

RGB, VNIR ve SWIR Kameralar ile Elde Edilen Buğday Çekirdeđi Görüntülerinin Farklı
Füzyon Stratejileri Uygulanarak Tanınması ve Sınıflandırılması

Büşra Yavuz

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliđi Anabilim Dalı

Haziran 2020

Identification and Classification of Wheat Kernel Images Obtained by RGB, VNIR and
SWIR Cameras by Implementing Different Fusion Strategies

Büşra Yavuz

MASTER OF SCIENCE THESIS

Department of Computer Engineering

June 2020

RGB, VNIR ve SWIR Kameralar ile Elde Edilen Buğday Çekirdeđi Görüntülerinin Farklı
Füzyon Stratejileri Uygulanarak Tanınması ve Sınıflandırılması

Büşra Yavuz

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliđi Uyarınca
Bilgisayar Mühendisliđi Anabilim Dalı
Bilgisayar Yazılımı Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Dr. Öğr. Üyesi Şahin IŞIK

Bu Tez TÜBİTAK 1001-Bilimsel ve Teknolojik Araştırma Projelerini Destekleme
Programı tarafından “1160576” numaralı proje çerçevesinde desteklenmiştir.

Haziran 2020

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre Dr. Öğr. Üyesi Şahin IŞIK danışmanlığında hazırlamış olduğum “RGB, VNIR ve SWIR Kameralar ile Elde Edilen Buğday Çekirdeği Görüntülerinin Farklı Füzyon Stratejileri Uygulanarak Tanınması ve Sınıflandırılması” başlıklı YÜKSEK LİSANS tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 08/06/2020

Büşra Yavuz

İmza

ÖZET

Tarım endüstrisinde makine öğrenme ve derin öğrenme sistemlerinin kullanımı oldukça büyük bir artış göstermiştir. Tarımsal ürünlerin çeşitlerinin tanınması sınıflandırılması üretim kalitesini ve verimliliğini olumlu yönde etkilemektedir. Tarım ürünleri arasında buğday ülkemizde ve dünyada insanların ihtiyaçlarını karşılaması açısından gıda ve sanayi sektöründe oldukça büyük bir paya sahiptir. Türkiye aynı zamanda dünyanın önde gelen buğday ihracatçılarından biridir. Dolayısıyla üretiminin sağlanması ve devamlılığı ülkemiz ve dünya ekonomisi adına da oldukça önemlidir. Buğday tanelerinin kalitesi, genetik ya da çevresel faktörlerden etkilenmektedir. Yıllardır göz ardı edilen bu durum, büyük maddi kayıplara neden olmaktadır. Buğdayın kalite düzeyinin ve çeşitlerinin doğru belirlenmesi de üretim kalitesini de doğrudan etkilemektedir. Çeşitlerin tanınması ve çeşitlerin kimliğini belirleyebilmek için sınıflandırma yöntemlerinin hayata geçirilmesi, depolama işlemlerin doğru bir şekilde yapılmasını sağlayacaktır. Böylece işlemler daha hızlı ilerleyecek; zaman, emek ve para kaybının önüne geçilebilecektir. Dolayısıyla buğday çeşidi ne kadar hızlı ve doğru tanınırsa üretilen buğdayın kalitesi de ona göre belirlenir. Doğru sınıflandırma ve tanıma yapılabilmesi için yeni teknolojik sistemler geliştirilmektedir. Bu çalışma kapsamında üç farklı görüntüleme tekniğinden (RGB, VNIR, SWIR) elde edilmiş 8000 adet buğday görüntüsünden oluşturulan veri seti üzerinde tanıma ve sınıflandırma çalışmaları yapılmıştır. 6400 görüntü eğitim için ayrılırken 1600 görüntü test için kullanılmıştır. Tanıma doğruluğunu arttırmak adına öncelikle imge (image) füzyonu ve öznitelik (feature) füzyonu olmak üzere iki farklı füzyon yöntemi uygulanmıştır. Bu yöntemler buğday çekirdeği sınıflandırması üzerinde sırasıyla %98,19 ve %100 doğruluk oranları elde edilerek yüksek başarılar elde edilmiştir. Bunların yanı sıra yalnızca VNIR görüntüleme tekniğinden elde edilen 8000 buğday çekirdeği görüntüsünden oluşan veri seti ile VGG16 ve Shallow (sığ) olmak üzere iki farklı derin öğrenme modeli üzerinde çalışma yapılmıştır. Shallow modelinin performansı %80,13'lük bir doğruluk oranına ulaşırken, VGG16 modeli üzerinden %91,13'lük bir doğruluk sağlanmıştır. Eğitimler sonucu elde edilen sonuçlara göre derin öğrenme yöntemlerinin parametrik bağımlılara göre daha başarılı olduğu görülmüştür. Geliştirilen bu sistem etkili ve zahmetsiz tanımlama ve sınıflandırma imkânı sunarken aynı zamanda derin öğrenme teknolojisinin buğday çekirdeği türlerini yüksek performans ile ayırt edebileceğini göstermektedir. Ülke ekonomisinde büyümeye yaptığı katkının yanı sıra buğday endüstrisinde insan iş gücünü azaltarak daha fazla verimlilik ve üretkenlik sağlamak adına önemli bir adım atılmasını sağlamaktadır.

Anahtar Kelimeler: Derin Öğrenme, Makine Öğrenmesi, Sınıflandırma

SUMMARY

The use of machine learning and deep learning systems in the agricultural industry has increased considerably. Recognition and classification of agricultural products positively affects production quality and productivity. Among the agricultural products, wheat has a large share in the food and industrial sector in terms of supplying the needs of people in our country and the world. Turkey is also one of the world's leading wheat exporters. Therefore, the continuity of production is so important for our country and the world economy. The quality of wheat grains is affected by genetic or environmental factors. This situation, which has been ignored for many years, causes huge financial losses. Correct determination of the quality level and types of wheat also directly affects the production quality. Implementation of classification methods for the identification of varieties will ensure that the storage operations are performed correctly. Thus, transactions will proceed faster; loss of time, labor and money can be prevented. Therefore, the more quickly and accurately the wheat type is, the better the quality of wheat produced. New technological systems have been developed for accurate classification and recognition. In this way, manpower is minimized, time and labor are saved. In this project, recognition and classification studies were performed on the data set composed of 8000 wheat images obtained from three different imaging techniques (RGB, VNIR, SWIR). While 6400 images were used for the training, 1600 images were used for testing. In order to increase the accuracy of recognition, two different fusion methods were performed: image fusion and feature fusion. These methods have achieved a high success rate of 99.95% on wheat seed classification. These methods have achieved high success on wheat seed classification with 98.19% and 100% accuracy rates, respectively. In addition, two different deep learning models, VGG16 and Shallow, were used by using a data set consisting of 8000 wheat kernels images obtained from VNIR imaging technique only. Performance the Shallow model achieved an accuracy of 80.13%, while the VGG16 model achieved an accuracy of 91.13%. According to the results of obtained by simulations, deep learning methods were found to be more successful than parametric dependent based ones. This developed system provides effective and effortless identification and classification, also demonstrates that deep learning technology can distinguish wheat seed species with high performance. In addition to his contribution to growth in the national economy, an important step was taken to ensure greater efficiency and productivity by reducing human labor in wheat industry.

Keywords: Deep Learning, Machine Learning, Classification

TEŞEKKÜR

Tez konumun belirlenmesinden itibaren tüm süreç boyunca her türlü fikir, görüş, düşünce ve yönlendirmesiyle ilerlememe yardımcı olan Sayın hocam Doç. Dr. Kemal ÖZKAN'a teşekkür ederim.

Tezimin her aşamasında yardımlarını esirgemeyen, tez sürecinde ve tezimin tamamlanmasında, yapılan araştırmalarda, karşılaştığım sorunlarda ve yönlendirmesinde, tezimin tamamlanmasında destek olan tez danışmanım Dr. Öğr. Üyesi Şahin IŞIK'a teşekkür ederim.

Hayatım boyunca her zaman olduğu gibi bu süreçte de her türlü destekleriyle yanımda olan, hiçbir zaman maddi ve manevi desteklerini esirgemeyen canım aileme ve sevgili eşime teşekkür ederim.

Tezimin yazım aşamasında hayatıma dâhil olan bana çok şey öğreten, hayata bakış açımı, moral ve motivasyonumu tamamıyla değiştiren en değerli varlığım kızım Zeynep Yavuz'a teşekkür ederim.

1160576 numaralı proje kapsamında 1001 – Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı ile maddi destek sağlayan TÜBİTAK'a teşekkür ederim.

İÇİNDEKİLER

Sayfa

ÖZET	vi
SUMMARY	vii
TEŞEKKÜR.....	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ.....	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEMLER	9
3.1. Yöntem-1 ve Yöntem-2 Veriseti Oluşturma.....	9
3.1.1. Kısa Dalga Kızılötesi Işık (SWIR-Short Wave Infrared)	12
3.1.2. Yakın Görünür Kızılötesi Işık Dalgası (VNIR - Visible Light Infrared Wave). 13	13
3.1.3. Görülebilir Işık Dalgaları	14
3.1.4. Deneysel Çalışmalarda Kullanılan Ölçüm Yöntemleri.....	15
3.2. Yöntem1: İmge ve Öznitelik Uzayında Füzyon	16
3.2.1. İmge Uzayında Füzyon Yöntemleri	16
3.2.2. The Brovey Dönüşümü (BT) Tabanlı Füzyon	17
3.2.3. Yoğunluk-Ton-Doygunluk (IHS) Tabanlı Füzyon	18
3.2.4. Ayrık Kosinüs Dönüşümü (DCT) Tabanlı Füzyon	19
3.2.5. Konvolüsyonel Sinir Ağı (CNN) Tabanlı Füzyon	20
3.2.6. Ortak Vektör Yaklaşımı (CVA) Tabanlı Füzyon:.....	20
3.2.7. Öznitelik (Feature) Uzayında Füzyon Yöntemleri.....	25
3.2.8. Çalışma#1’de Kullanılan Öznitelik Füzyonu Yöntemleri:	26
3.3. Yöntem 2: Derin ve Sığ CNN Yöntemlerinin Karşılaştırılması	29
3.3.1 Sığ Model (Shallow)	29
3.3.2 Derin Model (VGG16).....	30
4. DENEYSEL ÇALIŞMALAR VE PERFORMANS DEĞERLENDİRME.....	32

İÇİNDEKİLER (devam)

