionV3

InceptionV3, 24 milyon parametre ile Inception-V1 ağının optimize edilmiş bir versiyonudur (Szegedy vd., 2016). InceptionV3 ağında, başlangıç modülü ince ayarlarla güncellenmiştir. Hesaplama karmaşıklığını optimize etmek ve değişkenlerin başlangıç blokları için çarpma sayısını azaltmak için iki çarpanlara ayırma tekniği sunar. İlk teknik, önerilen parametre sayısını ve filtrelerin boyutunu 5×5 ve 7×7 'den 3×3 'e düşürmek için büyük filtrelerle ilişkili evrişimlerin çarpanlara ayrılmasıdır. İkinci teknik, asimetrik evrişimlerde uzamsal çarpanlara ayırmadır. Mimari, hesaplama maliyetini azaltmak için klasik evrişimleri ($N \times N$) asimetrik evrişimlerle ($N \times 1$ ve $1 \times N$) değiştirmeyi önerir.

4.6.5. ResNet

(K. He vd., 2016) tarafından önerilen artık bloklara dayalı bir evrişimsel sinir ağının gelişmiş bir versiyonudur. Bu mimari, doğruluğun doymaya başladığı çok derin ağlarda

görülen gradyan bozulması sorununu çözmeyi amaçlar. Bu sorunu çözmek için ResNet, ağ derinliğini artırmadan doğruluğu artırmak ve CNN derinleşirken bozulmayı önlemek için katmanlar arasına kısayol bağlantıları dahil ederek artık bloklar kavramını sunar. 3×3 evrişim filtresi, küresel ortalama havuzlama, artık bloklar, toplu normalleştirme ve ardından sınıflandırma katmanı kullanır. Hesaplama maliyetini azaltmak ve ResNet'in eğitimini hızlandırmak için, 3×3 evrişim ile tanımlanan darboğaz blokları, 1×1 evrişim, ardından 3×3 evrişim ve başka bir 1×1 evrişim ile değiştirilir. ResNet'in, ResNet50, ResNet101 ve ResNet152 gibi farklı sayıda katman içeren çeşitli varyasyonları bulunmaktadır.

4.6.6. Inception-ResNet

(Szegedy vd., 2017) tarafından geliştirilmiş olup 56 milyon parametreden oluşmaktadır. Inception ve ResNet modüllerinin performansından esinlenerek, Inception mimarilerine eklenen modüller ve ResNet'teki artık bağlantılar arasında bir hibridizasyon sunar. InceptionV3 mimarisindeki başlangıç modüllerinin, artık-başlangıç (Residual-Inception) bloklarıyla değiştirilmesinden oluşur. Giriş ve çıkışın aynı boyutluluğunu elde etmek için başlangıç katmanlarındaki konvolüsyonun çıktısını girişe ekleyerek, orjinal konvolüsyonlardan sonra 1×1 konvolüsyonlar kullanırlar. Bu kombinasyon, Inception ağının öğrenme süresini hızlandırmayı ve bozulma gradyanı sorununu önlemeyi amaçlar.

4.6.7. Xception

2017 yılında Google'dan (Chollet, 2017) tarafından önerilmiştir. Xception mimarisi, 14 modülde yapılandırılmış 36 evrişim katmanından oluşur. Başlangıç bloklarının adaptasyonuna dayalı olarak 23 milyon parametreyi derinlemesine ayrılabilir evrişim katmanlarıyla değiştirerek işler. Artık bağlantılarla, derinlemesine ayrılabilir evrişim, farklı uzamsal girdi boyutlarının (1×1 , 5×5 , 3×3) tek bir boyutla 3×3 ve ardından 1×1 noktasal evrişimle değiştirilmesinden oluşur. Girdi olarak $299 \times 299 \times 3$ boyutundaki görüntüleri kullanır.

4.6.8. MobileNet

(Howard vd., 2017) tarafından önerilen MobileNet, mobil cihazlar ve entegre görüş sistemleri için tasarlanmıştır. 13 derinlikli evrişim ve 13 noktasal evrişim dahil olmak

üzere 28 katmandan oluşur. Derinlemesine evrişim modüllerinin temel amacı ağın boyutunu küçültmektir. MobileNet'te, tüm katmanları toplu normalleştirme ve ReLU takip eder ve son katman, softmax'ı besleyen tam bağlantılı bir katmandır. MobileNet ağı, yanıt süresi, depolama alanı ve kesinlik arasında bir uzlaşma sağlamak için genişlik çarpanı ve çözünürlük çarpanı olmak üzere iki hiperparametre sunar. Genişlik çarpanının rolü, evrişim katmanlarındaki özellik haritalarının sayısını azaltmaktır. Buna karşılık, çözünürlük çarpanı, giriş görüntüsünün çözünürlüğünü azaltarak hesaplama maliyetini düşürür.

4.6.9. DenseNet

DenseNet, (Huang vd., 2017) tarafından CNN modellerinde ilk katmanlar ile sonraki katmanlar arasındaki bağlantıların daha derin, daha doğru ve daha verimli olabileceği konseptine dayalı olarak geliştirilmiştir. Geleneksel CNN'de, tüm katmanlar kademeli olarak birbirine bağlanır ve Denklem (4.9)'da gösterildiği gibi l^{th} katmanın çıktısını $(l + 1)^{th}$ katmana girdi olarak bağlar (Krizhevsky vd., 2012). Bu, ağı daha derin ve daha geniş olmasını zorlaştırır. Daha sonra en az iki katmanı atlayarak kısayol bağlantıları sağlama fikri ile ResNet mimarisi ortaya çıkmıştır (K. He vd., 2016). Denklem (4.10)'da ifade edildiği gibi, ResNet mimarisi, l^{th} katmanın çıktısını evrişim katmanından sonraki çıktıya ekler ve onu $(l + 1)^{th}$ katmanına girdi olarak bağlar.

$$x_l = H_l(x_{l-1}) \quad (4.9)$$

$$x_l = H_l(x_{l-1}) + x_{l-1} \quad (4.10)$$

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (4.11)$$

DenseNet mimarisinde ise Denklem (4.11)'de ifade edildiği gibi her katman önceki tüm katmanların özelliklerini girdi olarak kullanmakta ve katmandaki kendi özelliklerini de sonraki katmanlara girdi olarak vermektedir. DenseNet mimarilerinin avantajı kaybolan gradyan sorununu hafifletmeleri, özellik yayılımını güçlendirmeleri ve özelliğin yeniden kullanılmasına olanak sağlayarak parametre sayısını azaltmasıdır. DenseNet169 modeli evrişim katmanı, dört yoğun blokta $(6+12+32+32) \times 2 = 164$ katman, üç geçiş katmanı ve bir sınıflandırma katmanı olmak üzere toplam 169 katmandan oluşmaktadır. Benzer şekilde, DenseNet201 modeli de evrişim katmanı, dört yoğun blokta

$(6+12+48+32) \times 2 = 196$ katman, üç geiş katmanı ve bir sınıflandırma katmanı olmak üzere 201 katmandan oluşur.

4.6.10. NasNet

Nasnet, Google tarafından önerilen ölçeklenebilir bir CNN mimarisidir (Zoph vd., 2018). Takviyeli öğrenme yöntemini kullanarak optimize edilmiş bir ağı kavramını tanıtır. NasNet, aynı mimariye ve farklı ağırlıklara sahip birden çok kez tekrarlanan hücre adı verilen temel evrişim katmanlarından oluşur. Mimarideki her hücre, giriş görüntülerinin evrişimli, tür, ağırlık veya düzenlileştirme yöntemleri boyutundaki evrişimli hücre sayısında ve filtrelerde sabit olmayan bloklar olarak bilinen farklı küçük birimlerin birleştirilmesini sunar. Bu bloklar, düzenli evrişimler, ayrılabilir evrişimler, maksimum havuzlama ve ortalama havuzlamadan oluşur. Her blok, iki girişı tek bir çıktı özellik haritasına eşleyerek artık bir bağlantı oluşturur. Nasnet'in iki tür evrişim hücresi vardır:

- Normal Hücreler, aynı boyutta bir özellik haritası döndürür ve üç adet 3×3 evrişim katmanı ve iki adet 5×5 derinlikte ayrılabilir evrişim içerir.
- İndirgeme Hücreleri, yükseklik ve genişlikte iki kat azaltılmış bir özellik haritası döndürür. İndirgeme hücreleri bir 3×3 , iki 5×5 ve iki 7×7 derinlikte ayrılabilir evrişim içerir.

4.6.11. EfficientNet

(Tan ve Le, 2019) tarafından geliştirilen EfficientNet, diğer CNN'lere kıyasla parametre boyutunu azaltarak doğruluğı ve verimliliğı optimize eder. EfficientNet'in ana fikri, sabit bileşik ölçekleme katsayılarını (genişlik, derinlik ve görüntü çözünürlüğü) yapılandırılmış bir şekilde kullanarak derin sinir ağı yöntemlerinin farklı boyutlarını ölçeklendirmektir. EfficientNet ailesi, 224×224 giriş boyutuna sahip temel sürüm B0'dan B7'ye kadar sekiz farklı model içerir. B0'dan türetilen her bir versiyonda çözünürlük giriş görüntüsü, her katman için bir dizi özellik haritası (genişlik) ve katman sayısı (derinlik) artırılmıştır.

5. DENEYSEL BULGULAR VE TARTIŞMA

Bu tez çalışmasının temel amacı, incir işleme tesisi gibi gerçek dünya ortamında aflatoksinin tahribatsız, çevrimiçi ve hızlı bir şekilde tespit edilmesini sağlayan yapay zeka tabanlı bir teknik geliştirmektir. Aflatoksinle kontamine olmuş kuru incirlerin tespiti için kullanılabilecek halka açık bir veri seti yoktur. Bu çalışma için Türkiye'nin Ege Bölgesi'ndeki üretim tesislerinden aflatoksin bulaşmış kuru incir örnekleri toplandı ve yeni, özgün veri setleri oluşturuldu. Transfer öğrenme modelleri kullanılarak sınıflandırma ve öznitelik çıkarma çalışmaları yapıldı ve en etkili yaklaşım değerlendirildi. Oluşturulan veri setleri üzerinde aflatoksinli incirlerin tespiti için 2 farklı deneysel çalışma yapıldı. Birinci deneysel çalışma BGYF ışıması gösteren incirlerin tespitine yönelik ve ikinci deneysel çalışma farklı dalga boyundaki ışık kaynakları kullanılarak elde edilen görüntülerden aflatoksinli incirlerin tespitine yöneliktir.

İncir üretim tesislerinde aflatoksinli incirler, çalışanlar tarafından karanlık bir odada ve UV ışık altında BGYF kontrolü yapılarak manuel olarak ayıklanmaktadır. Manuel ayıklama sübjektif kriterlere dayalıdır ve çalışanların uzmanlığına bağlıdır. Ayrıca bu çalışanlar uzun süre UV ışınlarına maruz kaldıkları için cilt kanseri ve göz rahatsızlıkları gibi sağlık sorunları ile karşılaşabilmektedirler (Gallagher ve Lee, 2006). Bu tez çalışmasında aflatoksin bulaşmış incirlerin insan sağlığına zarar vermeyecek şekilde tespiti için uzman çalışanlar kadar etkili ve sağlam yöntemler araştırıldı.

Çalışmanın yapılabilmesi için hazır bir veri seti bulunmadığı için öncelikle veri seti hazırlandı. Bölüm 5.1'de, kuru incir örneklerinin temini, görüntü verilerinin elde edilmesi, referans cihaz ölçümlerinin yapılması ve örneklerin etiketlenmesi sonucunda veri setlerinin oluşturulması konusunda detaylı bilgilendirme yapıldı. Bölüm 5.2 ve 5.3'de sırasıyla, modellerin karşılaştırılması için kullanılan performans metriklerinden ve modellerin geliştirildiği ortam ve veri setindeki verilerin çoğaltılması işlemlerinden bahsedildi. Tez kapsamında iki farklı çalışma yapıldı. Bunlardan BGYF tespiti için yapılan çalışmalardan Bölüm 5.4'de, farklı dalga boylarındaki ışık kaynakları kullanılarak yapılan aflatoksin tespitinden ise Bölüm 5.6'da bahsedildi. İncir üretim tesislerinde kullanılmakta olan BGYF yöntemi ile aflatoksin arasındaki korelasyon ile ilgili yapılan çalışma ve elde edilen sonuçlar ise Bölüm 5.5'de belirtildi.