4.1 Yöntem-1 Bulguları	32
4.2 Yöntem-2 Bulguları	34
5. BULGULAR VE TARTIŞMA.....	37
6. SONUÇ VE ÖNERİLER.....	41
KAYNAKLAR DİZİNİ.....	43

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
1.1. Dünya buğday verileri.	3
1.2. Türkiye buğday verileri.	4
3.1. Görüntü kayıt ortamı	10
3.2. Laboratuvar Deney Ortamı	12
3.3. Çalışmada kullanılmış olan SWIR Kamera	13
3.4. Çalışmada kullanılmış olan VNIR Kamera	14
3.5. Çalışmada kullanılmış olan Halojen Ampuller	15
3.6. RGB, SWIR ve VNIR kanalları üzerinden füzyon işleminin görselleştirmesi.	16
3.7. BT + RGB + SWIR ve BT + RGB + VNIR	18
3.8. IHS + RGB + SWIR ve IHS + RGB + VNIR	18
3.9. DCT + RGB + SWIR, DCT + RGB + VNIR ve DCT + SWIR + VNIR	19
3.10. CNN + RGB + SWIR, CNN + RGB + VNIR ve CNN+ SWIR + VNIR	20
3.11. CVA+ RGB +SWIR, CVA + RGB +VNIR ve CVA+ SWIR + VNIR	21
3.12. Farklı yöntemler ile görüntü etki alanı üzerinde füzyon örneği	23
3.13. Buğday çekirdekleri için VGG16 kullanarak öznetelik çıkarma aşaması.....	25
3.14. Önerilen tahmin sistemi.....	26
3.15. Önerilen Shallow Model.....	29
4.1. VGG16 hassasiyeti	35
4.2. Sığ modein 100 epoch başına performansı.....	36

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
2.1. Gıda üzerine yapılan farklı dalga boylarındaki çalışmalar	8
3.1. Kullanılan 40 buğday çeşidinin listesi.....	10
3.2. VNIR görüntü örnekleri.....	11
3.3. İki sınıflı bir örnekte karışıklık matrisi.....	15
3.4. İmge uzayında füzyonun 40 sınıf üzerindeki görüntü örnekleri.....	24
3.5. Önerilen Shallow modelin katmanları	30
3.6. Hiper-parametreler setini	30
4.1. İmge alanı üzerinde yapılan füzyonun 40 sınıf için genel performansı.	32
4.2. Öznitelik uzayında yapılan füzyonun 40 sınıf için genel performansı.	33
4.3. Shallow ve VGG16 modellerimizin diğer çalışmalarla performans karşılaştırması. ...	34
5.1. 2016'dan beri önerilen bazı yöntemlerle performans karşılaştırması.	37

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
ANN	Artificial Neural Networks (Yapay Sinir Ağları)
BT	The Brovey Transform
CNN	Convolutional Neural Network
CVA	Common Vector Approach
DCT	Discrete Cosine Transformation
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
HOG	Histogram of Gradient
HSI	Hiperspectral Imaging (Hiperpektral Görüntüleme)
IHS	Intensity-Hue-Saturation
K-NN	K-Nearest Neighbors (K-En Yakın Komşuları)
LBP	Local Binary Patterns
LSN	Local Similarity Numbers
LSP	Local Similarity Patterns
NIR	Near Infrared (Yakın Kızılötesi)
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
RGB	Red/Green/Blue
SRC	Sparse Representation-Based Classification (Seyrek Temsil Temelli Sınıflandırma)
SVM	Support Vector Machine
SVSKLPP	Supervised Virtual Sample Kernel Locality Preserving Projection
SWIR	Supervised Virtual Sample Kernel Locality Preserving Projection,
TN	True Negative (Gerçek Negatif)
TP	True Positive (Gerçek Pozitif)
VGG	Visual Geometry Group
VNIR	Visible Near Infrared (Yakın Görünür Kızılötesi)
YSA	Yapay Sinir Ağları

1. GİRİŞ VE AMAÇ

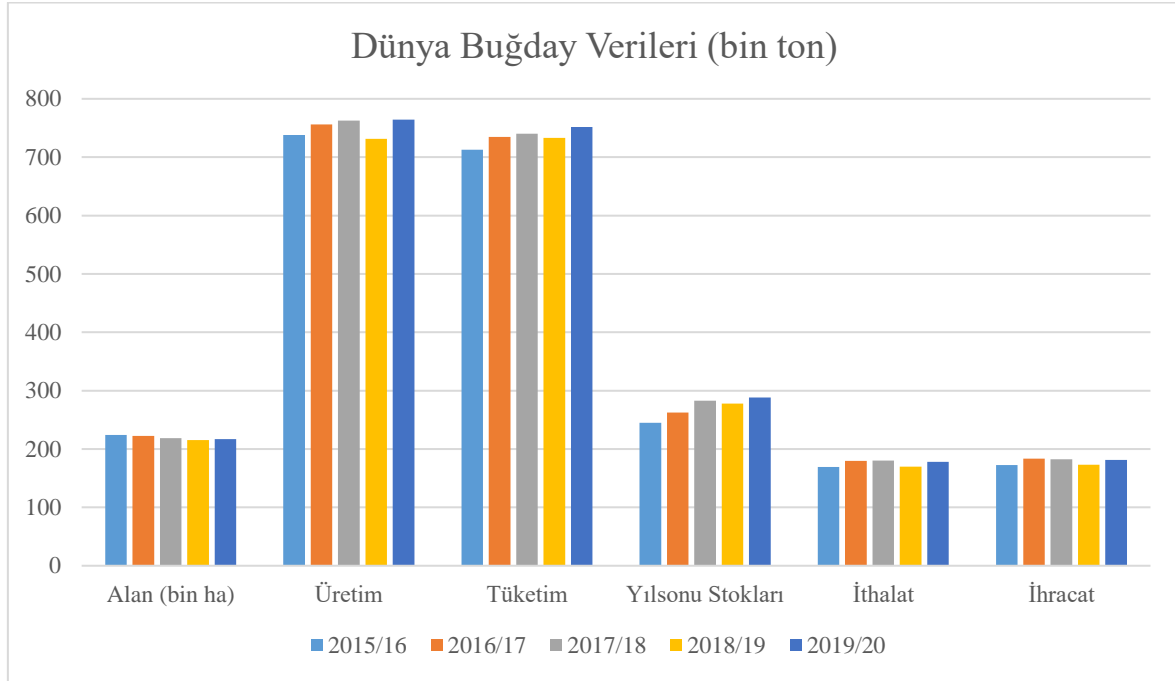
Ülkemizde ve dünyada insanların gıda ihtiyaçlarının karşılanması açısından oldukça büyük bir öneme sahip olan buğday, başta unlu mamuller olmak üzere birçok gıda ürünü ve diğer endüstriyel alanlarda kullanılmaktadır. Buğday insan beslenmesinde kullanılan kültür bitkileri arasında ekiliş ve üretim bakımından dünyada ilk sırada yer almaktadır. Nüfusun artması ile birlikte buğday tüketimi her geçen gün artmakta ve sonuç olarak buğday üretimi de giderek daha fazla önem kazanmaya başlamaktadır. Buğday üretim miktarı yüksek bir ülke olan Türkiye, dünyadaki un ihracatçısı ülkelerin başında yer almaktadır. Bu nedenle buğday üretiminin sağlanması ve devamlılığı ülkemiz ve dünya ekonomisi açısından oldukça büyük bir öneme sahiptir. Gerek dünya ve gerekse ülkemizde herhangi bir nedenle buğday üretiminin azalması, undan yapılan gıda maddelerinin fiyatlarını yükselterek tüm insanları doğrudan veya dolaylı olarak etkilemektedir. Bu nedenle bir ülke için buğday üretimi açısından yeterli olmak ve stoklarında yeterince buğday ürünü bulundurmamak stratejik bir önem arz etmektedir. Bununla ilişkili olarak, tarımsal üretimde verimi artırmak için tescilli, yani genetik potansiyeli yüksek çeşitlerin sertifikalı tohumluklarının kullanımının yaygınlaştırılması da oldukça önem arz eden bir konudur. Buğday üretiminde verimliliğinin artırılması, kalitenin yükseltilmesi ve maliyetinin düşürülmesi için buğday tohumluğu ülkemiz için en öncelikli girdi ve teknolojik unsurdur. Diğer taraftan, ülkemizde buğday üretiminin en önemli sorunlarından biri de kalite sorunudur. Kaliteli bir üretim için sadece bitkinin sahip olduğu kalite düzeyi sorunu çözmekte; aynı zamanda tohumluk değerine olumsuz etki yapan aynı veya başka tür/çeşit tohumlarının karışması, süne ve kımlı zararı, yabancı madde, iyi temizlememe ve tasnif ve uygunsuz depolama şartları gibi faktörler tohumluk kalitesini düşürmektedir. Tohumlukların değerini düşüren en önemli faktörlerden birisi de çeşit karışıklığıdır. Çeşitlerin tanınması ve teşhis edilmesi, çeşitlerin kimliğini belirleyen yöntemlerin hayata geçirilmesi, depolama, borsa işlemlerinin doğru yürütülmesi vakit, emek ve para kaybının önüne geçilmesi gibi birçok açıdan önem arz etmektedir. Bu nedenle üretilen buğdayın kalitesinin belirlenmesi için çeşitlerin hızlı ve doğru tanınmasını sağlayan tekniklerin geliştirilmesi gerekmektedir. Buğday alım-satımı sırasında fiyat tespiti, cinsinin tanımı ve kalitesinin kararı buğday uzmanlarının görüşü ile olmaktadır. Bu durum ise insan faktörüne bağımlılığı artırmaktadır. Farklı uzmanlar farklı fiyat verebilmektedir. İlerleyen teknoloji ile birlikte daha objektif kalite yöntemleri denenmeye başlamış ve buğday

çeşitlendirmelerini de bu yeni teknolojilere göre uygun olarak belirleme önerilerini beraberinde getirmiştir. Bu proje ile görünür ışık, yakın kızıl ötesi ve kısa dalga kızıl ötesi görüntüleme tekniğindeki dalga boylarından elde edilecek bilgilerin görüntü işleme teknikleri kullanarak işlenmesi, öznelik çıkarma ve sınıflandırıcı yöntemleri içerecek bir yazılım geliştirilmesi ve bu sensörlerle beraber tümleşik bir sistemin tasarlanması hedeflenmektedir. Geliştirilecek sistem ile birlikte fiyat tespiti, buğday cinsinin tanımlanması için insan faktörü ortadan kaldırılacak ve daha objektif karar verme sağlanabilecektir.