5.1. Veri Setinin Oluşturulması

5.1.1. İncir Numunelerinin Temini

Deneysel çalışmaların gerçekleştirilebilmesi için Ege Bölgesi'ndeki kuru incir üretim tesislerinden 400 adet incir örneği temin edildi. İlk olarak incirler uzman çalışanlar tarafından UV ışık altında BGYF gösteren ve göstermeyen olarak sınıflandırıldı. Daha sonra Şekil 5.1'de gösterilen cihaz kullanılarak floresans emisyonları incelendi ve incirler BGYF ışımlarına göre dört gruba (yüksek, orta, düşük ve sıfır) ayrıldı. Dengeli dağılmış verilerden oluşan veri setleri oluşturabilmek için, her gruptan rastgele 25 adet incir seçildi. Oluşturulan veri setlerinin her biri iki adet sınıftan (BGYF(+)/BGYF(-) veya AF(+)/AF(-)) oluşsa da, bu iki sınıftaki verilerin de dengeli bir şekilde dağılması sınıflandırma doğruluğu açısından çok önemlidir. Çünkü verilerin çoğunluğu yüksek veya orta BGYF gösteren örneklerden oluşuyorsa sınıflandırma doğruluğu yüksek olabilirken, düşük BGYF gösteren örneklerden oluşuyorsa daha düşük sınıflandırma doğruluğu elde edilebilir. Veya AF(+) sınıfındaki verilerin büyük bir çoğunluğu çok yüksek konsantrasyonlu incirlere sahip olursa, oluşturulan model yüksek aflatoksin konsantrasyonlu incirlerin tespitinde çok iyi fakat düşük konsantrasyonlu incirlerin tespitinde zayıf kalabilir. Son olarak seçilen 100 incir numaralandırıldı, ayrı plastik torbalara yerleştirildi ve 4°C'de saklandı.

5.1.2. Görüntülerin Elde Edilmesi


İncirlerin görüntülerini elde etmek için 250 nm ile 1000 nm arasında değişen farklı dalga boylarında ışık kaynaklarına, optik filtreler ve 15 megapiksel (mp) renkli CMOS kameraya sahip bir sistem kullanıldı. Görüntüler aynı optik koşullar ve parametreler altında elde edildi. İncirler cihaz yüzeyinin ortasına yerleştirilen ve dört taraftan 50° açıyla konumlandırılan LED ışık kaynakları ile aydınlatıldı. Görüntüler, cihazın yüzeyine göre 90° açıyla konumlandırılan bir kamera ile elde edildi. İstenmeyen ortam ışığını önlemek için cihazın kapakları kapatılarak karanlık bir ortam oluşturuldu. Görüntüleri elde etmek için kullanılan optik sistem Şekil 5.1'de gösterilmektedir.



Şekil 5.1. İncir görüntülerinin alındığı optik sistem (Kılıç ve İner, 2022)

Işık spektrumunda 100-400 nm dalga boyu aralığı (100-280 UVC, 280-315 UVB, 315-400 UVA) UV bölgesi, 400-700 nm aralığı ise görünür bölge olarak tanımlanır. UV bölgesindeki ışık kaynakları insan sağlığına ciddi zararlar vermekte ve UVC bölgesinde bu hasarın etkisi çok yüksek olup, görünür bölgeye yaklaştıkça azalmaktadır (Lawrence vd., 2018). Ayrıca farklı dalga boylarında ışık kaynakları altında çekilen incir görüntülerinden sınıflandırma için farklı öznelilikler tespit edilebilmektedir. Bu nedenle deneysel çalışmamızda 365 nm ışık kaynağı yanında UV/görünür radyasyon sınır bölgesi (385–405 nm) ışık kaynakları ve 420 nm ışık kaynağı kullanıldı. Öncelikle 365 nm (Nichia – 1450 mW), 395nm (Luxeon - 625 mW), 405nm (Luxeon – 675 mW), 420nm (Luxeon - 675 mW) ve beyaz (Luxeon – 6500K, 220lm) LED ışık kaynakları kullanılarak incirlerin ön ve arka yüzey görüntüleri alındı. Aflatoksin kontaminasyonu incirin iç veya dış bölgesinde herhangi bir yerde bulunabileceğinden dolayı, daha sonra alkolle temizlenmiş bir bıçakla ortadan ikiye kesilerek hem iç hem de dış yüzeyleri görüntülendi. Sonuç olarak 100 adet örnek için her ışık kaynağı altında 400 görüntü olmak üzere toplam 2000 görüntü elde edildi. Her bir incir örneğinin elde edilen görüntüsü 2304×1644 piksel çözünürlüğe sahiptir. BGYF ışıması yapan ve yapmayan incir örneklerine ait görüntüler


Şekil 5.2’de verilmiştir. Farklı dalga boylarında ışık kaynaklarıyla aydınlatılan örnek bir incirin görüntüleri de Şekil 5.3’de gösterilmektedir.




Şekil 5.2. BGYF ışıması yapan ve yapmayan incir örnekleri (Kılıç ve İner, 2022)

5.1.3. Referans Cihaz Ölçümleri

İncirlerdeki aflatoksin miktarını kantitatif olarak ölçmek için referans cihaz ölçümleri yapılmıştır. İncirlerin görüntüleri alındıktan sonra, TÜBİTAK Marmara Araştırma Merkezi Gıda Teknolojileri Enstitüsü’nde HPLC cihazı yardımıyla, incirlerdeki AFB₁, AFB₂, AFG₁, AFG₂ ve toplam aflatoksin miktarlarının tespit edilmesi sağlandı. İlk olarak incirler tartılarak ağırlıkları tespit edildi ve sonrasında ekstraksiyon aşamasına geçildi. Yapılan tüm tartım işlemlerinde Mettler Toledo PC-220 Delta Range terazi kullanıldı. Ekstraksiyon aşamasında her bir kuru incir numunesinin 10 gramı için 1 gram sodyum klorür (NaCl) ve 60 ml ekstraksiyon çözeltisi (48 ml metanol, 12 ml saf su) ilave edildi. Ölçümler esnasında kullanılan terazi ve NaCl ve ekstraksiyon çözeltisinin karıştırıldığı cihaz Şekil 5.4’de verilmiştir.



Şekil 5.3. Farklı ışık kaynakları altında örnek incir görüntüsü




Şekil 5.4. Ölçümler esnasında kullanılan terazi ve karıştırıcı cihaz


Elde edilen karışım homojenizatör kullanılarak 3 dakika yüksek devirde karıştırılarak homojenize edildi. Ardından elde edilen karışım Şekil 5.5’de gösterildiği şekilde Whatman filtre kağıdı kullanılarak süzüldü. Bu aşamada HPLC cihazıyla ölçüm yapabilmek için 6 ml süzüntü alındı ve üzerine 60 ml phosphate buffered saline (PBS) (pH 7.4) çözeltisi ilave edildi. Hazırlanan karışım vakum manifoldu yardımıyla afla-Immunoaffinity kolonundan (AflaStar™ R, 3ml format, Romer Labs) saniyede 1 damla olacak şekilde geçirildi. Daha sonra 2 kez 10 ml saf su ile kolon yıkandı. Bu işlemten sonra kolondan birkaç saniye hava geçirilerek kolondaki su temizlendi. 1 ml metanol alınarak kolondan saniyede 1 damla olacak şekilde geçirilerek koyu renkli bir şişeye toplandı. Aynı işlem 1 ml distile su ile tekrar edildi ve aynı şişeye toplandı. Şişe içerisindeki elde edilen bu solüsyonun 100 µL’si, 1 ml/min akış hızında Şekil 5.6’da gösterilen HPLC (Shimadzu Nexera XR)’ye enjekte edilerek ölçüm gerçekleştirildi. Veri setindeki incirlerin referans cihaz ölçümlerinden elde edilen aflatoksin konsantrasyonları Şekil 5.7’de verilmiştir. Burada, toplam aflatoksin konsantrasyonuna göre veri setinin dengeli bir dağılıma sahip olduğu görülmektedir.



Şekil 5.5. Karışımın homojenize edilmesi ve Whatman filtre kağıdından süzülmesi



Şekil 5.6. Referans ölçümlerin yapıldığı HPLC cihazı



Şekil 5.7. Veri setindeki incirlerin aflatoksin konsantrasyon değerleri

5.1.4. Örneklerin Etiketlenmesi

Çalışmada hem BGYF sınıflandırması hem de farklı dalga boylarındaki ışık kaynakları kullanılarak aflatoksin sınıflandırması yapılacağı için incir örnekleri hem BGYF ışımlarına göre hem de aflatoksin miktarlarına göre ayrı ayrı etiketlendirildi ve farklı veri setleri oluşturuldu.

İncir üretim tesisinin uzman çalışanları, incir örneklerini UV ışık altında BGYF yayanlar ve yaymayanlar olarak sınıflandırdı. İncirler ayrıca kendi optik sistemimiz kullanılarak da incelendi. Sonuç olarak 365nm ışık kaynağı kullanılarak elde edilen 400 görüntüden oluşan veri seti oluşturuldu ve tüm incirler BGYF(+) veya BGYF(-) olarak etiketlendi. Bu veri seti DS-BGYF olarak isimlendirildi.

Farklı dalga boylarındaki ışık kaynakları ile aflatoksin sınıflandırması çalışmaları için, kuru incir numuneleri HPLC cihazından elde edilen ölçüm sonuçlarına göre aflatoksin konsantrasyon seviyeleri de dikkate alınarak etiketlendi. Aflatoksin konsantrasyonu bazlı etiketleme işlemi esnasında, AB ülkeleri için izin verilen maksimum sınır olan 4 ppb limit değeri kullanılarak, aflatoksin miktarı 4 ppb ve üzerinde olan incirler AF(+) ve altında olanlar AF(-) olarak etiketlendi. Farklı dalga boyundaki ışık kaynakları ile alınan incir görüntüleri kullanılarak oluşturulan veri setleri DS-W, DS-365, DS-395, DS-405 ve DS-420 olarak isimlendirildi. HPLC cihazı ile ölçümü yapılan tamamı doğal yollarla enfekte olmuş 100 adet kuru incir örneği kullanıldı. Her bir veri seti toplam 400 adet görüntüden oluştuğu için toplamda 2000 adet görüntü elde edildi.

5.2. Performans Metrikleri

Modellerin performansını değerlendirmek için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve f-skor değerleri kullanıldı. Doğruluk, modeldeki doğru tahmin edilen örneklerin toplam örnek sayısına oranını temsil eder. Kesinlik, doğru tahmin edilen pozitif örneklerin gerçek pozitif örneklere oranını temsil eder. Duyarlılık, doğru tahmin edilen pozitif örneklerin gerçek pozitif ve yanlış negatif örneklere oranını gösteren bir ölçümdür. F-skor, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır ve yanlış pozitif ve yanlış negatif riskini dengelemeyi amaçlar. Denklem (5.1-4)'deki şekilde ifade edilebilirler:

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} \quad (5.1)$$

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (5.2)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN} \quad (5.3)$$

$$F\text{-Skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5.4)$$

Burada TP (Gerçek Pozitif) değeri, AF(+) veya BGYF(+) olduğu doğru tahmin edilen incirleri; TN (Gerçek Negatif) değeri, AF(-) veya BGYF(-) olduğu doğru tahmin edilen incirleri; FP (Hatalı Pozitif) değeri, AF(+) veya BGYF(+) olduğu yanlış tahmin edilen incirleri ve FN (Hatalı Negatif) değeri AF(-) veya BGYF(-) olduğu yanlış tahmin edilen incirleri ifade etmektedir.

5.3. Geliştirme Ortamı ve Veri Çoğaltma

Yapılan deneysel çalışmalarda kullanılan derin transfer öğrenme modelleri, Jupyter Notebook üzerinde Python programlama dili ile tasarlandı ve Intel Core i5-10300H 2.50 GHz CPU, NVIDIA GeForce GTX 1650Ti 4 GB ekran kartı ve 8 GB RAM'e sahip sistem konfigürasyonu kullanılarak yürütüldü.

Veri sayısının az olması aşırı öğrenme sorununa ve oluşturulacak modelin performansının düşük olmasına sebep olacağı için, incir görüntülerine çevirme, döndürme, kırpma, kaydırma ve yakınlaştırma gibi geometrik dönüşüm teknikleri uygulanarak veri çoğaltma işlemi gerçekleştirildi. Veri çoğaltma için kullanılan yöntemler ve parametre ayarları Tablo 5.1'de verilmiştir. Böylece modelin her epokta daha önce hiç görmediği yeni görüntüleri görmesini sağlayarak modelin genellenebilirliği artırıldı.

Tablo 5.1. Veri çoğaltma parametreleri

Kullanılan Metot	Kullanım Şekli
Kırpma	$[-15^\circ, 15^\circ]$ arasındaki açıyla rastgele
Kaydırma	$[-20, 20]$ piksel kaydırmalı
Yakınlaştırma	$[0.85, 1.15]$ aralığında rastgele
Döndürme	$[0^\circ, 360^\circ]$ arasındaki açıyla rastgele
Çevirme	Soldan sağa

5.4. BGYF Tespit Çalışmaları


Aflatoksin ile kontamine olmuş kuru incirlerde BGYF ışımasının tespiti için literatürde yer alan çalışmalarda en umut verici çalışmalar eşikleme ve SVM yöntemleri kullanılarak yapılmıştır (Gunes, Durmus, vd., 2013; Ö. Özlüoymak, 2014). Bu yöntemlerin bizim yöntemimizle kıyaslamasını sağlıklı bir şekilde yapabilmemiz için DS-BGYF veri setine bu yöntemler uygulandı.