Tarımsal kaynakların sürdürülebilir şekilde yönetimi, gelişen teknoloji ile ürünler üzerindeki fenolojik gözlemlerin tespitini ve çeşit tanımlama yöntemlerinin bütünleşmesini gerektirmektedir. Son zamanlarda, tarımsal endüstride makine öğrenme ve derin öğrenme sistemlerinin kullanımı oldukça yüksek bir artış göstermiştir. Buğdayın kalite düzeyinin ve çeşitlerinin belirlenmesi de üretim kalitesini doğrudan etkilemektedir. Çeşitlerin tanınması ve sınıflandırmanın doğru yapılabilmesi için yeni teknolojik sistemler geliştirilmektedir. Bu sayede insan gücü en aza indirilerek, zamandan ve emekten tasarruf sağlanmaktadır. Böylece bir taraftan daha adil bir sistem oluşturulurken diğer taraftan da ekonomik iyileşmeler getirmektedir. Uygun taksonomi tespiti ile buğday çeşidinin kalitesi ve maliyeti belirlenirken, aynı zamanda uzmanların doğru kararlar vermesine yardımcı olması sağlanmaktadır. Bu çalışma kapsamında geliştirilen buğday tanıma sistemi sadece etkili ve zahmetsiz bir tanımlama çerçevesi olarak hizmet etmekle kalmaz, aynı zamanda derin öğrenme araçlarının buğday çeşidini yeterince ayırt edebileceğini kanıtlamaktadır. Önerilen sistem, ekonomik büyümeyi iyileştirmenin yanı sıra, buğday endüstrisinde daha fazla verimlilik ve daha yüksek üretkenliğe yol açan iş gücünü azaltmak için önemli bir ilerleme sağlayacaktır.

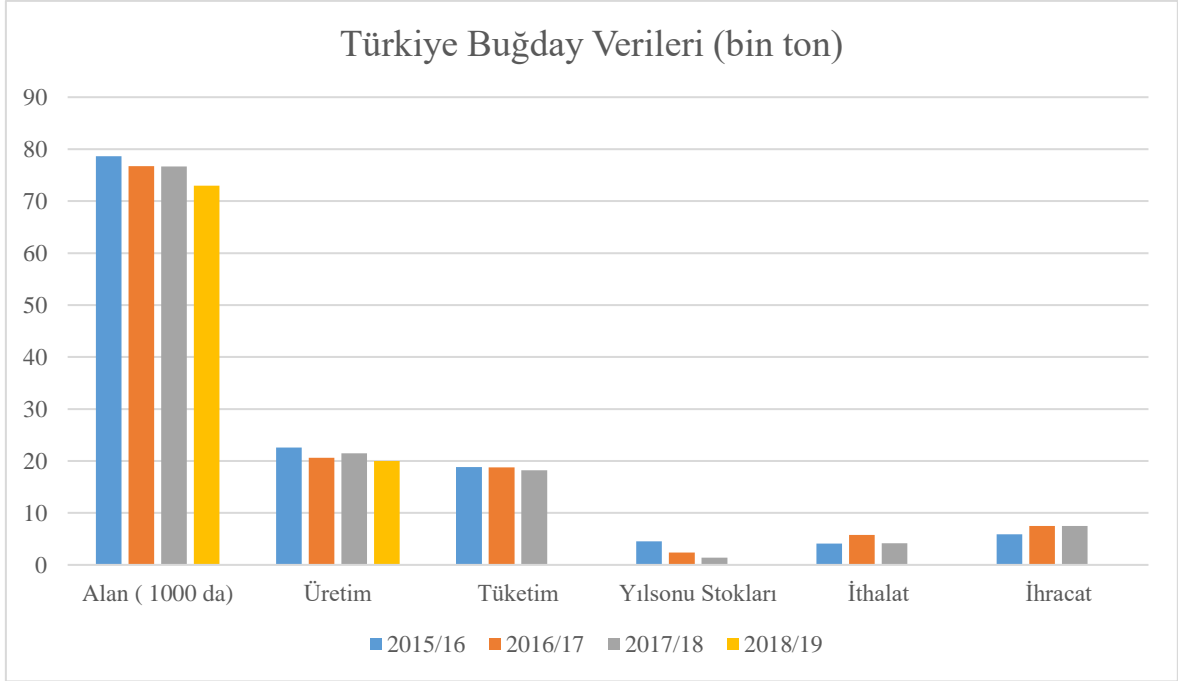
Buğday çeşitlerinin tespiti ve doğru sınıflandırma üretimin kalitesini de doğrudan etkileyen önemli bir faktördür. Kaliteye gereken önem verildiği takdirde ekonomik kayıpların azaltılması sağlanacaktır. Ayrıca, çeşitlerin tanınması ve sınıflandırmanın doğru yapılabilmesi için yeni teknolojik sistemler geliştirilmektedir. Bu nedenle buğday çeşitlerini doğru bir şekilde belirleyebilmek adına güvenilir sınıflandırma yöntemleri geliştirilmelidir. Nitekim geçmiş yıllardan günümüze kadar çeşitlerin tanınması, hastalıklı buğdayların tespiti

ve doğru sınıflandırma adına birçok çalışmanın yapılmış olması konunun önemini vurgulaması açısından önem arz etmektedir.



Şekil 1.1. Dünya buğday verileri.

Şekil 1.1’de genel olarak dünyadaki buğday ile alakalı üretim/tüketim, ithalat/ihracat ve ekilmiş alanlar üzerine bazı önemli bilgiler sunulmuştur (Tarım ve Orman Bakanlığı, 2020). Beş yıllık veriler göz önüne alındığında; 2018/19 yılında buğday üretim miktarının tüketim miktarına göre düşük kaldığı gözlenmektedir. Ayrıca diğer yıllara göre, 1000/Hektar – Metre Kare (bin ha) oranıyla, 2018/19 yılında daha az miktarda buğday alanı işlenmektedir. Yine en yüksek buğday üretiminin 2019/2020 yılında ve en düşük buğday tüketiminin 2015/2016 yılında olduğu gözlenmektedir.



Şekil 1.2. Türkiye buğday verileri.

Tarım ve Orman Bakanlığı'nın (2020) verilerine göre Türkiye buğday ekim alanı 2019/20 üretim sezonu itibarıyla dünya buğday ekim alanının %3,3'üne sahiptir. Yine 2018/19 üretim sezonu itibarıyla Türkiye buğday ekim alanı 72,9 milyondur (Şekil 1.2). Buğday üretim miktarı göz önüne alındığında son dört yılda değişimin az olduğu gözlenmektedir. Fakat ekili alanlar dikkate alındığında yıllara göre düşme olduğu anlaşılmaktadır (Şekil 1.2).

2. LİTERATÜR ARAŞTIRMASI

Geçmiş yıllardan günümüze kadar hastalıklı buğdayları tespit edebilmek kaliteyi yükseltmek ve doğru sınıflandırmak adına birçok çalışmalar yapılmıştır. Bu çalışmalar geleneksel ve modern yöntemler olarak ikiye ayrılabilir. Geleneksel yöntemlerde daha çok öznitelik mühendisliği yapılırken, modern yöntemlerde ise derin öğrenme tabanlı yaklaşımlar sergilenmektedir.

Görüntü özniteliklere göre hasarlı soya fasulyesi tohumlarının ayırt edilmesi ve ortadan kaldırılması üzerine yapılan bir çalışmada (Liu vd., 2015), beş çeşit hasarlı soya fasulyesi çekirdeği üzerinde çalışılmıştır. Hasar görmüş soya fasulyesi tohumunu tanımlamak ve ortadan kaldırmak için görüntü işleme teknolojilerinin içeriğine dayalı olarak bir sinir ağı ve otomatik mekanik kontrol uygulanarak gerçekleştirilmiştir. Karakteristik parametreleri giriş katmanı olarak çıkarmak için 14 girişli nöron, 6 çıkış nodu ve 12 gizli katmanı olan bir nöral ağ sınıflandırma modeli kurulmuştur. Sınıflandırma modeli için her birinden 200'er adet test örneği alınarak verilen tanıma oranları: normal taneler %100, küflenmiş taneler %99, böceklerden zarar gören taneler %98,5, cilt hasarlı taneler %94,5, kırık taneler % 97,5 ve kısmen arızalı taneler % 94 olarak tespit edilmiştir.

Bir diğer çalışmada (Pourreza vd., 2012) ise görüntü işleme ve dokusal analiz ile dokuz İran buğday tohumu çeşitleri üzerinden görüntü işleme tekniklerinden yararlanarak ayırma işlemi yapılmıştır. Gri matrisin en iyi özelliğini kullanmak ve LBP (Local Binary Patterns), LSP (Local Similarity Patterns) ve LSN (Local Similarity Numbers) matrislerinden çıkarılan öznitelikler kullanıldığı için önceki çalışmalarıyla kıyaslandığında sınıflandırma doğruluğunu arttığı gözlemlenmiştir. Buğday tanelerine ait dokusal öznitelikler, buğday çeşitliliği ayırt etme amacı için tercih edildiğinde başarılı sonuçlar ürettiği gözlenmiştir. Tüm öznitelik gruplarında en iyi 50 özniteliği kullanılarak %98,15 doğruluk elde edilmiştir.

Başka bir çalışmada (Kuo vd., 2016) ise görüntü işleme ve seyrek temsil temelli sınıflandırma (Sparse Representation-Based Classification) (SRC) kullanılarak tahribatsız 30 çeşit pirinç tanelerinin ayrılması amaçlanmıştır. 30 pirinç çeşidinin yüksek çözünürlüklü

tane görüntülerini elde etmek için bir mikroskop sistemi geliştirilmiş olup pirinç tanelerinin morfolojik, dokusal ve renk öznelikleri görüntü işleme araçları kullanılarak ölçülmüştür. Kullanılan görüntüleme sisteminin avantajı olarak yüksek çözünürlüğe sahip pirinç tanelerinin ince detaylarının gözlemlenmesini sağlamıştır. Tanelerin çeşitlerini tahmin etmek için bu bahsedilen seyrek temsil temelli sınıflandırma yöntemi (SRC) geliştirilmiş olup sınıflandırma sonucunda %89,1 doğruluk ve %7,0 standart sapma elde edilmiştir.