5.4.1. Eşikleme Yöntemi ile Tespit

Öncelikle görüntüler üzerindeki gürültüleri kaldırmak ve kuru incirlerin kenarlarını belirleyebilmek için ön işlemlere tabi tutuldu. Yapılan işlemler sırasıyla aşağıda verilmiştir:

1. Renkli görüntüler griye dönüştürüldü.
2. Gri görüntü siyah-beyaza çevrildi. Bunun için THRESH_BINARY ve THRESH_OTSU eşikleme yöntemleri bir arada kullanıldı.
3. Gürültüyü azaltmak için açma işlemi uygulandı.
4. Gürültü olmayan fakat eşişe takılan değerler için kapama işlemi uygulandı.
5. Bulanıklaştırmadan sonra tekrar eşikleme yapılarak kalan gürültüler silindi.


Bu işlemlerin neticesinde gürültüden arındırılmış ve incir kenarları belirlenmiş görüntüler elde edildi. Böylece kuru incir yüzeyinin ne kadarlık bir alana (piksel sayısı) sahip olduğu hesaplanabildi. Örnek bir kuru incir görüntüsü üzerinde yapılan ön işlem adımları Şekil 5.8’de gösterilmiştir.



Şekil 5.8. Kuru incir görüntüleri ön işleme adımları

Ön işleme işlemlerinden sonra kuru incir üzerindeki BGYF ışıması yapan bölgeleri belirleyebilmek için doğru eşik değerinin belirlenmesi gerekmektedir. Eşikleme parametrelerini belirlemek için HSV renk uzayı kullanıldı. HSV renk alanı, rengi “Ton”, “Doygunluk” ve “Değer” açısından tanımlar. “Ton” rengin baskın dalga boyunu, “Doygunluk” rengin saflığını ve yoğunluğunu, “Değer” ise rengin parlaklığını ifade eder. BGYF ışıması yapan ve yapmayan örnekler üzerinde yapılan çalışmada, eşik değerleri Ton için 0-255, Doygunluk için 150-255 ve Değer için 150-255 olarak belirlendi. Böylece incir görüntüleri üzerindeki her pikselin HSV değeri belirlenen eşik değerleri ile karşılaştırıldı ve eşik değerlerine göre görüntüler BGYF gösteriyor veya göstermiyor şeklinde sınıflandırıldı. Tüm incirlerin değerlendirilmesi sonucunda kontamine incirler %95 doğrulukla sınıflandırıldı. Şekil 5.9 eşikleme yöntemine göre incirler üzerindeki

BGYF ışıması yaptığı tespit edilen bölgeleri ve bu bölgelerin maskelenmiş halini göstermektedir.



Şekil 5.9. Eşikleme yöntemiyle BGYF ışıması tespiti yapılan incir örnekleri


5.4.2. SVM ile Sınıflandırma

BGYF ışıması yayan örneklerde incir yüzeyinde bir parlama mevcut olduğu için, öznelitektörlerinin çıkarımı için incir görüntülerinin renkli histogramları kullanıldı ve bu histogram değerlerinden 64 adet öznelitektör belirlendi. Veri seti, 70:30 oranı kullanılarak

rastgele eğitim ve test setlerine bölündü. SVM çekirdek fonksiyonu olarak polinom kullanıldı. Ayrıca C ve gamma parametre değerleri olarak 1 verildi. Sonuç itibarıyla BGYP gösteren incirler SVM yöntemi ile %85 doğrulukla sınıflandırıldı.

5.4.3. Transfer Öğrenme ile Sınıflandırma


DS-BGYP veri setinde hangi transfer öğrenme modelinin daha verimli olduğunu belirlemek için Keras kütüphanesindeki tüm modeller kullanılarak bir ön çalışma yapıldı. Veri seti, 70:30 oranı kullanılarak rastgele eğitim ve test setlerine bölündü. Transfer öğrenme modellerinin performansı, sınıflandırma doğruluğu kullanılarak puanlandı. Önceden eğitilmiş CNN modellerinde ince ayar yapmak için ilk öğrenme hızı 0,0001 olarak, mini parti boyutu ve maksimum epok sayısı ise sırasıyla 10 ve 20 olarak seçildi. Modeller, Adam optimizasyon algoritması kullanılarak eğitildi. İlk etapta en yüksek doğruluk değerlerine sahip modeller Şekil 5.10'daki grafikte gösterilmiştir. Deneysel sonuçlar DenseNet modellerinin BGYP tespiti için daha iyi çalıştığını gösterdi. Bu nedenle DenseNet169 ve DenseNet201 modelleri ile çalışmalara devam edildi.



Şekil 5.10. BGYP tespiti için farklı transfer öğrenme modelleriyle elde edilen doğruluk değerleri

DenseNet modellerinde kolaylık olması için tüm incir görüntüleri 224×224 boyutlarında yeniden boyutlandırıldı. Modellerin performansını artırmak için ince ayar yapıldı. Buna göre mini parti boyutu, maksimum epok sayısı ve öğrenme oranı sırasıyla 10, 100 ve 0,00005 olarak seçildi. Optimize edici olarak momentumlu stokastik gradyan (Stochastic

Gradient Descent with Momentum, SGDM) kullanıldı ve momentum değeri 0,9 olarak seçildi. Önerilen modelin mimarisi Şekil 5.11'de gösterilmiştir.



Şekil 5.11. BGZF sınıflandırması için DenseNet modeli kullanılarak inşa edilen mimari (Kılıç ve İner, 2022)

Kenarlar, eğriler, köşeler, renk tonları, gölgeler ve dokular gibi görüntü özellikleri DenseNet mimarisinin ilk katmanlarında öğrenildiğinden, evrişim, havuzlama ve DenseBlock1 katmanları donduruldu ve yeni modele aktarıldı. BGZF'yi algılayabilen soyut ve spesifik özellikler gibi daha karmaşık özellikler sonraki katmanlarda öğrenilir. Bu nedenle, DenseBlock 2, 3 ve 4 yeniden eğitildi. Son katmanlar büyük veri kümelerini sınıflandırmak için tasarlandığından, veri kümemize uyacak şekilde değiştirildiler. Öncelikle çalışma DenseNet169 modeli ile gerçekleştirildi. İlk olarak, tüm yoğun bloklar donduruldu ve ağın son katmanları kaldırıldı. Bu katmanların yerine 256 düğümlü FCL, ardından 128 düğümlü FCL ve son olarak çıktı için softmax aktivasyonlu 2 sınıflı bir FCL eklendi. Ayrıca, düğümlerin birbirleri hakkında daha az bilgi sahibi olmaları ve birbirlerinin ağırlık değişikliklerinden daha az etkilenmeleri için FCL katmanları arasına toplu normalleştirme ve %20 dropout eklendi. Sonuç olarak modelin eğitilmesi ile %85 doğruluk elde edildi. Ardından yaklaşık 6 milyon parametrelili DenseBlock4 (DB4) yeniden eğitilerek parametre sayısı 27 milyona çıkarıldı. Bu durumda %87 doğruluk elde edildi. Ardından yaklaşık 4 milyon parametreden oluşan DenseBlock3 (DB3) yeniden eğitildiğinde toplam parametre sayısı 31 milyona, doğruluk değeri ise %89'a yükseldi. Benzer şekilde, diğer yoğun bloklar da yeniden eğitildi. En yüksek doğruluk değeri, DB4 ve DenseBlock2'nin (DB2) yeniden eğitilmesiyle elde edildi. Sonuç olarak, %98,57 eğitim doğruluğu ve %97,50 test doğruluğu elde edildi. DenseNet169 üzerinde yoğun blok katmanlarının yeniden eğitilmesiyle oluşturulan modellerin performans metrikleri Tablo 5.2'de verilmiştir.

Tablo 5.2. DenseNet169 modeli ile yapılan çalışmada elde edilen performans metrikleri

Yeniden Eğitilen Yoğun Bloklar	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitilen Parametre Sayısı	Toplam Eğitim Süresi (saniye)	Model Büyüklüğü (Mb)
-	0,850	0,850	0,826	0,838	21.070.210	212	211
DB4	0,875	0,942	0,817	0,875	26.983.810	539	234
DB4 + DB3	0,892	0,875	0,925	0,899	31.299.970	963	250
DB4 + DB3 + DB2	0,892	0,892	0,892	0,892	32.219.650	1175	254
DB3 + DB2	0,950	0,933	0,983	0,957	26.306.050	749	231
DB2	0,900	0,967	0,842	0,900	21.989.890	533	214
DB3	0,900	0,900	0,950	0,925	25.386.370	538	228
DB4 + DB2	0,975	0,958	0,978	0,968	27.903.490	857	237

DenseNet201 modeli ile de benzer bir çalışma yapıldı. DenseNet201 modelinde yoğun blok katmanları yeniden eğitildikten sonra hesaplanan performans metrikleri Tablo 5.3'te verilmiştir. DenseNet169 ve DenseNet201 modellerinin karışıklık matrisleri de Tablo 5.4'te gösterilmiştir. DenseNet169 modeli, Densenet201 modelinden daha iyi performans gösterdi. DenseNet169 modelinin doğruluk ve kayıp grafikleri Şekil 5.12'de verilmiştir. Ayrıca deneysel bulgular önerilen modelin her bir incir örneğinin BGYF sınıflandırmasını 42 milisaniyede gerçekleştirdiğini gösterdi.

Tablo 5.3. DenseNet201 modeli ile yapılan çalışmada elde edilen performans metrikleri

Yeniden Eğitilen Yoğun Bloklar	Doğruluk	Kesinlik	Duyarlılık	F-Skor	Eğitilen Parametre Sayısı	Toplam Eğitim Süresi (saniye)	Model Büyüklüğü (Mb)
-	0,867	0,857	0,817	0,837	24.306.562	256	257
DB4	0,883	0,875	0,842	0,858	31.285.122	668	284
DB4 + DB3	0,925	0,883	0,975	0,927	39.356.802	1391	316
DB4 + DB3 + DB2	0,933	0,900	0,975	0,936	40.276.482	1510	319
DB3 + DB2	0,933	0,917	0,967	0,941	33.297.922	1072	292
DB2	0,933	0,925	0,967	0,945	25.226.242	641	261
DB3	0,925	0,892	0,958	0,925	32.378.242	860	289
DB4 + DB2	0,950	0,935	0,935	0,935	32.204.802	967	288



Tablo 5.4. DenseNet169 ve DenseNet201 modellerinin karışıklık matrisleri

		Tahmin	
		BGYF(+)	BGYF(-)
Gerçek	BGYF(+)	44	2
	BGYF(-)	1	73

(a) DenseNet169

		Tahmin	
		BGYF(+)	BGYF(-)
Gerçek	BGYF(+)	43	3
	BGYF(-)	3	71

(b) DenseNet201



Şekil 5.12. BGYP tespiti için önerilen modelin doğruluk ve kayıp grafikleri

Kuru incirlerde BGYF yöntemi kullanılarak aflatoksin tespiti ve sınıflandırılması için farklı görüntü işleme ve makine öğrenmesi tabanlı çalışmalar yapılmıştır. (Kalkan vd., 2014) UV ışığı altında multispektral görüntüler kullanarak 192 aflatoksin bulaşmış inciri tespit etmek için bir Destek Vektör Sınıflayıcı (Support Vector Classifier, SVC) sınıflandırma yaklaşımı önermiştir. Bu yaklaşıma göre incirler %11,98 hata oranı ile sınıflandırılmıştır. (Gunes, Durmus, vd., 2013) UV ışığı altında görüntülenen 569 kuru incir örneğini SVM kullanarak %89 doğruluk oranıyla sınıflandırmıştır. (Ö. Özlüoymak, 2014) tarafından yapılan bir başka çalışmada ise eşikleme yöntemi ile BGYF gösteren 200 incir %4 hata oranı ile, BGYF göstermeyen 200 incir ise %0 hata oranı ile tespit edilebilmiştir. Bu çalışmalar ortak bir veri seti kullanılarak yapılmadığı için yöntemlerin performansını karşılaştırmak imkansızdır. Bu nedenle sonuçları bu yöntemlerle karşılaştırmak için veri setimize eşikleme ve SVM yöntemleri uygulandı. Eşikleme yöntemiyle %95, SVM yöntemiyle %85 doğruluk oranı elde edildi (bkz. Tablo 5.5). Bu sonuç, aflatoksin bulaşmış incirlerde BGYF'yi tespit etmek için önerilen yöntemin en başarılı yöntem olduğunu göstermektedir.