Farklı sayıda yer fıstığının doğru sınıflandırılması için geliştirilen yöntemler incelenecek olursa farklı fiyatlandırmalara sahip yer fıstıkları tek fıstık, iki fıstık ve üç yer fıstığı olmak üzere üç kategoriye ayrılmaktadır (Li vd., 2018b). Fıstık sayısının sınıflandırılmasını tahmin etmek için Support Vector Machine (SVM) ile birleştirilmiş üç farklı öznelik kullanılmıştır. Yerfıstığı görüntülerinin öznelikleri, konvolüsyon nöral ağı, Histogram of Gradient (HOG) ve Hu değişmez moment de dâhil olmak üzere üç farklı yöntemle çıkartılmış ve daha sonra SVM tarafından bu görüntüler sınıflandırılmıştır. Sonuçlar mercek altına alındığında; en boy oranı + SVM algoritmasının doğruluk oranı, HOG + SVM algoritması, Hu değişmez moment + SVM algoritması sırasıyla %96,72, %81,97 ve %81,97 olmuştur. Elde edilen yüksek tanıma değerleri yerfıstığı sınıflandırmasının endüstride otonom olarak gerçekleştirilmesinde önemli bir rol oynamıştır. Çalışmanın eksik yanları incelendiğinde; yerfıstığı görüntülerinin elde edilmesi zor olduğundan, yer fıstığı görüntü veri tabanı oluşturmak karmaşık olmaktadır. İki yer fıstığı üç yer fıstığından nispeten küçüktür ve ikisini birbirinden ayırmak zorlaşmaktadır. Görüntünün benzerliğini geliştirmek ve yer fıstığını tüm yönleriyle göstermek için daha fazla çaba gösterilmesi gerekmektedir. Geliştirilen uygulamanın performansını artırmak için daha fazla fıstık görüntüsü kullanılmasında fayda vardır.

Bir diğer farklı yaklaşım olarak, mısırın genetik araştırması ve modern mısır yetiştiriciliğinde önem arz eden mısır haploid tohumlarının tanımlanması üzerine çalışmalar gerçekleştirilmiştir (Yu vd., 2018). Haploid tohumların hibrit tohumlardan ayırt edilmesi için yakın kızıl ötesi spektroskopi teknolojisinden faydalanılmıştır. Çünkü yakın kızıl ötesi spektroskopi tabanlı görüntüleme sistemi tahribatsız hızlı ve düşük maliyetli olma avantajlarına sahiptir. Haploid mısır tohumları tanımlaması için doğrusal olmayan analitik (SVSKLPP – Supervised Virtual Sample Kernel Locality Preserving Projection) bir yöntem

önerilmiştir. Bu yöntem (SVSKLPP) kullanarak ortalama doğruluk oranları sırasıyla %97,1, %98,8 ve %95,4 olarak bulunmuştur.

Bu tez çalışması ile benzerlik gösteren başka bir çalışmada, buğday tanelerinin otomatik ve hızlı bir şekilde sınıflandırılmasını sağlayacak bir yöntem geliştirilmiş ve DSIFT öznelikleri SVM sınıflandırıcısına gönderilerek yüksek tanıma performansı yakalanmıştır (Olgun vd., 2016). Geliştirilen buğday tanıma sisteminin yüksek doğruluk oranı (%88,33) ile başarılı olduğu kaydedilmiştir. Yine son zamanlarda yapılan başka bir çalışmada üzüm yapraklarının örüntü tanıma yaklaşımları ile sınıflandırılması amaçlanmıştır (Champ vd., 2016). Bu amaç doğrultusunda iki farklı üzüm yaprakları kullanılarak veri tabanı oluşturulmuştur. Bunlardan birincisi, tohum bankasında tutulan 95 çeşide ait 2071 adet gevşek pirinç çekirdeği koleksiyonudur. İkincisi ise tarlalarda ve bağcılıkta kullanılan en yaygın 34 çeşide ait 2037 adet üzüm yaprağı koleksiyonudur. İki veri kümesi üzerinde, en son teknolojinin en etkili iki sınıflama tekniklerinden olan Konvolüsyonel Sinir Ağları (Convolutional Neural Networks- CNN) ve diğeri Fisher Vektör Tabanlı Diskriminant modelleri kullanılarak bir deneysel çalışma gerçekleştirilmiştir. Deneyler sonucunda üzüm çeşitlerini yapraklarından ayırt etmek oldukça sorun olsa da CNN yönteminin bu gibi problemler için en iyi sonucu verdiği görülmektedir.

Yukarıdaki çalışmaların dışında, farklı çekirdek boyutu kullanılarak hiperspektral görüntüleri tanımak için üç evrişim katmanı ve iki normalizasyon katmanına sahip sığ bir CNN mimarisi geliştirilmiştir (Yu vd., 2017). Teknik olarak, HxWxN şeklindeki hiperspektral bir görüntü CNN modeline iletilir, daha sonra 1xC tahmin çıktıları son aktivasyon fonksiyonu, yani Softmax tarafından üretilir. N hiperspektral görüntüdeki kanalların sayısını ifade ederken, C sınıfların sayısını belirtir. 16 sınıf için, sistemin performansı %85,24'lük genel doğruluk oranıyla rapor edilmiştir. Ayrıca, bitki türlerini tanımak için CNN metodolojisi de geliştirilmiştir. Başka bir çalışmada, 10.413 renkli görüntünün üzerine bir CNN modeli oluşturulmuş (Dyrmann ve ark., 2016) ve CNN performansının 22 yabancı ot ve bitki türünü %86,2 hassasiyetle ayırt edebildiği rapor edilmiştir. Bilgisayar destekli kalite denetim sistemleri hakkında uluslararası alanda farklı çalışmalar yapılmıştır. Bu çalışmalardan hiperspektral kamera ile gıda üzerine yapılan yapay zekâ ve makine öğrenmesi tabanlı çalışmalar Çizelge 2.1'de sunulmuştur.

Çizelge 2.1. Gıda üzerine yapılan farklı dalga boylarındaki çalışmalar

Gıda	Analiz	Dalga Boyu (nm)	Sınıflandırıcı	Referans
Çilek	Sıklık ve çözünabilir katı içeriğinin ölçümü	650-1000, 450-650	Aşamalı Çoklu Doğrusal Regresyon	(Nagata vd., 2005), (Nagata vd., 2004)
Elma	Berelenmeleri Algılama	400-1000	Temel Bileşen Analizi	(Xing vd., 2005)
Elma	Berelenmeleri Algılama	900-1700	Temel Bileşen Analizi ve Maksimum Gürültü Fraksiyonu	(Lu, 2003)
Elma	Dışkı bulaşması algılama	450-851	Temel Bileşen Analizi	(Kim vd., 2002)
Elma	Dışkı bulaşması algılama	452-729 ve 465-900	Bant oranı	(Lefcourt vd., 2006)
Elma	Yüzey kusurları ve yabancı maddelerin tespiti	430-900	Asimetrik ikinci fark yöntemi	(Mehl vd., 2004)
Elma	Acı çekirdeklerin ölçümü	900-1700	Ayrılcı kısmi en küçük kareler regresyonu	(Nicolai vd., 2006)
Çilek	pH değeri algılama	400-1000	Kısmi en küçük kareler regresyonu ve çoklu lineer regresyonu	(ElMasry vd. 2007)
Şeftali	Sertlik ölçümü	500-1000	Çoklu lineer regresyon	(Lu ve Peng, 2005)
Mantar	Donma hasarı	400-1000	Temel Bileşen Analizi, Linear ayrılcı analizi	(Gowen vd. 2009)
Salatalık	Berelenmeleri Algılama	900-1700	Temel Bileşen Analizi	(Ariana vd., 2006)
Salatalık	Soğutma zararların	450-950	Temel Bileşen Analizi, Lineer	(Cheng vd., 2004)
Mısır	Nem ve yağ içeriği tahmini	750-1090	Kısmi en küçük kareler regresyonu	(Cogdill vd., 2004)
Mısır	Sertliğine göre mısır sınıflandırma	1000-2498	Kısmi en küçük kareler regresyonu	(Williams vd., 2009)
Buğday	8 farklı buğday çeşidini sınıflandırma	960-1700	Yapay sinir ağları	(Mahesh vd., 2009)
Buğday	13 farklı buğday çeşidini sınıflandırma	960-1700	Yapay sinir ağları	(Choudhary vd., 2009)
Buğday	5 farklı buğday çeşidini sınıflandırma	960-1700	Lineer ayrılcı analizi	(Mahesh vd., 2011)
Buğday	Protein tahmini ile sınıflandırma	----	Kimyasal yöntemler	(Koenig vd., 2015)
Buğday	Mantar bozulmasına uğramış buğdayların sınıflandırılması	1000-1600	Destek vektör makineleri	(Zhang vd., 2007)
Buğday	Böcek hasar tespiti	1000-1600	Lineer ayrılcı analizi	(Singh vd., 2009 ve 2010a)
Buğday	Titresineği-hasarlı buğday tanelerinin tanınması	700-1100	İstatistiksel analiz	(Singh vd., 2010b)
Buğday	Buğday içindeki yabancı madde	1000-1600	Yapay sinir ağları, en yakın komşuluk, Bayes	(Radhika ve Sardeshmukh 2014)

3. MATERYAL VE YÖNTEMLER

Tez çalışmasında iki farklı yöntem geliştirilmiştir;

Yöntem 1: İmge ve Öznitelik uzayında füzyon yapılarak buğday tanınması.

Yöntem 2: Derin ve Sığ CNN yapılarının buğday tanınması üzerine karşılaştırılması.

3.1. Yöntem-1 ve Yöntem-2 Veri seti Oluşturma

Günümüzde tarım ürünlerinin çeşit ve kalitesinin kontrolünde, bilgisayar destekli denetim sistemleri geliştirilmektedir. Bu sistemler, genel olarak buğday yığını ve diğer tanelere ait sayısal görüntülerin bilgisayar ortamına aktarılarak görüntü işleme teknikleri ve derin öğrenme prensipleri yardımıyla taneler üzerinde tanımlayıcı bilgilerin elde edilmesi ve bu bilgilerin sınıflandırılması prensibine dayanmaktadır. Bu sistemler hızlı, tutarlı, objektif olmaları, kayıtları saklama ve arşivleme özelliklerinden dolayı diğerlerine göre çok daha avantajlıdır.


Bu çalışmada hiperspektral görüntülemeler için 3 farklı kamera kullanılmıştır. Bunlar SWIR, VNIR ve RGB kameralardır.

Veri setleri, Görünür ışık (RGB, dalga boyu: 400nm ila 800nm), Görünür Yakın Kızılötesi (VNIR, dalga boyu: 400nm ila 1100nm) ve Kısa Dalga Kızılötesi (SWIR, dalga boyu: 900nm ila 1700nm) dâhil olmak üzere üç görüntüleme sisteminden oluşmaktadır.

Her sınıf 200 örnek içerir v 40 sınıftan 8000 örnek elde edilmiştir. Kontrollü bir ortamda, 8000 görüntü için 40 buğday sınıfından üç veri kümesi oluşturulmuştur. Her bir görüntü 640 x 512 boyutundadır. Bir kümenin 6400'ü eğitim simülasyonu için ayrılmıştır ve kalan 1600 de test simülasyonu için ayrılmıştır. Ayrıca aşağıdaki Çizelge 3.1'de 40 sınıfın her bir ismi mevcuttur.

Hiperspektral görüntüleme veya spektroskopisi, dijital görüntüleme ve spektroskopinin gücünü birleştirir. Hiperspektral bir kamera, bir görüntüdeki her bir piksel için, çok sayıda (tipik olarak birkaç ile yüzlerce) bitişik spektral bant için ışık yoğunluğunu alır. Böylece görüntüdeki her piksel sürekli bir spektrum (parlaklık veya yansıma) içerir ve sahnede bulunan nesnelere büyük hassasiyet ve ayrıntılarla karakterize etmek için kullanılabilir. VNIR kamera ile elde edilen 40 farklı buğday çeşidinin örnek görüntüleri Çizelge 3.2’de gösterilmiştir.

Kullanılan görüntü yakalama sistemini göstermek için, sanallaştırılmış model Şekil 3.1’de verilmiştir.



Şekil 3.1. Görüntü kayıt ortamı

Çizelge 3.1. Kullanılan 40 buğday çeşidinin listesi.

Ahmetaga	Altay2000	Atay85	Aytin	Bayraktar2000	Bezostaja	Cesit1252	Cetiner
Dagdas	Ekiz	Energo	Es26	Esperia	Flamura85	Gelibolu	Gerek79
Harmankaya	Izgi	KateA1	Kirac	Kirgiz	Kunduru	Mesut	Michelangelo
Midas	Mufitbey	Nacibey	Pehlivan	Porsuk	Reis	Renan	Selimiye
Sonmez	Soyer	Sultan95	Suzen	Tosunbey	Yelken	Yildiz	Yunus

Çizelge 3.2. VNIR görüntü örnekleri.



Şekil 3.2’deki deney ortamında görüldüğü gibi, spesifik kameralar, SWIR, VNIR, RGB için mesafelerin 50, 30 ve 20 cm olduğu buğday numunelerinin tepesine uygun şekilde yerleştirilir. SWIR, VNIR ve RGB için odaklama alanı sırasıyla 21x29 cm², 9x7 cm² ve 9x7 cm² olarak işaretlenmiştir. Ortamdaki ani ışık değişimlerini engellemek için, iki adet 100 W halojen ışık kaynağı, SWIR kameranın sol tarafında ve RGB kameranın sağ tarafında konumlanarak, bu da düzgün bir ışık dağılımı sağlayarak kullanılır.



Şekil 3.2. Laboratuvar Deney Ortamı

3.1.1. Kısa Dalga Kızılötesi Işık (SWIR-Short Wave Infrared)

Günümüzün modern teknolojisine sahip SWIR, 900-1700nm aralığında çalışan 3. Nesil bir termal görüntüleme sistemidir. Sisli havada sürücü görüş geliştirme, endüstriyel kontrol (plastik, boya ve cam), bilimsel görüntüleme, trafik kontrolü, güvenlik ve gözetim, hava platformları, drone ve İHA tabanlı görüntüleme gibi uygulama alanlarında kullanılmaktadır.

Bu çalışmada Mikro Tasarım’ a ait MT-CL-MicroCAM-SW641 (MikroTasarım, 2018) (<http://www.mikro-tasarim.com.tr>) SWIR Kamera kullanılmıştır. Deneysel çalışmada kullanılan SWIR kamera görselleri Şekil 3.3’te gösterilmiştir.




Şekil 3.3. Çalışmada kullanılmış olan SWIR Kamera

3.1.2. Yakın Görünür Kızılötesi Işık Dalgası (VNIR- Visible Light Infrared Wave)

VNIR çoklu spektral görüntü kameraları yaklaşık 400nm-1100nm NIR spektral bandında çalışmakta olup, uzaktan algılama ve görüntüleme spektroskopisinde SWIR kameralara benzer şekilde geniş uygulama alanlarına sahiptir. VNIR çok spektrumlu görüntü kameraları uzaktan algılama, görüntüleme spektroskopisi ve robotik tarımda geniş bir uygulama alanına sahiptir. Kameraya dahil olan özel lens ve NIR ışınlarıyla, insan gözünün ürünün yüzeyinde tanıyamayacağı değişiklikleri ve ayrıntıları tespit etmek mümkündür.

Bu çalışmada ise Şekil 3.4'te de gösterildiği gibi Mikro Tasarıma ait MT-CL-CAM-VNIR6415 (MikroTasarım, 2018) (<http://www.mikro-tasarim.com.tr>) VNIR kamera kullanılmıştır.



Şekil 3.4. Çalışmada kullanılmış olan VNIR Kamera

3.1.3. Görülebilir Işık Dalgaları

Görülebilir ışık, insan gözünün görebildiği 380nm – 760nm arasındaki elektromanyetik dalgalarıdır. Beyaz ışık demeti prizmadan geçtiğinde farklı dalga boyları farklı açılarla kırılarak ayrılırlar ve renkleri oluştururlar. Bu dalgaları gökkuşağının renkleri olarak görmekteyiz.

Her renk farklı bir dalga boyuna sahiptir. Tüm renklerden oluşan bölgede en küçük dalga boyuna sahip olan mor (380nm) iken en büyük dalga boyuna sahip olan (700nm) kırmızıdır. Tüm renk dalgalarının bir araya gelmesiyle beyaz renk oluşmaktadır.

Işık ampulleri ise, bir diğer görünür ışık dalgası kaynağıdır. Bu çalışmanın laboratuvar aşamasında görünür ışık dalgaları için RGB kamera kullanılmıştır. Ani ışık etkilerini dengelemek ve homojen dağılmış aydınlatma sağlamak için, sağ ve sol tarafta iki adet 100 W halojen ışık kaynağı kullanılmıştır. Sistem Şekil 3.5'te gösterilen iki adet 100-W halojen ışık ampuller tarafından aydınlatılmaktadır.



Şekil 3.5. Çalışmada kullanılmış olan Halojen Ampuller

3.1.4. Deneysel Çalışmalarda Kullanılan Ölçüm Yöntemleri

Tasarlanan sistemin başarısı, doğru sınıfa atanan örneklerin ve yanlış sınıfa atanan örneklerin nicelikleri ile ölçülmektedir. Testler neticesinde elde edilen sonuçların başarımları bilgileri karışıklık matrisi ile belirtilmektedir. Karışıklık matrisinde yer alan satırlar test kümesindeki örneklere ait gerçek sayıları ifade etmektedir. Sütunlar ise modelin tahminlenmesini göstermektedir. İki sınıflı bir örnekte karışıklık matrisi Çizelge 3.3'te gösterildiği gibi olmaktadır. (Pietikäinen, 2010)

Çizelge 3.3: İki sınıflı bir örnekte karışıklık matrisi

		Öngörülen Sınıf	
		Sınıf A	Sınıf B
Doğru Sınıf	Sınıf A	Gerçek Pozitif (True Positive, TP)	Yanlış Pozitif (False Positive, FP)
	Sınıf B	Yanlış Negatif (False Negative, FN)	Gerçek Negatif (True Negative, TN)

Başarıyı ölçmek için kullanılan en yaygın ve en temel yöntem, modelin doğruluğudur. Doğru kategorilere ayrılmış olan örnek sayısının (TP+TN), toplam örnek sayısına olan (TP+TN+FN+FP) oranıdır. Hata oranı ise bu değer 1'e tamlayanıdır. Diğer bir ifadeyle yanlış sınıflandırılmış örnek sayısının (FP+FN), toplam örnek sayısına (TP+TN+FN+FP) oranıdır (Denklem 3.1 ve 3.2).

$$Doğruluk = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.1)$$


$$Hata Oranı = \frac{FP + FN}{TP + FP + FN + TN} \quad (3.2)$$

Kesinlik, sınıfı A olarak tahminlenmiş Gerçek Pozitif sayısının, sınıfı A olarak tahminlenmiş tüm örnek sayısına oranı $TP / (TP + FP)$ duyarlılık ise doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranı, $TP / (TP + FN)$, olmak üzere f ölçütü aşağıdaki gibi tanımlanır. (Denklem 3.3) F-ölçütü, kesinlik ve duyarlılığın harmonik ortalamasıdır.

$$f - ölçütü = \frac{2 * Duyarlilik * Kesinlik}{Duyarlilik + Kesinlik} \quad (3.3)$$

3.2. Yöntem1: İmge ve Öznitelik Uzayında Füzyon

3.2.1. İmge Uzayında Füzyon Yöntemleri



Şekil 3.6. RGB, SWIR ve VNIR kanalları üzerinden füzyon işleminin görselleştirilmesi.

Görüntü üzerinde yapılan füzyon işleminde, RGB, VNIR ve SWIR kanallarında belirtilen anlamlı yerel bilgiler önceden tahmin edilen olasılık oranları ile birleştirilmek üzere işlenmektedir. Temel amaç, buğday taneleri sınıflandırmak için ayırt edici bir görüntü oluşturmaktır. Şekil 3.6, farklı görüntü kanallarının füzyonu ile ilgili gösterimi ifade etmektedir. Çalışmada, bu görüntü füzyon metodolojilerinin buğday çekirdeklerinin sınıflandırılması üzerindeki performansları incelenmiştir.