Tablo 5.5. BGYF tespiti için önerilen metot ile diğer yöntemlerin karşılaştırması

Kullanılan Metot	Doğruluk
Eşikleme	95.0%
SVM	85.0%
Transfer öğrenme ile DenseNet201	95.0%
Transfer öğrenme ile DenseNet169 (Önerilen Metot)	97.5%

5.5. BGYF ve Aflatoksin Arasındaki Korelasyon

İncir numunelerinin BGYF kontrol sonuçları ve HPLC referans cihazı sonuçları, BGYF'nin aflatoksin bulaşmış kuru incirleri tespit etmedeki etkinliğini araştırmak için kullanıldı. İncirlerin %9'unda aflatoksin bulunmasına rağmen BGYF tespit edilmedi ve %18'inde aflatoksin olmamasına rağmen BGYF tespit edildi. Sonuç olarak, BGYF kontrolü yapılarak aflatoksinli incirler %73 doğruluk oranı ile tespit edilebildi. Aflatoksin kontaminasyonu ve BGYF tespiti arasındaki ilişkinin grafiği Şekil 5.13'de verilmiştir. Bu sonuç, BGYF'nin varlığının aflatoksin varlığının kesin kanıtı olmadığını, ancak aflatoksin

içeren veya içermesi muhtemel ürünlerin tahribatsız tespiti için kullanılabileceğini göstermektedir.




Şekil 5.13. BGYF ve aflatoksin arasındaki korelasyon

5.6. Farklı Dalga Boyundaki Işık Kaynakları ile Aflatoksin Tespit Çalışmaları

Bu deneysel çalışmada DS-420, DS-405, DS-395, DS-365 ve DS-W veri setleri kullanılarak aflatoksin tespiti için çalışmalar yapıldı. Veri setleri, 75:25, 70:30, 65:35 ve 60:40 oranları kullanılarak rastgele eğitim ve test setlerine bölünerek deneysel çalışmalar gerçekleştirildi. İlk olarak, transfer öğrenme modellerinde ince ayar yapılarak sınıflandırma çalışmalarının sonuçları görüldü. Elde edilen sonuçların performansı yeterli görülmediğinden, transfer öğrenme modellerinden çıkarılan öznitelikler kullanılarak aflatoksin bulaşmış incirlerin sınıflandırılması bir sınıflandırıcı yardımıyla gerçekleştirildi.

5.6.1. CNN Modellerinde İnce Ayar


Öncelikle tüm modeller için tüm katmanlar son havuz katmanına kadar donduruldu. Ardından, sınıflandırma görevini gerçekleştirmek için son FCL, iki nöron içeren özel bir softmax katmanıyla değiştirildi. Önceden eğitilmiş CNN modellerinde ince ayar yapmak için mini parti boyutu, maksimum epok sayısı ve öğrenme hızı sırasıyla 10, 50 ve 0,0001 olarak seçildi. Modeller Adam optimizier kullanılarak eğitildi. Ardından performansı artırmak için bazı donmuş katmanlar yeniden eğitildi. Yapılan çalışma neticesinde, en iyi sonuç DS-365 veri seti üzerinde ResNet101 modeline ince ayar yapılarak elde edildi. Tüm çalışmadan elde edilen en iyi sonuçlar için doğruluk değerleri Şekil 5.14'teki grafikte verilmiştir.



Şekil 5.14. Aflatoksin tespiti için farklı transfer öğrenme modelleriyle elde edilen doğruluk değerleri

5.6.2. CNN Modellerine Dayalı Öznitelik Çıkarma

Öznitelik sayısı çok fakat veri sayısı az olduğunda SVM, Random Forest gibi sınıflandırıcıların daha iyi performans gösterdiği bilinmektedir (Huo vd., 2016). Bu nedenle bu deneysel çalışmada, ilk olarak önceden eğitilmiş CNN modellerini kullanarak incir görüntülerinin öznitelikleri çıkarıldı ve çıkarılan öznitelikler birleştirildi. Ardından birleştirilen özniteliklerin boyutunu azaltmak için küresel ortalama havuzlama (Global Average Pooling, GAP) ve PCA olmak üzere 2 farklı boyut azaltma yöntemi denendi. Yapılan çalışmada izlenen yolu gösteren genel mimari Şekil 5.15’de gösterilmiştir.



Şekil 5.15. Öznitelik çıkarma, birleştirme, boyut azaltma ve sınıflandırma mimarisi

Öznitelik birleştirme, sınıflandırma sürecini geliştirmek için farklı özellikleri bir araya getirmenin etkili bir yoludur. Kullanılan her bir modelden elde edilen öznitelikler şu şekilde birleştirilir:

$$F_T = F_1 \cup F_2 \cup \dots F_N \quad (5.5)$$

Farklı önceden eğitilmiş CNN modelleri görüntüler üzerinde benzer özniteliklere sahip olabilir. Bu sebeple sınıflandırma aşamasına geçmeden önce sınıflandırma sonucuna negatif yönde etki etmeyecek olan öznitelikler PCA ile çıkartılarak öznitelik sayısı düşürülür. Bunun için verilerdeki varyansın %99'unu açıklayabilen temel bileşenler seçildi. Denklem (5.6)'da belirtildiği gibi öz değerler toplamı %99'u aşan en büyük ilk K adet temel bileşen seçilir.

$$\frac{\sum_{i=1}^K \lambda_i}{\sum_{i=1}^T \lambda_i} \times 100 \geq 99 \quad (5.6)$$

Burada; λ özdeğerleri (Eigenvalues), T birleştirilen özniteliklerin toplam sayısını ve K seçilen temel bileşen sayısını ifade etmektedir. T adet öznitelik sayısı PCA sonrası K adet özniteliğe düşürülmüş olur.

Önceden eğitilmiş her bir CNN modeli, aflatoksin tespiti için farklı öznitelikler çıkarabilir. Bu nedenle, önceden eğitilmiş birden fazla CNN modelinden çıkarılan öznitelikler, incir görüntülerinde aflatoksini en iyi temsil edebilecek öznitelikleri çıkarmak için kullanıldı. Öznitelik çıkarımı için Keras kütüphanesindeki önceden eğitilmiş tüm CNN modelleri ile deneyler yapıldı. Sınıflandırma modeli olarak SVM ve RF kullanıldı. SVM, doğrusal fonksiyon çekirdeği ile C=0,1 ve gamma=1 olarak uygulandı. RF için estimator=50 ve random_state=42 kullanıldı. Öznitelik azaltma için özniteliklerin birleştirilmesi adımıyla sonra PCA eklendi. Böylece öznitelik sayısı önemli ölçüde azaltılmış olsa da sınıflandırma doğruluk değeri değişmedi. Her bir veri seti için SVM ve RF sınıflandırıcıları kullanılarak elde edilen en yüksek doğruluk değerleri Tablo 5.6'da verilmiştir. Şekil 5.3'te görüldüğü gibi, farklı dalga boylarındaki ışıklar altında alınan incirler farklı görünümlere sahiptir. Dolayısıyla çıkarılan öznitelikler de birbirinden farklı olmaktadır. Bu nedenle aynı öznitelik çıkarma yöntemlerinin farklı veri setlerinde farklı sonuçlar verdiği görüldü.

Tablo 5.6. Deneysel çalışma sonucu elde edilen doğruluk değerleri


Öznitelik çıkarma yöntemi	DS-W		DS-365		DS-395		DS-405		DS-420	
	SVM	RF	SVM	RF	SVM	RF	SVM	RF	SVM	RF
VGG16	0,60	0,63	0,63	0,70	0,70	0,87	0,77	0,80	0,70	0,63
VGG19	0,63	0,77	0,77	0,63	0,80	0,60	0,77	0,80	0,67	0,63
MobileNetV2	0,77	0,57	0,83	0,63	0,77	0,80	0,80	0,73	0,80	0,73
EfficientNetB7	0,83	0,63	0,53	0,53	0,60	0,63	0,53	0,83	0,47	0,50
ResNet152V2	0,73	0,67	0,63	0,70	0,77	0,60	0,63	0,70	0,80	0,77
DenseNet121	0,67	0,67	0,70	0,63	0,60	0,60	0,83	0,63	0,67	0,70
ResNet101V2	0,50	0,40	0,83	0,73	0,63	0,60	0,67	0,60	0,70	0,67
VGG16+MobileNetV2	0,60	0,60	0,83	0,70	0,80	0,63	0,77	0,67	0,83	0,60
ResNet50V2+EfficientNetB4	0,77	0,57	0,63	0,57	0,70	0,60	0,83	0,60	0,70	0,53
ResNet152V2+MobileNetV2	0,53	0,43	0,73	0,67	0,73	0,67	0,63	0,60	0,87	0,67
DenseNet169+ResNet101V2	0,57	0,43	0,83	0,60	0,67	0,57	0,73	0,63	0,80	0,73
ResNet101V2+MobileNetV2	0,57	0,53	0,87	0,83	0,70	0,50	0,70	0,70	0,83	0,60
EfficientNetB7+MobileNetV2	0,80	0,70	0,83	0,53	0,80	0,70	0,80	0,63	0,73	0,57
VGG19+DenseNet121	0,67	0,67	0,67	0,60	0,60	0,67	0,83	0,63	0,67	0,67
DenseNet169+ResNet101V2+MobileNetV2	0,80	0,53	0,87	0,70	0,73	0,73	0,76	0,63	0,87	0,70
ResNet152V2+MobileNetV2+EfficientNetB4	0,70	0,73	0,77	0,60	0,73	0,67	0,63	0,63	0,87	0,77
VGG16+MobileNetV2+Xception	0,73	0,73	0,73	0,60	0,83	0,77	0,77	0,63	0,77	0,60
MobileNetV2+ResNet101V2+InceptionResNetV2	0,70	0,63	0,96	0,83	0,70	0,63	0,67	0,67	0,83	0,67
ResNet152+ResNet101V2+MobileNetV2+InceptionResNetV2	0,70	0,60	0,90	0,77	0,73	0,60	0,63	0,67	0,80	0,70
ResNet101V2+MobileNetV2+VGG19+DenseNet121	0,73	0,83	0,90	0,73	0,70	0,63	0,73	0,70	0,73	0,73

Deneysel çalışma sonucunda tüm veri setleri için elde edilen en başarılı yöntemlerin değerlendirme kriterleri Tablo 5.7'de verilmiştir. DS-W veri setinde EfficientNetB7 modelinden elde edilen öznitelik vektörleri SVM ile sınıflandırılmış ve %83 doğruluk elde edildi. DS-395 veri seti üzerinde gerçekleştirilen deneysel çalışmada VGG16 modeli kullanılarak öznitelik vektörleri çıkarıldı. Rastgele orman ile yapılan sınıflandırma ile %87 doğruluk elde edildi. DS-405 veri setinde ResNet50V2 ve EfficientNetB4 modellerinden çıkarılan öznitelik vektörleri SVM kullanılarak sınıflandırıldı ve %87 doğruluk elde edildi. DS-420 veri setindeki görüntüler üzerinde ResNet152V2 ve MobileNetV2 modelleri kullanılarak öznitelik vektörleri çıkarıldı ve SVM kullanılarak sınıflandırıldı. Sonuç olarak %87 doğruluk elde edildi. Tüm veri setleri üzerinde yapılan

deneysel çalışmada en başarılı sonuçlar DS-365 veri setinde alındı. Başka bir ifadeyle, aflatoksinler en iyi şekilde 365nm ışık altında çekilen görüntüler kullanılarak sınıflandırıldı. MobileNetV2, ResNet101V2 ve InceptionResNetV2 modellerinden çıkarılan öz nitelik vektörleri birleştirildi ve ardından veri boyutunu küçültmek ve verimli bir sınıflandırıcı oluşturmak için SVM ile sınıflandırma işleminden önce PCA uygulandı. Böylece 201.472 olan öz nitelik sayısı PCA'dan sonra 74'e düşürüldü. Sonuç olarak veri setinde yer alan aflatoksinli incirler %100 doğrulukla sınıflandırılırken, aflatoksin bulaşmamış temiz incirlerin %7,7'si AF(+) olarak sınıflandırıldı ve %96 sınıflandırma doğruluğu elde edildi. Önerilen modelin mimarisi Şekil 5.16'da ve karışıklık matrisi Tablo 5.8'de verilmiştir.