Çalışma#1’de Kullanılan İmge (Image) Füzyonu Yöntemleri:


1. Brovey Dönüşümü (The Brovey Transform, BT)
2. Yoğunluk-Ton-Doygunluk (Intensity-Hue-Saturation, IHS)
3. Ayrık Kosinüs Dönüşümü (Discrete Cosine Transformation, DCT)
4. Konvolüsyonel Sinir Ağı (Convolutional Neural Network, CNN)
5. Ortak Vektör Yaklaşımı (Common Vector Approach, CVA)

Füzyon işlemi, Brovey Dönüşümü (BT) Tabanlı Füzyon, Yoğunluk-Ton-Doygunluk (IHS) Tabanlı Füzyon, Ayrık Kosinüs Dönüşümü (DCT) Tabanlı Füzyon, Konvolüsyonel Sinir Ağı (CNN) Tabanlı Füzyon, Ortak Vektör Yaklaşımı (CVA) Tabanlı Füzyon olmak üzere beş farklı popüler yöntem üzerinde simüle edilmiştir.

3.2.2. The Brovey Dönüşümü (BT) Tabanlı Füzyon

Brovey dönüşümü (Gillespie vd., 1987) birden fazla sensörden gelen verileri, Red, Green, Blue kanalları, hedef imgeyle birleştirmek amacıyla tek bir kanal elde etmek için kullanılan bir yöntemdir. Amaç, RGB imgesi için kullanılan çoklu-imgeyi normalize etmek ve imgeye yoğunluk ya da parlaklık bileşenini eklemek için sonucu istenen herhangi bir veri ile çarpmaktır. Elimizdeki RGB ve VNIR(v) görüntülerinin füzyonu için Brovey dönüşümü yöntemini kullanarak gerçekleştirmek için aşağıdaki formül uygulanmıştır ve Şekil 3.7’de Brovey dönüşümü tabanlı füzyon ile elde edilen görüntü örnekleri gösterilmiştir:

$$\mathbf{RN} \cong \frac{\mathbf{R}}{\mathbf{R} + \mathbf{G} + \mathbf{B}} \mathbf{V}, \quad \mathbf{GN} \cong \frac{\mathbf{G}}{\mathbf{R} + \mathbf{G} + \mathbf{B}} \mathbf{V}, \quad \mathbf{BN} \cong \frac{\mathbf{B}}{\mathbf{R} + \mathbf{G} + \mathbf{B}} \mathbf{V} \quad (3.4)$$




Şekil 3.7. BT + RGB + SWIR ve BT + RGB + VNIR

3.2.3. Yoğunluk-Ton-Doygunluk (IHS) Tabanlı Füzyon

Geleneksel ve basit füzyon yöntemi olan IHS, yüksek uzamsal çözünürlük olan tek bant ve düşük uzamsal çözünürlük olan multispektral uzaktan algılanan imgelerini birleştirmek amacıyla kullanılmıştır (Schetselaar, 1998). IHS yönteminde imge füzyonu için multispektral imgenin R, G ve B bantları Ton (Hue), yoğunluk (Intensity), doygunluk (Saturation) bantlarına dönüştürülür ve yüksek çözünürlüklü yoğunluk bileşeni H, I ve S kanallarına uygulanarak füzyon işlemi gerçekleştirilir. Şekil 3.8'de IHS tabanlı füzyon ile elde edilen görüntü örnekleri gösterilmiştir.

$$\begin{aligned}
 V_1 &\cong \frac{R+G-2B}{\sqrt{6}}, & V_2 &\cong \frac{R-G}{\sqrt{2}} \\
 RN &\cong V + \frac{V_1}{\sqrt{6}} + \frac{V_2}{\sqrt{2}}, & GN &\cong V + \frac{V_1}{\sqrt{6}} - \frac{V_2}{\sqrt{2}}, & BN &\cong V - 2 \frac{V_1}{\sqrt{6}}
 \end{aligned} \tag{3.5}$$




Şekil 3.8. IHS + RGB + SWIR ve IHS + RGB + VNIR


3.2.4. Ayrık Kosinüs Dönüşümü (DCT) Tabanlı Füzyon

Bu yöntemde sayısal görüntünün frekans uzayı gösterimi elde edilir. Elimizde RGB imgeden elde edilmiş Grey (G) ve VNIR(V) imgeleri olduğunu varsayalım. DCT tabanlı füzyon işleminde imgelerden elde edilen parçalar öncelikle DCT transformasyondan (Abdollahzadeh vd., 2016; Haghghat vd., 2010) geçirilmektedir. Daha sonra DCT uzayında parçaların varyans bilgileri dikkate alınarak füzyon işlemi yapılmakta ve tekrardan DCT transformasyonun tersi alınarak füzyon işlemi tamamlanmaktadır. Elimize G ve V imgelerinden alınmış, 8x8'lik ve P1 ve P2 parçaları olsun ve füzyon edilmiş parça P olduğunu varsayalım. Bu durumda öncelikle DCT transformasyon uygulanarak P1 ve P2 oluşturulmaktadır. Denklemdeki gibi füzyon stratejisi uygulanarak daha anlamlı ve zengin parça olan P kazanılmaktadır. En son işlem olarak P parçası üzerinden DCT transformasyonun tersi alınıp füzyon sonlandırılmaktadır. Şekil 3.9'da DCT tabanlı füzyon ile elde edilen görüntü örnekleri gösterilmiştir.


$$\begin{aligned}
 \mathbf{P}'_1 &\cong \frac{\mathbf{P}'_1}{\mathbf{8}}, & \mathbf{P}'_2 &\cong \frac{\mathbf{P}'_2}{\mathbf{8}} \\
 var_1 &\cong \text{variance of } \mathbf{P}'_1 & & \\
 var_2 &\cong \text{variance of } \mathbf{P}'_2 & & \\
 \mathbf{P} &\cong \begin{cases} \mathbf{P}'_2 & \text{if } var_1 < var_2 \\ \mathbf{P}'_1 & \text{otherwise} \end{cases}
 \end{aligned} \tag{3.6}$$



DCT + RGB + SWIR



DCT + RGB + VNIR




DCT + SWIR + VNIR

Şekil 3.9. DCT + RGB + SWIR, DCT + RGB + VNIR ve DCT + SWIR + VNIR

3.2.5. Konvolüsyonel Sinir Ağı (CNN) Tabanlı Füzyon

CNN tabanlı füzyon stratejisi (Li vd., 2018a) önceden ImageNet imgeleri üzerinden eğitilmiş olan VGG19 filtreleri ile imgeleri öznitelik uzayına dönüştürmesine dayanmaktadır. VGG19'daki 1. konvolüsyon katmanından elde edilen çıktı ReLU ile aktive edilmekte ve bu şekilde imgeler öznitelik uzayına dönüştürülmektedir. Öznitelik uzayındaki çıktılar normalize edilerek kaynak ve hedef imgeden ne kadar oranda alınacağına dair olasılık oranlarının tespit edilmesine dayanmaktadır. Varsayalım elimizde Grey (G) ve VNIR (V) imgeleri olsun, P füzyon imgesini elde etmek için CNN tabanlı füzyon aşağıdaki formül ile gerçekleştirilmektedir. Şekil 3.10'da CNN tabanlı füzyon ile elde edilen görüntü örnekleri gösterilmiştir.


$$\begin{aligned}
 \mathbf{V}' &\cong \text{CNN features of } \mathbf{V} \\
 \mathbf{G}' &\cong \text{CNN features of } \mathbf{G} \\
 \mathbf{p}_v &\cong \frac{\mathbf{V}}{\mathbf{V} + \mathbf{G}}, \quad \mathbf{p}_g \cong \frac{\mathbf{G}}{\mathbf{V} + \mathbf{G}} \\
 \mathbf{P} &\cong \mathbf{p}_v \mathbf{V} + \mathbf{p}_g \mathbf{G}
 \end{aligned} \tag{3.7}$$



Şekil 3.10. CNN + RGB + SWIR, CNN + RGB + VNIR ve CNN+ SWIR + VNIR

3.2.6. Ortak Vektör Yaklaşımı (CVA) Tabanlı Füzyon:

Farklı görüntülerin kaynaşması için yeni bir yaklaşım olarak, buğday çekirdeklerinin tanımlanması amacıyla CVA'nın (Gulmezoglu vd., 2001) potansiyel özelliklerini nicelleştirilmiştir. Bu amaçla, CVA kavramı, Kırmızı, Yeşil, Mavi, VNIR ve SWIR kanallarından farklı kombinasyonlar oluşturarak tek ve etkili bir kanal elde etmek için çalışmıştır. CVA algoritması, teorik altyapıya sahip Temel Bileşen Analizine (PCA) benzemektedir, ancak farkı en büyük veya en küçük özdeğerlere karşılık gelen özvektör kullanılarak elde edilmektedir. Şekil 3.11'de CVA tabanlı füzyon ile elde edilen görüntü örnekleri gösterilmiştir.



Şekil 3.11. CVA+ RGB +SWIR, CVA + RGB +VNIR ve CVA+ SWIR + VNIR

PCA'nın aksine, sıfıra yaklaşan, en küçük özdeğerlerle eşleşen özvektörler veri projeksiyonu için kullanılmıştır. Özvektörlere ayrıştırma dışında, Gram-Schmidt ortogonalizasyon yöntemi vektörlerin ortasını bulmak için kullanılabilir. Farz edelim, Kırmızı, Yeşil, Mavi, SWIR ve VNIR renk bileşenleri $h \times w$ formatında verilmiş olsun. Matris şeklinde verilen imgeler daha sonra $(\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \mathbf{v}_4, \mathbf{v}_5)$ şeklinde vektör formatına dönüştürülür. Vektörlerin ortalaması, $\boldsymbol{\mu}$, verilen her vektörden sırayla çıkartılmaktadır. Bu şekilde sıfır ortalamalı vektör seti $(\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3, \mathbf{a}_4, \mathbf{a}_5)$ elde edilmektedir.

CVA yöntemine göre, bir vektör ortak ve fark vektörlerin bileşeni, $\mathbf{a}_i = \mathbf{a}_{\text{com}} + \mathbf{a}_{\text{diff}}$, şeklinde ifade edilebilir. Diğer bir deyişle vektörler arasında uzaysal bilgi fark ve ortak

vektörlerle ifade edilmektedir. CVA yönteminin genel prensipleri aşağıdaki kurallarla anlatılmaktadır.