Tablo 5.7. Tüm veri setleri için en iyi modellerin performans metrikleri

Veri seti	Öz nitelik çıkarma yöntemi	Sınıflandırıcı	Doğruluk	Kesinlik	Duyarlılık	F Skor
DS-W	EfficientNetB7	SVM	0,83	0,92	0,75	0,83
DS-365	MobileNetV2+ResNet101V2+ InceptionResNetV2	SVM	0,96	1	0,92	0,96
DS-395	VGG16	RF	0,87	0,88	0,88	0,88
DS-405	ResNet50V2+EfficientNetB4	SVM	0,83	0,82	0,88	0,85
DS-420	ResNet152V2+MobileNetV2	SVM	0,87	0,88	0,88	0,88



Şekil 5.16. Aflatoksin tespiti için önerilen modelin mimarisi

Tablo 5.8. Önerilen modelin karışıklık matrisi

		Tahmin			Toplam Doğruluk
		AF(+)	AF(-)	Doğruluk	
Gerçek	AF(+)	12	0	100%	96%
	AF(-)	1	12	92,3%	

Deneysel çalışma esnasında veri seti, 75:25 oranında eğitim ve test setine bölündü. Veri setinde fazla miktarda veri mevcut olduğunda 90:10 veya 80:20 oranları etkili olabilirken, az veri olduğunda 70:30 veya 60:40 gibi oranlar yaygın olarak kullanılır. Veri setimiz için en etkili eğitim ve test veri sayılarını belirlemek üzere, veri setini farklı oranlara bölerek modelimizin performansını değerlendirdik. Çalışma sonucu elde edilen performans metrikleri Tablo 5.9’da verilmiştir. Bu sonuçlara göre veri setinin 75:25 ve 70:30 oranlarında bölünmesi durumunda, aflatoksini incirlerin %100 doğrulukla tespit edilebildiği görülmektedir.

Tablo 5.9. Önerilen modelin farklı eğitim:test veri oranlarındaki performans metrikleri

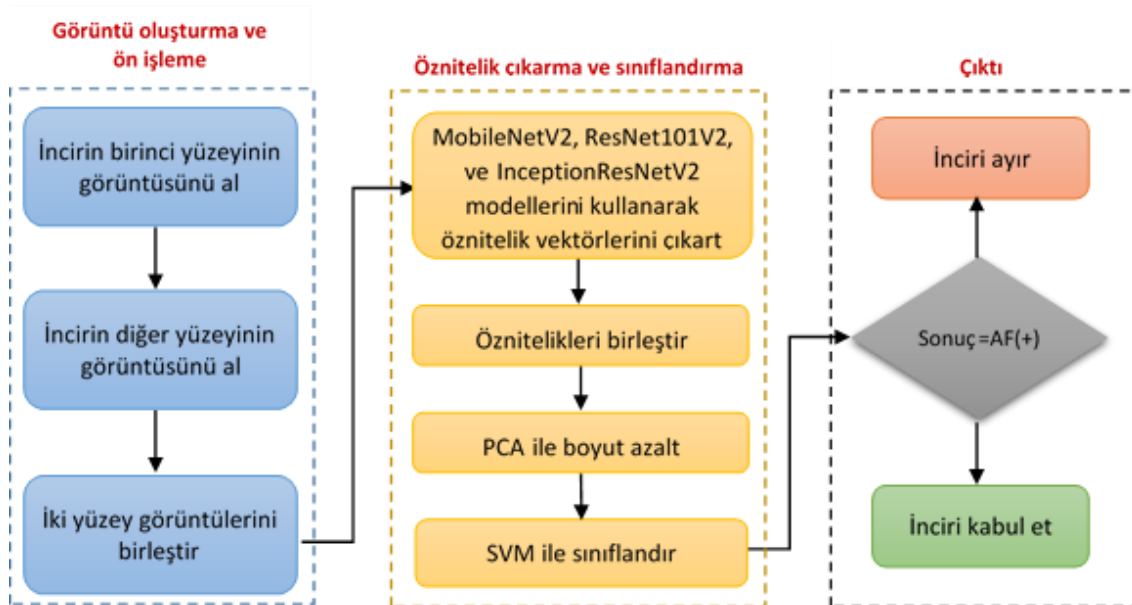
Veri Seti Dağılımı (Eğitim:Test)	Doğruluk	Kesinlik	Duyarlılık	F Skor
75:25	0,96	1	0,92	0,96
70:30	0,93	1	0,88	0,93
65:35	0,89	0,94	0,84	0,89
60:40	0,80	0,82	0,82	0,82

Tahratsız tespit için incirlerin sadece dış yüzeylerine bakılarak aflatoksini tespiti yapılmalıdır. Fakat aflatoksini incirin iç yüzeyinde de olabileceği gerçeğini göz önüne alarak, incirin iç yüzey görüntülerinin kullanılmasının sınıflandırma doğruluğunu artırıp artırmayacağı konusunda da inceleme yapıldı. Bu kapsamda, her bir incir örneği için hem iç hem de dış yüzeylerinden alınan görüntüler ile deneysel çalışma yapıldı. Her bir veri setindeki incirlerin iç ve dış yüzey görüntüleri üzerinde SVM ve RF sınıflandırıcıları kullanılarak yapılan sınıflandırma çalışmalarında elde edilen en yüksek doğruluk değerleri Tablo 5.10’da verilmiştir. En yüksek doğruluk DS-420 veri setinde ResNet152V2 ve ResNet101 modellerinden çıkarılan öznelik vektörlerinin SVM ile sınıflandırılmasıyla elde edildi. Elde edilen %90’lık sınıflandırma doğruluğu, incirlerin sadece dış görüntüleri ile elde edilen başarının gerisinde kalmıştır.


Tablo 5.10. İncirlerin iç ve dış yüzey görüntüleri ile yapılan deneysel çalışma sonucu elde edilen doğruluk değerleri

Öznitelik çıkarma yöntemi	DS-W		DS-365		DS-395		DS-405		DS-420	
	SVM	RF	SVM	RF	SVM	RF	SVM	RF	SVM	RF
VGG16	0,60	0,67	0,70	0,77	0,67	0,80	0,67	0,60	0,57	0,57
VGG19	0,77	0,70	0,73	0,73	0,60	0,83	0,73	0,70	0,73	0,63
MobileNetV2	0,63	0,53	0,80	0,77	0,83	0,70	0,73	0,70	0,63	0,80
EfficientNetB7	0,83	0,57	0,60	0,53	0,73	0,57	0,63	0,73	0,77	0,63
ResNet152V2	0,60	0,70	0,80	0,63	0,60	0,53	0,60	0,63	0,80	0,67
ResNet101	0,57	0,47	0,70	0,67	0,63	0,60	0,67	0,67	0,80	0,70
VGG16+MobileNetV2	0,63	0,53	0,80	0,67	0,83	0,77	0,77	0,63	0,70	0,67
ResNet152V2 - ResNet101	0,60	0,67	0,63	0,70	0,63	0,53	0,63	0,53	0,90	0,67
ResNet152V2+MobileNetV2	0,63	0,50	0,70	0,63	0,70	0,73	0,63	0,57	0,80	0,70
NASNetMobile - MobileNetV2	0,50	0,57	0,87	0,70	0,83	0,63	0,73	0,63	0,73	0,57
DenseNet169 - DenseNet121	0,77	0,83	0,87	0,67	0,53	0,70	0,70	0,70	0,73	0,70
ResNet50 - ResNet101V2	0,87	0,77	0,77	0,47	0,60	0,53	0,70	0,67	0,67	0,67

Aflatoksinin tahribatsız tespiti için yapılan sınıflandırma çalışmasında elde edilen başarı oranı, önerilen yöntemin incir üretim tesislerinde hızlı ve başarılı tespit için rahatlıkla kullanılabileceğini göstermektedir. Önerilen modelin akış diyagramı Şekil 5.17'de verilmiştir. Önerilen modelin incir üretim tesislerinde bulunan taşıma bantlarında gerçek zamanlı çalışacak örnek tasarımı Şekil 5.18'de verilmiştir.



Şekil 5.17. Aflatoksin tespiti için önerilen yöntemin akış diyagramı



Şekil 5.18. Aflatoksin tespiti için önerilen sistemin örnek tasarımı

Aflatoksin içeren incirlerin gerçek zamanlı tespiti için bilgisayarlı görü tabanlı sistemlere ihtiyaç duyulmaktadır. Böylece hızlı, güvenilir ve tahribatsız yöntemler üretilebilmektedir. İncir için bilgisayarlı görü tabanlı tespit çalışmaları genel olarak BGYF kontrolü ile aflatoksin tespit edilmeye çalışılmıştır. BGYF yöntemi dışında farklı yöntemlerle elde edilen verileri kullanarak yapılan üç sınıflandırma çalışması bulunmuş, bu çalışmaların ikisinde spektral ölçüm verileri, diğerinde ise incir görüntüleri kullanılmıştır.

(Durmuş vd., 2017) Fourier Dönüşümlü NIR yansıma spektroskopisi yöntemi ile aldıkları veriler üzerinde LDC kullanarak aflatoksin içeren incirleri %100 doğrulukla sınıflandırabildiklerini bildirmişlerdir. Bu çalışma sırasında, spektroskopik ölçümler için incir yüzeyinin ortasına yerleştirilmiş bir fiber prob kullanılmıştır. Her numune için 15,32 saniye süren 32 tarama yapılmış ve bu tarama ölçümlerinin ortalaması alınmıştır. Aflatoksin incirin tüm yüzeyinde bulunabileceği için incirin tamamını ölçmek gerekir. Bu çalışmada incir yüzeyinin çok küçük bir bölümünde alınan ölçüm verileri kullanıldığından, sınıflandırma amacıyla kullanılan verilerin incir yüzeyinin tamamını temsil etmediği görülmektedir. İncirin tüm yüzeyini taramak uzun zaman alacaktır. Bu nedenle önerilen yöntem, hızlı tespit gerektiren incir üretim tesislerinde kullanılamaz. Benzer şekilde (Gunes, Kalkan, vd., 2013), NIR yansıma spektroskopisi yöntemiyle elde edilen spektrum verileri üzerinde LDC ile %90 sınıflandırma doğruluğu elde etmiştir. (Kalkan vd., 2014), UV ışığı altında multispektral görüntüler kullanarak aflatoksin bulaşmış incirleri tespit etmek için bilgisayarlı görü tabanlı bir makine öğrenimi

yaklaşımı önermiştir. Dokuz spektral bant görüntüsü kullanarak, SVC ile incirleri %12 hata oranıyla sınıflandırabilmişlerdir. Bu sonuçlar, önerilen yöntemimizin incir üretim tesislerinde gerçek zamanlı aflatoksin tespiti için kullanılabilecek en hızlı ve en başarılı yöntem olduğunu göstermektedir.

6. SONUÇLAR VE ÖNERİLER

Aflatoksin, ekolojik koşullara bağlı olarak üretimden tüketime kadar tarım ürünlerinde gelişebilen ve çoğalabilen en tehlikeli mikotoksindir. Aflatoksin birçok gıda ve tarım ürünüde bulunabilmekte ve hem insanlarda hem de hayvanlarda çok çeşitli sağlık sorunlarına neden olabilmektedir. Kirlenmiş gıdalardan aflatoksini temizlemek mümkün değildir. Bu nedenle kontamine gıdaların doğru ve hızlı bir şekilde tespiti ve tüketiminin önlenmesi insan sağlığı ve ekonomik faydalar açısından büyük önem taşımaktadır. Gıda ve tarım endüstrisinde aflatoksin tespiti için kullanılan ve altın standart olarak kabul edilen mevcut kromatografik yöntemlerin bazı dezavantajları vardır. Bu yöntemler pahalıdır, zaman alıcıdır ve numune parçalanmasını gerektirdiğinden yıkıcıdır. Ayrıca bu yöntemler üretim hatlarında uygulanamadığı için çevrim dışı tespit yöntemleridir. Bu nedenle, gerçek zamanlı ve çevrimiçi olarak aflatoksin kontaminasyonunu tespit etmek için optik spektroskopik teknikleri kullanarak hızlı ve tahribatsız algılama sistemleri oluşturmaya artan bir ilgi vardır. Son yıllarda gıda ve tarımda spektroskopik tekniklerin uygulamaları önemli ölçüde genişlemiştir. Optikteki gelişmeler, uygun fiyatlı optik bileşenler ve potansiyel uygulamaların geniş çapta ortaya çıkması bunu mümkün kılmıştır. Optik spektroskopik tekniklerin aflatoksin tespitinde başlıca faydaları hız, minimum numune hazırlama veya hiç numune hazırlamama, düşük maliyet, doğruluk ve tahribatsız tespittir.

Aflatoksin bulaşmış incirler, incir işleme tesislerinde UV ışığı altında görülen BGYF ışımasına göre çalışanlar tarafından manuel olarak ayıklanmaktadır. Çalışanların uzmanlığı, manuel ayıklamanın başarısını etkiler. Bununla birlikte, UV radyasyonuna uzun süre maruz kalmak sağlık sorunlarına neden olmaktadır. Bu nedenle, aflatoksinle kontamine olmuş incirleri tanımlamak için otomatik tespit sistemlerine ihtiyaç duyulmaktadır.

Aflatoksinle kontamine olmuş kuru incirlerin tespiti için kullanılabilecek halka açık bir veri seti bulunmamaktadır. Bu sebeple öncelikle dengeli verilerden oluşan yeni ve özgün veri setleri oluşturulmuştur. Bu veri setleri farklı dalga boylarındaki ışık kaynakları kullanılarak elde edilen incir görüntülerinden oluşmaktadır.

Bu tez çalışması kapsamında incirde aflatoksin tespitine yönelik iki farklı yöntem geliştirilmiştir. Bu yöntemlerden ilki incir üretim tesislerinde aflatoksinli incirleri ayıklamak için kullanılan BGYF ışmasının otomatik tespitine yönelik geliştirilmiştir. Önerilen yöntem, kuru incirde BGYF tespiti için transfer öğrenme modelleri ile yapılan ilk sınıflandırma çalışmasıdır. Sıfırdan bir derin öğrenme modeli geliştirmek zaman alıcı ve zahmetli bir iş olduğundan, bu çalışma kapsamında yaygın olarak kullanılan ve başarısı kanıtlanmış önceden eğitilmiş modeller seçilmiş ve bu probleme uyarlanmıştır. Çalışma sonucunda DenseNet169 modeli, diğer transfer öğrenme modelleri arasında %97,50 doğruluk oranı ile en iyi performansı elde etmiştir. Bu deneysel çalışma, önerdiğimiz yöntemin aflatoksine kontamine incirlerde BGYF'yi tespit etmede en başarılı yöntem olduğunu göstermiştir. Önerilen yöntem incirleri 42 milisaniyede sınıflandırabildiği için incir üretim tesislerinde kurulabilecek otomatik ayıklama sisteminde kolaylıkla kullanılabilecektir.

Çalışma kapsamında, BGYF kontrolünün aflatoksinli incirleri tespit etmedeki etkinliğini kontrol etmek için BGYF ile aflatoksin arasındaki korelasyon kontrol edilmiştir. Çıkan sonuca göre BGYF kontrolü aflatoksinli incirleri %73 doğrulukla tespit edebilmiştir. BGYF her ne kadar aflatoksin varlığının kesin kanıtı olmasa da, aflatoksine tahribatsız tespiti için kullanılabilmektedir.

Geliştirilen ikinci yöntem ise, farklı dalga boyundaki ışık kaynakları kullanılarak elde edilen görüntüler üzerinde aflatoksin tespitine yöneliktir. Önerilen yöntem, BGYF'den farklı bir yöntemle kuru incirde aflatoksin tespiti için bilgisayarlı görü tabanlı transfer öğrenme kullanan ilk sınıflandırma çalışmasıdır. UV ışığının insan sağlığına olan zararlı etkilerinden dolayı daha az zararlı veya zararsız UV/görünür radyasyon sınır bölgesi ışık kaynakları kullanılarak elde edilen görüntüler ile farklı veri setleri oluşturulmuş ve bu veri setleri ile bir sınıflandırma çalışması yapılmıştır. Bu çalışmada, derin öznitelik çıkarımı için yaygın olarak kullanılan ve başarısı kanıtlanmış önceden eğitilmiş modeller kullanılmış ve elde edilen öznitelikler bir sınıflandırıcı yardımıyla sınıflandırılmıştır. Farklı dalga boylarındaki ışık kaynakları kullanılarak elde edilen her bir incir görüntüsü, aflatoksin sınıflandırması için farklı özelliklerin çıkarılmasına olanak sağlamıştır. Ayrıca her bir model, incir görüntüleri üzerinde aflatoksini tespit edebilmek için farklı öznitelikler çıkarmıştır. Bu sebeple farklı modellerden elde edilen öznitelikler

birleştirilerek sınıflandırma doğruluğu artırılmıştır. Çalışma sonucunda 365nm ışık kaynakları altında çekilen görüntüler üzerinde MobileNetV2, ResNet101V2 ve InceptionResNetV2 modelleri kullanılarak çıkarılan öznitelik vektörleri SVM ile sınıflandırılarak en iyi performans elde edilmiştir. Kontamine incirler %100, kontamine olmayan incirler ise %92,3 doğrulukla tespit edilmiştir. Sonuç olarak, %96 genel sınıflandırma doğruluğu elde edilmiştir.

Önerilen yöntemlerden elde edilen sonuçlar aflatoksinli incirlerin tahribatsız, hızlı ve otomatik bir şekilde tespit edilebileceğini göstermektedir. Ayrıca geliştirilen yöntemlerin literatürde yer alan benzer çalışmalardan daha iyi sonuçlar verdiği kanıtlanmıştır. Önerilen yöntemler, kuru incir üretim tesislerinde kullanılan konveyör bant sistemlerinde hızla hareket eden incirler arasında bile aflatoksini otomatik olarak tespit etmek için etkin bir şekilde kullanılabilir.

Tez çalışmasının ana katkıları aşağıdaki gibi maddeler halinde sıralanabilir:

- Farklı dalga boyundaki ışık kaynakları kullanılarak elde edilen kuru incir görüntülerinden dengeli, özgün ve yeni veri setleri oluşturulmuş ve bu veri setleri kullanılarak sınıflandırma çalışmaları için farklı yöntemler önerilmiştir.
- Aflatoksinle kontamine olmuş kuru incir numunelerinin tahribatsız tespiti için yeni, etkili ve sağlam yöntemler sunulmuştur.
- Görüntü analizine dayalı aflatoksin tespitinde transfer öğrenme yaklaşımının etkinliği kanıtlanmıştır.
- Önerilen yöntemler, kuru incir örneklerinde aflatoksin tespiti için transfer öğrenme yaklaşımları kullanılarak yapılan ilk sınıflandırma çalışmalarıdır.
- Önerilen yöntemler, aflatoksin bulaşmış kuru incirlerde bilgisayarlı görüye dayalı tahribatsız tespit yapan önceki aflatoksin tespit yöntemlerine göre daha başarılıdır.
- Geliştirilen yöntemler gerçek dünya ihtiyaçlarına uygulanabilir. Kuru incir üretim tesislerindeki gerçek zamanlı aflatoksin ayıklama sistemlerinde kolaylıkla kullanılabileceği gibi, ihtiyaca göre geliştirilebilecek cihazlar ile aflatoksin tespiti amaçlı da kullanılabilir.

Bu çalışma, transfer öğrenme yöntemlerinin görüntü sınıflandırma problemlerinde başarıyla kullanılabileceğini göstermiştir. Ancak dikkate alınması gereken ve

performansı doğrudan etkileyen faktörlerin de göz ardı edilmemesi gerekir. Bu çalışmada, dengeli dağıtılmış verilerden oluşan bir veri kümesinin, sınıflandırma performansını etkileyen yanlılık sorununu en aza indirdiği deneyimlenmiştir. Transfer öğrenme modellerinin aynı veri kümesine uygulandığında bile farklı performanslar gösterdiği ve modellerin performansının ince ayar ile önemli ölçüde artırılabilceği görülmüştür. Öznitelik çıkarımı ve öznitelik azaltma işlemlerinin sınıflandırma başarısı üzerindeki etkileri gözlenmiştir. Farklı dalga boylarındaki ışık kaynakları kullanılarak elde edilen görüntülerin her biri, sınıflandırma için farklı özelliklerin çıkarılmasını sağlamıştır. Ayrıca önceden eğitilmiş farklı modellerden elde edilen öznitelik vektörlerinin birleştirilmesi sonucunda elde edilen yeni öznitelik vektörlerinin sınıflandırma doğruluğunu arttırdığı gözlemlenmiştir.

Ürünlerdeki aflatoksin kontaminasyon miktarı, referans kromatografik yöntemler kullanılarak kantitatif olarak belirlenmektedir. Bu yöntemler pahalı, zaman alıcı ve iyi donanımlı bir laboratuvar ve personel gerektirmektedir. Aflatoksinin optik yöntemlerle kantitatif ölçümü hız ve maliyet açısından avantaj sağlayacaktır. Aflatoksinin ürünün iç kısmında da bulunacağı unutulmamalıdır, bu nedenle aflatoksin kontaminasyon miktarını tahribatsız olarak ölçmek zor olabilir. Kuru incirlerde aflatoksin kontaminasyonu üzerine yapılan bir çalışmada, referans cihazlar tarafından belirlenen aflatoksin miktarı ile kontamine örneklerin dış yüzeyindeki BGYF yansımalarının toplam yüzey alanı arasında doğrusal bir ilişki olmadığı gösterilmiştir (Ö. B. Özlüoymak, 2018). Bu nedenle aflatoksinin optik spektroskopik yöntemlerle kantitatif ölçümü, daha fazla araştırmaya ihtiyaç duyulan bir alandır.

KAYNAKLAR

- Adeyeye, S. A. O. (2016). Fungal Mycotoxins in Foods: A Review. *Cogent Food & Agriculture*, 2(1). DOI: 10.1080/23311932.2016.1213127
- Anaç, H. (2012). *Geçmişten Günümüze İncir*. Aydın Ticaret Odası Kültür Yayınları.
- Atas, M., Yardimci, Y., Temizel, A. (2011). Aflatoxin Contaminated Chili Pepper Detection by Hyperspectral Imaging and Machine Learning Musa. *Sensing for Agriculture and Food Quality and Safety III*, 8027. DOI: 10.1117/12.883237
- Ataş, M., Yardimci, Y., Temizel, A. (2012). A New Approach to Aflatoxin Detection in Chili Pepper by Machine Vision. *Computers and Electronics in Agriculture*, 87, 129–141. DOI: 10.1016/j.compag.2012.06.001
- Bertani, F. R., Businaro, L., Gambacorta, L., Mencattini, A., Brenda, D., Di Giuseppe, D., De Ninno, A., Solfrizzo, M., Martinelli, E., Gerardino, A. (2020). Optical Detection of Aflatoxins B in Grained Almonds Using Fluorescence Spectroscopy and Machine Learning Algorithms. *Food Control*, 112. DOI: 10.1016/j.foodcont.2019.107073
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. DOI: 10.1023/A:1010933404324
- Casella, G., Fienberg, S., Olkin, I. (2013). *An Introduction to Statistical Learning*. Springer Texts in Statistics. DOI: 10.1007/978-1-4614-7138-7
- Chakraborty, S. K., Mahanti, N. K., Mansuri, S. M., Tripathi, M. K., Kotwaliwale, N., Jayas, D. S. (2020). Non-Destructive Classification and Prediction of Aflatoxin-B1 Concentration in Maize Kernels Using Vis–NIR (400–1000 nm) Hyperspectral Imaging. *Journal of Food Science and Technology*, 58, 437–450. DOI: 10.1007/s13197-020-04552-w
- Chavez, R. A., Cheng, X., Stasiewicz, M. J. (2020). A Review of the Methodology of Analyzing Aflatoxin and Fumonisin in Single Corn Kernels and the Potential Impacts of These Methods on Food Security. *Foods*, 9(3), 297. DOI: 10.3390/foods9030297
- Chelladurai, V., Jayas, D. S. (2014). Near-Infrared Imaging and Spectroscopy. İçinde A. Manickavasagan & H. Jayasuriya (Ed.), *Imaging with Electromagnetic Spectrum* (ss. 87–127). Springer-Verlag Berlin Heidelberg. DOI: 10.1007/978-3-642-54888-8_6
- Cheng, X., Vella, A., Stasiewicz, M. J. (2019). Classification of Aflatoxin Contaminated Single Corn Kernels by Ultraviolet to Near Infrared Spectroscopy. *Food Control*, 98, 253–261. DOI: 10.1016/j.foodcont.2018.11.037

- Cheplygina, V., de Bruijne, M., Pluim, J. P. W. (2019). Not-so-Supervised: A Survey of Semi-Supervised, Multi-Instance, and Transfer Learning in Medical Image Analysis. *Medical Image Analysis*, 54, 280–296. DOI: 10.1016/J.MEDIA.2019.03.009
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR*, 1800–1807. DOI: 10.1109/CVPR.2017.195
- Cinar, A., Onbaşı, E. (2020). Mycotoxins: The Hidden Danger in Foods. *Mycotoxins and Food Safety*. DOI: 10.5772/INTECHOPEN.89001
- Cortes, C., Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20, 273–297. DOI: 10.1023/A:1022627411411
- Deng, J., Zhang, X., Li, M., Jiang, H., Chen, Q. (2022). Feasibility Study on Raman Spectra-Based Deep Learning Models for Monitoring The Contamination Degree and Level of Aflatoxin B1 in Edible Oil. *Microchemical Journal*, 180. DOI: 10.1016/J.MICROC.2022.107613
- Doster, M. A., Michailides, T. J. (1998). Production of Bright Greenish Yellow Fluorescence in Figs Infected by *Aspergillus* Species in California Orchards. *Plant disease*, 82(6), 669–673. DOI: 10.1094/PDIS.1998.82.6.669
- Durmuş, E., Güneş, A., Kalkan, H. (2014). Yakın Kızılötesi Spektroskopisi ile İncirde Yüzey Küfü Tespiti ve Yüzey Küfünün Aflatoksin Seviyesine Etkisi. *2014 IEEE 22nd Signal Processing and Communications Applications Conference (SIU 2014)*, 445–448. DOI: 10.1109/SIU.2014.6830261
- Durmuş, E., Güneş, A., Kalkan, H. (2017). Detection of Aflatoxin and Surface Mould Contaminated Figs by Using Fourier Transform Near-Infrared Reflectance Spectroscopy. *Journal of the Science of Food and Agriculture*, 97(1), 317–323. DOI: 10.1002/jsfa.7735
- Engel, J., Gerretzen, J., Szymańska, E., Jansen, J. J., Downey, G., Blanchet, L., Buydens, L. M. C. (2013). Breaking with Trends in Pre-processing? *TrAC - Trends in Analytical Chemistry*, 50, 96–106. DOI: 10.1016/J.TRAC.2013.04.015
- European Commission-EC. (2010). Regulations. *Official Journal of the European Union*, L 50, 8–12.
- Gallagher, R. P., Lee, T. K. (2006). Adverse Effects of Ultraviolet Radiation: A Brief Review. *Progress in Biophysics and Molecular Biology*, 92(1), 119–131. DOI: 10.1016/J.PBIOMOLBIO.2006.02.011
- Gao, J., Ni, J., Wang, D., Deng, L., Li, J., Han, Z. (2020). Pixel-Level Aflatoxin Detecting in Maize Based on Feature Selection and Hyperspectral Imaging. *Spectrochimica Acta - Part A: Molecular and Biomolecular Spectroscopy*, 234. DOI: 10.1016/J.SAA.2020.118269