- İlk adım olarak, fark alt uzayı, kalanlardan bir referans vektör çıkartılarak elde edilmelidir. Bu çalışma için \mathbf{a}_1 referans olarak alınır. Daha sonra işlenen verilere ait fark vektörleri aşağıdaki gibi elde edilir:

$$\mathbf{d}_{i-1} = \mathbf{a}_i - \mathbf{a}_1 \quad i = 2, 3, 4, 5 \quad (3.8)$$

- Toplamda 4 farklı fark vektörü oluşturduktan sonra, verilen renk kanallarına ait fark alt uzayı (\mathbf{DS}) aşağıdaki denklem ile gösterilir.

$$\mathbf{DS}_i = \{\mathbf{d}_1, \mathbf{d}_2, \mathbf{d}_3, \mathbf{d}_4\} \quad (3.9)$$

- Elde edilen fark alt uzayı, Gram-Schmidt dikleştirme prosedürü uygulanarak dikleştirilir. Nihayetinde, işlenen kanalların fark alt uzayını kapsayan dört ortonormal temel vektör, $(\mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3, \mathbf{z}_4)$, ortaya çıkmaktadır.

- Ortak vektöre, \mathbf{a}_{com} , ulaşmak için referans vektör sırayla dört ortonormal temel vektör üzerine yansıtılır ve aşağıdaki eşitlikte ile temsil edilen fark vektörü, \mathbf{a}_{diff} , oluşturulur. Referans vektöründen çıkarıldığında, ortak vektör, denklemde gösterildiği gibi modelleneyecektir.

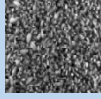
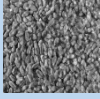
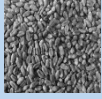
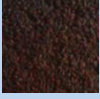
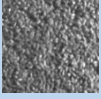
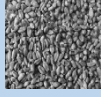
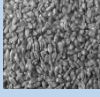
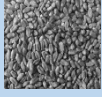
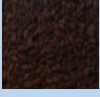
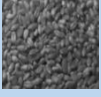
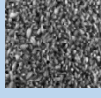
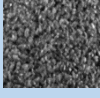
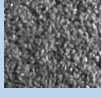


$$\mathbf{a}_{\text{diff}} = \langle \mathbf{a}_1, \mathbf{z}_1 \rangle + \langle \mathbf{a}_1, \mathbf{z}_2 \rangle + \langle \mathbf{a}_1, \mathbf{z}_3 \rangle + \langle \mathbf{a}_1, \mathbf{z}_4 \rangle \quad (3.10)$$

$$\begin{aligned} \mathbf{a}_{\text{com}} &= \mathbf{a}_1 - \mathbf{a}_{\text{diff}} \\ \mathbf{a}_{\text{com}} &= \mathbf{a}_{\text{com}} + \boldsymbol{\mu} \end{aligned} \quad (3.11)$$

Elde edilen ortak vektör, \mathbf{a}_{com} , anlamlı kaynaştırılmış görüntüyü gösterir ve paylaşılan bilgileri kanallar üzerinde saklar. Denklemde gösterildiği gibi, ortalama vektör,


μ , ortak vektör ile birleştirilir. Bu kanıttan hareketle, buğday çekirdeklerinin tanımlanması için ortak vektör kullanılmıştır.

RGB, VNIR ve SWIR değerleri farklı aralıkta olduğundan dolayı, homojen dağılım elde etmek amacıyla bunlar normalize edilmiştir. Normalizasyon ile kötü koşullanmış öğrenme sürecinin etkisini en aza indirmekteyiz. Şekil 3.12, farklı birleştirme yöntemleri ile ilgili örneklerin görsel temsilini göstermektedir. Çizelge 3.4'te ise 40 farklı çeşit buğday üzerindeki füzyon görüntü örnekleri verilmiştir.

	DCT	CNN	CVA	BT	IHS
RGB +SWIR					
RGB +VNIR					
SWIR +VNIR					

Şekil 3.12. Farklı yöntemler ile görüntü etki alanı üzerinde füzyon örneği

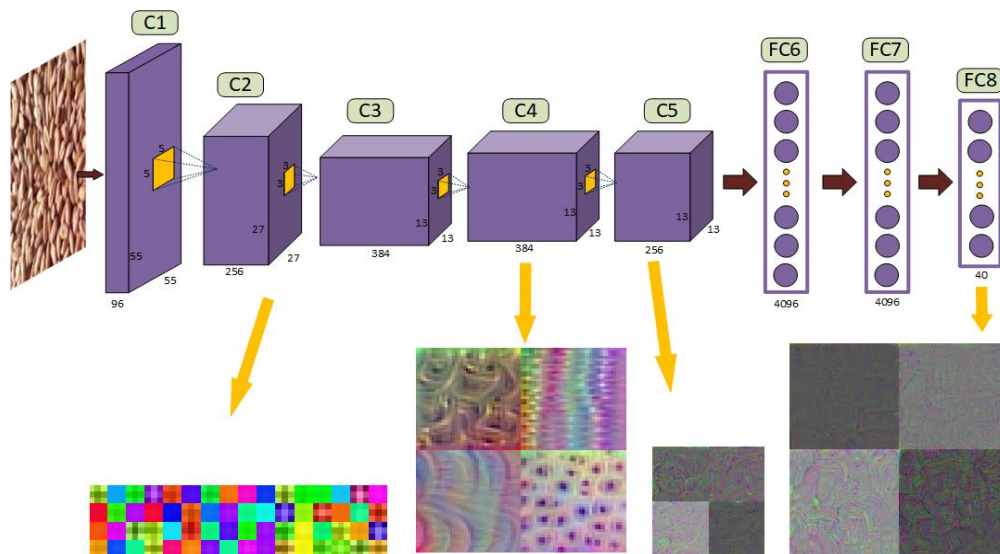
Çizelge 3.4. İmge uzayında füzyonun 40 sınıf üzerindeki görüntü örnekleri.



3.2.7. Öznitelik (Feature) Uzayında Füzyon Yöntemleri

Buğday çeşitlerinin ayırt edilmesi için yukarıda belirtilen görüntü füzyon yöntemlerinin yanı sıra, aralarındaki ilişkiyi ön plana alarak özniteliklerin kullanımı da desteklenmiştir.


Öznitelikleri çıkarmak için Visual Geometry Group (VGG16) (Simonyan ve Zisserman, 2014) olarak adlandırılan özel bir CNN mimarisi, RGB, SWIR ve VNIR buğday çekirdekleri için aynı anda eğitilmiştir. Her veri kümesi için, eğitim örneklerine dayalı bir VGG16 modeli oluşturulmuştur ve öznitelik vektörü, her test numunesi için VGG16'nın Tam Bağlı Katmanından (Fully Connected Layer) (FC6) türetilmiştir. Şekil 3.13, görselleştirilmiş evrişimli özniteliklere sahip VGG16 mimarisini sunmaktadır.



Şekil 3.13. Buğday çekirdekleri için VGG16 kullanarak öznitelik çıkarma aşaması

Füzyon işlemi için Eğitim/Test örneklerine karşılık gelen öznitelikler üzerinde Sezgisel, CVA, Vector of Locally Aggregated Descriptors (VLAD) (Jégou vd., 2010) ve Fisher Vector Encoding (FISHER) (Perronnin ve Dance, 2007; Perronnin vd., 2010) yaklaşımları gerçekleştirilmiştir. Kodlama metodolojisinden ilham alınarak VLAD ve FISHER, boyut küçültme prosedürü olarak kullanılırken Heuristic ve CVA, öznitelik uzayında bilgi füzyonu için kullanılmıştır.

Veri kümesi daha önce de belirtildiği gibi 8000 örnekten oluşmaktadır, bunların 6400 örneği eğitim için geri kalan 1600 örnek ise test için kullanılmıştır. VGG16 modelinin ağırlıkları, ham görüntü veri boyutunu azaltmak ve anlamlı özniteliklerle değiştirmek için eğitilmiştir. Her veri kümesi (RGB, SWIR ve VNIR) için bir model oluşturulduktan sonra, öznitelik vektörü, 4096×1 , her test örneği için çıkarılmıştır. Böylece, eğitim (4096×6400) ve test (4096×1600) verileri hazırlanmıştır. Performans ölçümü aşamasında, fine-tuning stratejisi kullanıldı. Bu amaç için VGG16'nın son başı olan Softmax Sınıflandırıcı çıkartılarak, yerine Destek Vektör Makinesi (SVM) sınıflandırıcısı gömülmüştür. Sonunda, sistem test aşamasında 1600 etiketi tahmin etmektedir. Tahmin performansını artırmak için yukarıda belirtilen öznitelik kodlama / füzyon yöntemleri tercih edilmiştir.



Şekil 3.14. Önerilen tahmin sistemi.

Tahmin mekanizması hakkında genel bir fikir vermek adına, sistem Şekil 3.14 ile özetlenmiştir. SVM'nin farklı görüntüleme sistemlerinde yüksek performans vermesi nedeniyle Softmax sınıflandırıcı yerine SVM tercih edilmiştir. Performansın değerlendirilmesi için LIBSVM kütüphanesi (Chang vd., 2011), buğday tanımlaması için entegre edilerek SVM'nin kapasitesini değerlendirmek için gerçekleştirmiştir. Maliyet parametresi (c) 10 olan olarak belirlenmiştir. Linear çekirdekli SVM kullanılmıştır.

3.2.8. Çalışma#1'de Kullanılan Öznitelik Füzyonu Yöntemleri:

CVA: Her örnek için, CVA kavramı, RGB (4096×1), SWIR (4096×1) ve VNIR (4096×1) üzerinden elde edilen öznitelik kümesinin birleştirilmesi için yapılmıştır. Nihayetinde, sistemi değerlendirmek için 4096×1 boyutunda bir vektör hesaplanmıştır.

Heuristic (Sezgisel): Özniteliklerin birleştirilmesi için kullanıcı tarafından önceden tanımlanmış bazı olasılık oranlarının kullanıldığı bir yöntemdir. Olasılık katsayıları, her bir görüntüleme sisteminin performansının ayrı ayrı analiz edilmesiyle belirlenmiştir. Verimlilik ne kadar iyi olursa, katsayısı da o kadar yüksek olur. Çizelge 4.2'deki doğruluk puanlarını referans olarak alarak, füzyon katsayıları RGB, SWIR ve VNIR için sırasıyla 0,2, 0,4 ve 0,4 olarak belirlenmiştir.