- Gao, J., Zhao, L., Li, J., Deng, L., Ni, J., Han, Z. (2021). Aflatoxin Rapid Detection Based on Hyperspectral with 1D-Convolution Neural Network in The Pixel Level. *Food Chemistry*, 360. DOI: 10.1016/J.FOODCHEM.2021.129968
- Gerretzen, J., Szymańska, E., Bart, J., Davies, A. N., van Manen, H. J., van den Heuvel, E. R., Jansen, J. J., Buydens, L. M. C. (2016). Boosting Model Performance and Interpretation by Entangling Preprocessing Selection and Variable Selection. *Analytica Chimica Acta*, 938, 44–52. DOI: 10.1016/J.ACA.2016.08.022
- Gimeno, A., Martins, M. L. (2006). *Mycotoxins and Mycotoxicosis in Animals and Humans*. Miami, USA: Special Nutrients, Inc.
- Gislason, P. O., Benediktsson, J. A., Sveinsson, J. R. (2006). Random Forests for Land Cover Classification. *Pattern Recognition Letters*, 27(4), 294–300. DOI: 10.1016/J.PATREC.2005.08.011
- Glorot, X., Bordes, A., Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks. *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, PMLR*, 15, 315–323.
- Gunes, A., Durmus, E., Kalkan, H. (2013). Detection of High Aflatoxin Risk Figs with Computer Vision. *IEEE 21st Signal Processing and Communications Applications Conference, SIU 2013*, 31–34. DOI: 10.1109/SIU.2013.6531575
- Gunes, A., Kalkan, H., Durmus, E., Butukcan, M. B. (2013). Detection of Aflatoxin Contaminated Figs Using Near-Infrared (NIR) Reflectance Spectroscopy. *2013 International Conference on Electronics, Computer and Computation, ICECCO 2013*, 123–126. DOI: 10.1109/ICECCO.2013.6718244
- Gürhayta, O. F., Çağındı, Ö. (2016). Kurutulmuş Meyvelerde Aflatoksin ve Okratoksin A Varlığının ve Sağlık Üzerine Etkilerinin Değerlendirilmesi. *Celal Bayar Üniversitesi Fen Bilimleri Dergisi*, 12(2), 327–338. DOI: 10.18466/cbujos.90850
- Han, Z., Gao, J. (2019). Pixel-Level Aflatoxin Detecting Based on Deep Learning and Hyperspectral Imaging. *Computers and Electronics in Agriculture*, 164. DOI: 10.1016/j.compag.2019.104888
- Haque, M. A., Wang, Y., Shen, Z., Li, X., Saleemi, M. K., He, C. (2020). Mycotoxin Contamination and Control Strategy in Human, Domestic Animal and Poultry: A Review. *Microbial Pathogenesis*, 142. DOI: 10.1016/j.micpath.2020.104095
- He, K., Zhang, X., Ren, S., Sun, J. (2014). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *Proceedings of the IEEE International Conference on Computer Vision*, 1026–1034. DOI: 10.48550/arXiv.1502.01852
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. DOI: 10.1109/CVPR.2016.90

- He, X., Yan, C., Jiang, X., Shen, F., You, J., Fang, Y. (2021). Classification of Aflatoxin B1 Naturally Contaminated Peanut Using Visible and Near-Infrared Hyperspectral Imaging by Integrating Spectral and Texture Features. *Infrared Physics and Technology*, 114. DOI: 10.1016/J.INFRARED.2021.103652
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. DOI: 10.48550/arxiv.1704.04861
- Hruska, Z., Yao, H., Kincaid, R., Brown, R. L., Bhatnagar, D., Cleveland, T. E. (2017). Temporal Effects on Internal Fluorescence Emissions Associated with Aflatoxin Contamination from Corn Kernel Cross-Sections Inoculated with Toxigenic and Atoxigenic *Aspergillus Flavus*. *Frontiers in Microbiology*, 8, 1–10. DOI: 10.3389/fmicb.2017.01718
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua*, 2261–2269. DOI: 10.1109/CVPR.2017.243
- Huo, J., Shi, T., Chang, J. (2016). Comparison of Random Forest and SVM for Electrical Short-term Load Forecast with Different Data Sources. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*, 1077–1080. DOI: 10.1109/ICSESS.2016.7883252
- Janik, E., Niemcewicz, M., Ceremuga, M., Stela, M., Saluk-Bijak, J., Siadkowski, A., Bijak, M. (2020). Molecular Aspects of Mycotoxins-A Serious Problem for Human Health. *International Journal of Molecular Sciences*, 21(21). DOI: 10.3390/ijms21218187
- Kalkan, H., Beriat, P., Yardimci, Y., Pearson, T. C. (2011). Detection of Contaminated Hazelnuts and Ground Red Chili Pepper Flakes by Multispectral Imaging. *Computers and Electronics in Agriculture*, 77(1), 28–34. DOI: 10.1016/j.compag.2011.03.005
- Kalkan, H., Güneş, A., Durmuş, E., Kuşçu, A. (2014). Non-Invasive Detection of Aflatoxin-Contaminated Figs Using Fluorescence and Multispectral Imaging. *Food Additives and Contaminants - Part A*, 31(8), 1414–1421. DOI: 10.1080/19440049.2014.926398
- Karaca, H. (2005). Kuru İncirlerin Aflatoksin, Patulin, Ergosterol İçeriği ve Farklı Koşullarda Aflatoksinlerin Parçalanma Düzeyleri. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli, 167490.
- Karaca, H., Nas, S. (2004). Ülkemiz Açısından Önemli Bazı Kuru Meyvelerde Toksik İkincil Metabolitler. *Akademik Gıda*, 2(2), 16–21.
- Khadka, J. (2019). Sampling Error in Survey Research. *International Journal of Science and Research (IJSR)*, 8(1).

- Kim, Y. K., Baek, I., Lee, K. M., Qin, J., Kim, G., Shin, B. K., Chan, D. E., Herrman, T. J., Cho, S. kil, Kim, M. S. (2022). Investigation of Reflectance, Fluorescence, and Raman Hyperspectral Imaging Techniques for Rapid Detection of Aflatoxins in Ground Maize. *Food Control*, 132. DOI: 10.1016/J.FOODCONT.2021.108479
- Kimuli, D., Lawrence, K. C., Yoon, S. C., Wang, W., Heitschmidt, G. W., Zhao, X. (2017). A SWIR Hyperspectral Imaging Method for Classifying Aflatoxin B1 Contaminated Maize Kernels. *2017 ASABE Annual International Meeting*. DOI: 10.13031/aim.201700764
- Kimuli, D., Wang, W., Lawrence, K. C., Yoon, S. C., Ni, X., Heitschmidt, G. W. (2018). Utilisation of Visible/Near-Infrared Hyperspectral Images to Classify Aflatoxin B1 Contaminated Maize Kernels. *Biosystems Engineering*, 166, 150–160. DOI: 10.1016/j.biosystemseng.2017.11.018
- Kılıç, C., İner, B. (2022). A Novel Method for Non-Invasive Detection of Aflatoxin Contaminated Dried Figs with Deep Transfer Learning Approach. *Ecological Informatics*, 70. DOI: 10.1016/J.ECOINF.2022.101728
- Konak, R. (2017). Kuru İncir'in Besin İçeriği Yolculuğu. *İncir Araştırma Dergisi*, 12–13.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *25th International Conference on Neural Information Processing Systems*, 1097–1105. DOI: 10.1145/3065386
- Kumar, P., Mahato, D. K., Kamle, M., Mohanta, T. K., Kang, S. G. (2017). Aflatoxins: A Global Concern for Food Safety, Human Health and Their Management. *Frontiers in Microbiology*, 7, 1–10. DOI: 10.3389/fmicb.2016.02170
- Lawrence, K. P., Douki, T., Sarkany, R. P. E., Acker, S., Herzog, B., Young, A. R. (2018). The UV/Visible Radiation Boundary Region (385-405 nm) Damages Skin Cells and Induces “dark” Cyclobutane Pyrimidine Dimers in Human Skin in vivo. *Scientific Reports*, 8. DOI: 10.1038/s41598-018-30738-6
- Lee, K. M., Herrman, T. J., Yun, U. (2014). Application of Raman Spectroscopy for Qualitative and Quantitative Analysis of Aflatoxins in Ground Maize Samples. *Journal of Cereal Science*, 59(1), 70–78. DOI: 10.1016/j.jcs.2013.10.004
- Lunadei, L., Ruiz-Garcia, L., Bodria, L., Guidetti, R. (2013). Image-Based Screening for the Identification of Bright Greenish Yellow Fluorescence on Pistachio Nuts and Cashews. *Food and Bioprocess Technology*, 6(5), 1261–1268. DOI: 10.1007/s11947-012-0815-8
- Mahato, D. K., Lee, K. E., Kamle, M., Devi, S., Dewangan, K. N., Kumar, P., Kang, S. G. (2019). Aflatoxins in Food and Feed: An Overview on Prevalence, Detection and Control Strategies. *Frontiers in Microbiology*, 10(October), 1–10. DOI: 10.3389/fmicb.2019.02266

- Manickavasagan, A., Jayasuriya, H. (2014). *Imaging with Electromagnetic Spectrum*. Springer-Verlag Berlin Heidelberg. DOI: 10.1007/978-3-642-54888-8
- Marsh, P. B., Simpson, M. E., Ferretti, R. J., Merola, G. V., Donoso, J., Craig, G. O., Trucksess, M. W., Work, P. S. (1969). Mechanism of Formation of a Fluorescence in Cotton Fiber Associated with Aflatoxins in the Seeds at Harvest. *Journal of Agricultural and Food Chemistry*, 17(3), 468–472. DOI: 10.1021/jf60163a006
- Mishra, M. (2022). Spectroscopic Techniques for the Analysis of Food Quality, Chemistry, and Function. İçinde A. K. Shukla (Ed.), *Advanced Spectroscopic Techniques for Food Quality* (ss. 1–22). Royal Society of Chemistry. DOI: 10.1039/9781839165849-00001
- Mitchell, N. J., Bowers, E., Hurburgh, C., Wu, F. (2016). Potential Economic Losses to the US Corn Industry From Aflatoxin Contamination. *Food Additives and Contaminants: Part A*, 33(3), 540–550. DOI: 10.1080/19440049.2016.1138545
- Nalepa, J., Marcinkiewicz, M., Kawulok, M. (2019). Data Augmentation for Brain-Tumor Segmentation: A Review. *Frontiers in Computational Neuroscience*, 13. DOI: 10.3389/FNCOM.2019.00083
- Nazhand, A., Durazzo, A., Lucarini, M., Souto, E. B., Santini, A. (2020). Characteristics, Occurrence, Detection and Detoxification of Aflatoxins in Foods and Feeds. *Foods*, 9(5), 644. DOI: 10.3390/foods9050644
- Özlüoymak, Ö. (2014). Development of a UV-based Imaging System for Real-Time Detection and Separation of Dried Figs Contaminated with Aflatoxins. *Tarım Bilimleri Dergisi*, 20(3), 302–316. DOI: 10.15832/tbd.87873
- Özlüoymak, Ö. B. (2018). Prediction of Aflatoxin Contamination on Dried Fig (*Ficus Carica*) Samples by Spectral Image Analysis in Comparison with Laboratory Results. *Fresenius Environmental Bulletin*, 27(2), 681–689.
- Pal, M. (2007). Random Forest Classifier for Remote Sensing Classification. *International Journal of Remote Sensing*, 26(1), 217–222. DOI: 10.1080/01431160412331269698
- Rosenstein, M. T., Marx, Z., Kaelbling, L. P., Dietterich, T. G. (2005). To Transfer or Not to Transfer. *NIPS 2005 Workshop on Transfer Learning*. Kanada, 9 Aralık 2005
- Ruder, S. (2016). An Overview of Gradient Descent Optimization Algorithms. *ArXiv*. DOI: 10.48550/arXiv.1609.04747
- Samiappan, S., Bruce, L. M., Yao, H., Hruska, Z., Brown, R. L., Bhatnagar, D., Cleveland, T. E. (2013). Support Vector Machines Classification of Fluorescence Hyperspectral Image for Detection of Aflatoxin in Corn Kernels. *2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 1–4. DOI: 10.1109/WHISPERS.2013.8080645

- Sauer, M., Hofkens, J., Enderlein, J. (2011). Basic Principles of Fluorescence Spectroscopy. İçinde *Handbook of Fluorescence Spectroscopy and Imaging* (ss. 1–30). Weinheim, Germany: Wiley-VCH Verlag GmbH & Co. KGaA. DOI: 10.1002/9783527633500.ch1
- Schrenk, D., Bignami, M., Bodin, L., Chipman, J. K., del Mazo, J., Grasl-Kraupp, B., Hogstrand, C., Hoogenboom, L., Leblanc, J. C., Nebbia, C. S., Nielsen, E., Ntzani, E., Petersen, A., Sand, S., Schwerdtle, T., Vleminckx, C., Marko, D., Oswald, I. P., Piersma, A., ... Wallace, H. (2020). Risk Assessment of Aflatoxins in Food. *EFSA Journal*, 18(3). DOI: 10.2903/j.efsa.2020.6040
- Shabeer, S., Asad, S., Jamal, A., Ali, A. (2022). Aflatoxin Contamination, Its Impact and Management Strategies: An Updated Review. *Toxins*, 14(5), 307. DOI: 10.3390/TOXINS14050307
- Sharman, M., Patey, A. L., Bloomfield, D. A., Gilbert, J. (1991). Surveillance and Control of Aflatoxin Contamination of Dried Figs and Fig Paste Imported into the United Kingdom. *Food Additives and Contaminants*, 8(3), 299–304. DOI: 10.1080/02652039109373979
- Shorten, C., Khoshgoftaar, T. M. (2019). A Survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). DOI: 10.1186/s40537-019-0197-0
- Simonyan, K., Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations, ICLR 2015*. DOI: 10.48550/arxiv.1409.1556
- Stasiewicz, M. J., Falade, T. D. O., Mutuma, M., Mutiga, S. K., Harvey, J. J. W., Fox, G., Pearson, T. C., Muthomi, J. W., Nelson, R. J. (2017). Multi-Spectral Kernel Sorting to Reduce Aflatoxins and Fumonisin in Kenyan Maize. *Food Control*, 78, 203–214. DOI: 10.1016/j.foodcont.2017.02.038
- Steiner, W. E., Rieker, R. H., Battaglia, R. (1988). Aflatoxin Contamination in Dried Figs: Distribution and Association with Fluorescence. *Journal of Agricultural and Food Chemistry*, 36(1), 88–91. DOI: 10.1021/jf00079a022
- Szegedy, C., Ioffe, S., Vanhoucke, V., Alemi, A. A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *31st AAAI Conference on Artificial Intelligence, AAAI 2017*, 4278–4284. DOI: 10.1609/aaai.v31i1.11231
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2015). Going Deeper with Convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9. DOI: 10.1109/CVPR.2015.7298594

- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818–2826. DOI: 10.1109/CVPR.2016.308
- Tan, M., Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *36th International Conference on Machine Learning, ICML 2019*, 10691–10700. DOI: 10.48550/arxiv.1905.11946
- Tao, F., Yao, H., Hruska, Z., Burger, L. W., Rajasekaran, K., Bhatnagar, D. (2018). Recent Development of Optical Methods in Rapid and Non-Destructive Detection of Aflatoxin and Fungal Contamination in Agricultural Products. *TrAC - Trends in Analytical Chemistry*, 100, 65–81. DOI: 10.1016/j.trac.2017.12.017
- Tao, F., Yao, H., Zhu, F., Hruska, Z., Liu, Y., Rajasekaran, K., Bhatnagar, D. (2019). A Rapid and Nondestructive Method for Simultaneous Determination of Aflatoxigenic Fungus and Aflatoxin Contamination on Corn Kernels. *Journal of Agricultural and Food Chemistry*, 67(18), 5230–5239. DOI: 10.1021/acs.jafc.9b01044
- Ticaret Bakanlığı. (2020). 2019 Yılı Kuru İncir Raporu. *T.C. Ticaret Bakanlığı Esnaf, Sanatkârlar ve Kooperatifçilik Genel Müdürlüğü*.
- Tripathi, S., Mishra, H. N. (2009). A Rapid FT-NIR Method for Estimation of Aflatoxin B1 in Red Chili Powder. *Food Control*, 20(9), 840–846. DOI: 10.1016/j.foodcont.2008.11.003
- Udomkun, P., Wiredu, A. N., Nagle, M., Müller, J., Vanlauwe, B., Bandyopadhyay, R. (2017). Innovative Technologies to Manage Aflatoxins in Foods and Feeds and The Profitability of Application – A Review. *Food Control*, 76, 127–138. DOI: 10.1016/j.foodcont.2017.01.008
- Valencia-Quintana, R., Milić, M., Jakšić, D., Klarić, M. Š., Tenorio-Arvide, M. G., Pérez-Flores, G. A., Bonassi, S., Sánchez-Alarcón, J. (2020). Environment Changes, Aflatoxins, and Health Issues, a Review. *International Journal of Environmental Research and Public Health*, 17(21), 7850. DOI: 10.3390/ijerph17217850
- Wacoo, A. P., Wendiro, D., Vuzi, P. C., Hawumba, J. F. (2014). Methods for Detection of Aflatoxins in Agricultural Food Crops. *Journal of Applied Chemistry*, 2014, 1–15. DOI: 10.1155/2014/706291
- Wang, W., Heitschmidt, G. W., Ni, X., Windham, W. R., Hawkins, S., Chu, X. (2014). Identification of Aflatoxin B1 on Maize Kernel Surfaces Using Hyperspectral Imaging. *Food Control*, 42, 78–86. DOI: 10.1016/j.foodcont.2014.01.038
- Wu, Q., Xu, J., Xu, H. (2019). Discrimination of Aflatoxin B1 Contaminated Pistachio Kernels Using Laser Induced Fluorescence Spectroscopy. *Biosystems Engineering*, 179, 22–34. DOI: 10.1016/j.biosystemseng.2018.12.009

- Xu, B., Wang, N., Kong, H., Chen, T., Li, M. (2015). *Empirical Evaluation of Rectified Activations in Convolutional Network*. DOI: 10.48550/arxiv.1505.00853
- Yang, Y., Zhang, Y., He, C., Xie, M., Luo, H., Wang, Y., Zhang, J. (2018). Rapid Screen of Aflatoxin-Contaminated Peanut Oil Using Fourier Transform Infrared Spectroscopy Combined with Multivariate Decision Tree. *International Journal of Food Science and Technology*, 53(10), 2386–2393. DOI: 10.1111/ijfs.13831
- Yao, H., Hruska, Z., Diana Di Mavungu, J. (2015). Developments in Detection and Determination of Aflatoxins. *World Mycotoxin Journal*, 8(2), 181–191. DOI: 10.3920/WMJ2014.1797
- Yao, H., Hruska, Z., Kincaid, R., Brown, R., Cleveland, T., Bhatnagar, D. (2010). Correlation and Classification of Single Kernel Fluorescence Hyperspectral Data with Aflatoxin Concentration in Corn Kernels Inoculated with *Aspergillus Flavus* Spores. *Food Additives and Contaminants: Part A*, 27(5), 701–709. DOI: 10.1080/19440040903527368
- Yao, H., Hruska, Z., Kincaid, R., Brown, R. L., Bhatnagar, D., Cleveland, T. E. (2012). SVM-Based Feature Extraction and Classification of Aflatoxin Contaminated Corn Using Fluorescence Hyperspectral Data. *4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 1–4. DOI: 10.1109/WHISPERS.2012.6874234
- Yao, H., Hruska, Z., Kincaid, R., Brown, R. L., Bhatnagar, D., Cleveland, T. E. (2013). Detecting Maize Inoculated with Toxigenic and Atoxigenic Fungal Strains with Fluorescence Hyperspectral Imagery. *Biosystems Engineering*, 115(2), 125–135. DOI: 10.1016/j.biosystemseng.2013.03.006
- Yao, H., Hruska, Z., Kincaid, R., Ononye, A., Brown, R. L., Cleveland, T. E. (2010). Spectral Angle Mapper Classification of Fluorescence Hyperspectral Image for Aflatoxin Contaminated Corn. *2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, 1–4. DOI: 10.1109/WHISPERS.2010.5594920
- Zain, M. E. (2011). Impact of Mycotoxins on Humans and Animals. *Journal of Saudi Chemical Society*, 15(2), 129–144. DOI: 10.1016/J.JSCS.2010.06.006
- Zhang, R., Ying, Y., Rao, X., Li, J. (2012). Quality and Safety Assessment of Food and Agricultural Products by Hyperspectral Fluorescence Imaging. *Journal of the Science of Food and Agriculture*, 92(12), 2397–2408. DOI: 10.1002/jsfa.5702
- Zhongzhi, H., Limiao, D. (2020). Aflatoxin Contaminated Degree Detection by Hyperspectral Data Using Band Index. *Food and Chemical Toxicology*, 137. DOI: 10.1016/j.fct.2020.111159
- Zhou, Q., Huang, W., Liang, D., Tian, X. (2021). Classification of Aflatoxin B1 Concentration of Single Maize Kernel Based on Near-Infrared Hyperspectral Imaging and Feature Selection. *Sensors*, 21(13), 1–16. DOI: 10.3390/s21134257

- Zhou, Q., Huang, W., Tian, X. (2022). Feature Wavelength Selection Based on the Combination of Image and Spectrum for Aflatoxin B1 Concentration Classification in Single Maize Kernels. *Agriculture*, 12, 385. DOI: 10.3390/agriculture12030385
- Zhu, F., Yao, H., Hruska, Z., Kincaid, R., Brown, R., Bhatnagar, D., Cleveland, T. (2016). Integration of Fluorescence and Reflectance Visible Near-Infrared (VNIR) Hyperspectral Images for Detection of Aflatoxins in Corn Kernels. *American Society of Agricultural and Biological Engineers (ASABE)*, 59(3), 785–794. DOI: 10.13031/trans.59.11365
- Zhu, H., Yang, L., Gao, J., Gao, M., Han, Z. (2022). Quantitative Detection of Aflatoxin B1 by Subpixel CNN Regression. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 268. DOI: 10.1016/j.saa.2021.120633
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., He, Q. (2021). A Comprehensive Survey on Transfer Learning. *Proceedings of the IEEE*, 109(1), 43–76. DOI: 10.1109/JPROC.2020.3004555
- Ziyadeh, P., Ahmadi, V. F., Bazyar, P., Cavallo, E. (2021). Comparison of Different Image Processing Methods for Segregation of Peanut (*Arachis hypogaea* L.) Seeds Infected by Aflatoxin-Producing Fungi. *Agronomy*, 11(5), 873. DOI: 10.3390/agronomy11050873
- Zoph, B., Vasudevan, V., Shlens, J., Le, Q. V. (2018). Learning Transferable Architectures for Scalable Image Recognition. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 8697–8710. DOI: 10.1109/CVPR.2018.00907

KİŞİSEL YAYIN VE ESERLER

- Kılıç, C.**, İner, B. (2022). A Novel Method for Non-Invasive Detection of Aflatoxin Contaminated Dried Figs with Deep Transfer Learning Approach. *Ecological Informatics*, 70. <https://doi.org/10.1016/J.ECOINF.2022.101728>
- Baz İ., **Kılıç C.**, (2020). Fotometrik Stereo Yöntemi ile Doküman Yüzey Topoğrafyasının 3B Modellenmesi, 28. *IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU 2020)*, 5-7 Ekim 2020
- Fank, S., Aydemir, B., Vatan, C., Anıl, D., **Kılıç, C.**, Kuyrukluıldız, A., (2015). A new 200 N dead weight force standard machine. *XXI IMEKO World Congress "Measurement in Research and Industry"*, Prague, Czech Republic, August 30 - September 4, 2015.
- Kılıç C.**, Soğukpınar İ., (2004). Increasing Security on Database Systems. TADA System, *The 3rd Asia Pasific International Symposium on Information Technology (APIS)*. İstanbul, Türkiye, 13-14 Ocak 2004

ÖZGEÇMİŞ

1995 yılında girdiği Kocaeli Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nden 1999 yılında mezun oldu. 2000-2003 yılları arasında Gebze Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı'nda Yüksek Lisans eğitimini tamamladı. 1999 yılından bu yana TÜBİTAK'ın farklı enstitülerinde proje yürütücülüğünden birim yöneticiliğine kadar birçok farklı pozisyonlarda görev almış ve halen aktif olarak çalışmaya devam etmektedir.