FISHER: RGB (4096x1), SWIR (4096x1) ve VNIR' den (4096x1) döndürülen ve 4096x3 olarak elde edilen özniteliği kodlamak adına her örnek için FISHER yöntemi kullanılmıştır. Kodlama için tüm öznitelik kümelerinden 1500 öznitelik örneği rastgele seçilmiş ve 1500x4096 öznitelikli matris oluşturulmuştur. Bu amaçla, tüm kategorilerden 500 öznitelik örneği seçilmiştir. Genel bir kodlama uygulaması olan, 1500 örnekle ilişkili ortalama ve kovaryans değerleri kodlama işleminden önce hesaplanmıştır. Daha sonra, birleştirilmiş bir öznitelik vektörü (4096x1), ortalama ve kovaryans değerleri üzerinde elde edilmiştir.

VLAD: VLAD yöntemi, kodlama yoluyla öznitelik boyut küçültme için kullanılan FISHER'a benzemektedir. Benzer şekilde, 1500x4096 öznitelikli matrisi rastgele oluşturulmuştur ve bir küme, k aracı kümelenmesine göre belirlenmiştir. Daha sonra KD-ağaç modeli, her bir öznitelik setinin indekslenmesi açısından elde edilen kümelenmeye dayanarak inşa edilmiştir. Sonunda, VLAD 4096x1'lik birleşmiş bir öznitelik vektörü verir.

VNIR + VLAD: VNIR özniteliğini, kodlanmış VLAD öznitelikleri ile birlikte birleştirmek anlamına gelmektedir. Bu nedenle, bir test örneği, 8192x1 boyutunda bir öznitelik vektörüyle temsil edilmiştir. Toplamda, 1600x8192'den oluşan bir test matrisi bu şekilde oluşturulmuştur.

VNIR + FISHER: Benzer bir şekilde VNIR öznitelikleri, kodlanmış FISHER öznitelikleri ile birleştirilmiştir. Yine, bir test örneği 8192x1 biçimindedir.

Genişletilmiş öznitelik vektörünün performansını analiz etmek için,

VNIR + VLAD + FISHER: VNIR, VLAD ve FISHER öznitelikleri bir araya getirilmiştir ve test öznitelik vektörü 12288x1 olmuştur.

RGB + SWIR: RGB ve SWIR özniteliklerinin birleştirilmesi anlamına gelmektedir. Test öznitelik vektörü 8192x1 şeklindedir.

RGB + VNIR: Yine, RGB ve VNIR öznitelikleri, 8192x1 şeklinde bir test öznitelik vektörü elde etmek için birleştirilmiştir.

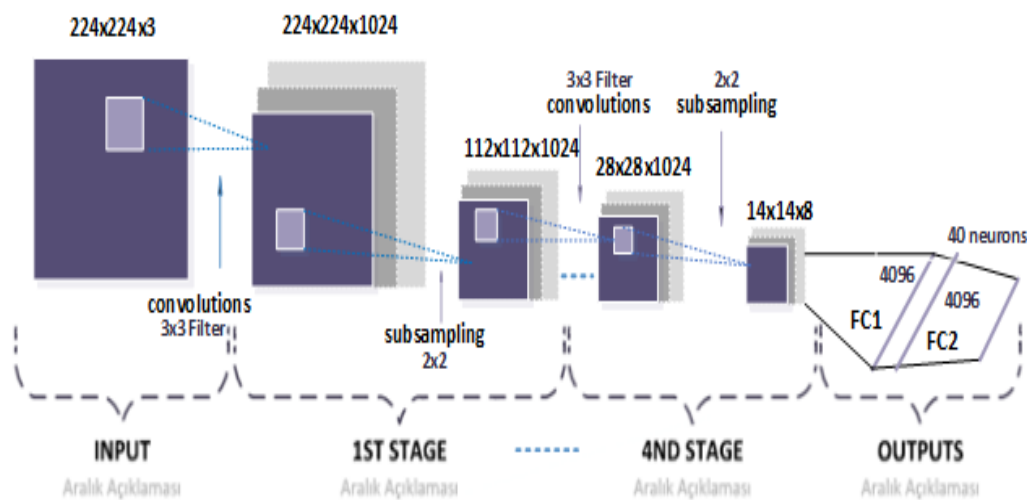
SWIR + VNIR: SWIR ve VNIR özniteliklerini birbirine bağlar. Benzer şekilde, test öznitelik vektörü 8192x1 şeklindedir.

RGB + SWIR + VNIR: Yine, öznitelik vektörünün boyutu, RGB, SWIR ve VNIR'den döndürülen tüm öznitelikleri birleştirerek genişlemiştir. Test öznitelik vektörü 12288x1 şeklindedir.

3.3. Yöntem 2: Derin ve Sığ CNN Yöntemlerinin Karşılaştırılması

3.3.1 Sığ Model

Yapılan ek çalışma kapsamında VGG16'ya ek olarak, daha az bellek kaynağı tüketmek, hesaplama süresini iyileştirmek ve daha verimli ve etkili bir CNN modeli oluşturmak amacıyla katman olarak daha yüzeysel bir CNN mimarisi de geliştirilmiştir.



Şekil 3.15. Önerilen Shallow Model

Yapının daha fazla katmanlı olması girdi verileri ve öğrenilen özellikler arasındaki etkileşimlerin daha kolay tasarlanmasına imkân vermesine rağmen, daha derin bir mimari için hesaplama ve doğruluk arasındaki değişimlerden kaynaklanan bazı sınırlamalara tabi tutulur. Bu faktörleri göz önünde bulundurarak, başarılı bir tanımlama doğruluğu elde etmek ve kaynakların verimli bir şekilde tahsis edilmesini sağlamak amacıyla yüzeysel (hafif) bir CNN üzerinde denemeler yapılmıştır. Bu çalışmada deney ortamı aynı tutularak yalnızca VNIR kamera ile elde edilen görüntülerden oluşan veri seti kullanılmıştır. Şekil 3.15 önerilen (Shallow) Sığ modeli gösterirken, Çizelge 3.4 önerilen (Shallow) Sığ modelin katmanlarını ve filtre boyutlarını göstermektedir.

Çizelge 3.3. Önerilen Shallow modelin katmanları

Katmanlar	# Filtre Sayısı	Filtre Boyutu
Conv1	1024	(3,3)
Conv2	1024	(3,3)
Max-Pool	-	(2,2)
Conv3	1024	(3,3)
Max-Pool	-	(2,2)
Conv4	1024	(3,3)
Max-Pool	-	(2,2)
Conv5	1024	(3,3)
Max-Pool	-	(2,2)
FC1	4096	-
Dropout	50%	
FC2	4096	-
Dropout	50%	

Yine, Çizelge 3.5, hem derin hem de yüzeysel CNN modelleri için (batch-size) eğitilen örnek sayısı, öğrenme oranı, epoch (devir) sayısı olan hiper-parametreler setini göstermektedir.

Çizelge 3.4. Hiper-parametreler seti

	<i>Shallow</i>	<i>VGG16</i>
<i>Learning Rate</i>	<i>1e-3</i>	<i>1e-4</i>
<i>Batch Size</i>	<i>16</i>	<i>16</i>
<i>Epochs</i>	<i>400</i>	<i>200</i>
<i>Optimizer</i>	<i>SGDM</i>	<i>SGDM</i>

3.3.2 Derin Model (VGG16)

ImageNet veri setinin bir milyondan fazla görüntüsü üzerinde önceden eğitilmiş bir model olan VGG16, 16 konvolüsyon katmanının yanı sıra 2 tam bağlantılı katmanın bulunduğu bir CNN mimarisidir. Teknik olarak, 1000 nesne kategorisinde yüksek

performans gösteren VGG16 Max Pooling, Fully Connected Katmanı, Relu Katmanı, Dropout Katmanı ve Softmax sınıflandırıcı dahil toplam 41 katmandan oluşmaktadır. VGG16, işlenmiş bir görüntüyü tamamen bağlı katmanlar (Fully Connected Layer) ile temsil edilen ayırt edici özniteliklere dönüştürür.

4. DENEYSEL ÇALIŞMALAR VE PERFORMANS DEĞERLENDİRME

4.1 Yöntem-1 Bulguları

Eğitim işlemi yeterli sayıda veri test edilmiştir. Elde edilen doğruluk skorları 1600'den test imgesi üzerinden elde edilmiş ve Çizelge 4.1'de sunulmaktadır. Burada sayısal sonuçlar 40 sınıf için değerlendirilen ortalama doğruluk yüzdesini göstermektedir. Bu denemeden elde edilen değerleri karşılaştırırken, en iyi doğruluk oranı (%98,19) BT metodu ile RGB-VNIR üzerinden elde edilmiştir. RGB-VNIR kanallarında uygulanan füzyonda BT ve IHS yöntemleri, DCT ve CNN'e kıyasla önemli ölçüde daha iyi performans gösterdiği açıktır.

Genel değerlendirmede, RGB-VNIR görüntüleme sistemlerinin kullanılması, görüntü alanı üzerinden füzyon yapılırken daha uygun olduğunu göstermektedir.

Çizelge 4.1. İmge alanı üzerinde yapılan füzyonun 40 sınıf için genel performansı.

Metot	RGB-SWIR (%)	RGB-VNIR (%)	SWIR-VNIR (%)
BT	90.88	98.19	-
IHS	83.13	96.13	-
DCT	73.88	90.00	74.38
CNN	84.88	89.69	80.75
CVA	92.63	92.56	78.81

İkinci bir deney olarak, öznelik uzayında füzyon prosedürünü gerçekleştirerek buğday tanımlama performansı değerlendirilmiştir. Çizelge 4.2'de verilen oranlar, füzyonun öznelik uzayın üzerindeki başarısını göstermektedir. Eğitim amaçlı 6400 örnek ve test amaçlı 1600 örnek kullanılmıştı. Sınıflandırma için sağlam bir alternatif, verimli bir füzyon mekanizması geliştirmek amaçlanan bu çalışmada, Heuristic, CVA, VLAD ve FISHER olmak üzere dört farklı yöntem, füzyon için seçildi ve buna göre sisteme gömüldü. Bu amaç doğrultusunda öncelikle RGB, SWIR ve VNIR performansı, füzyon metodolojinin yokluğunda incelenmiş ve performansları değerlendirilmiştir. En iyi performansı %99,38 ile VNIR' dan elde ettik. Daha sonra Çizelge 4.2'de gösterilen füzyon yöntemleri

gerçekleştirilmiştir. Bu sonuçlar göz önüne alındığında, bu füzyon yöntemlerinin öznelik uzayında iyi performans gösterdiği ve buğday çekirdeklerini yüksek oranda ayırt ettiği açıktır. En yüksek doğruluk oranını ise RGB + SWIR, RGB + VNIR, RGB + SWIR + VNIR, FISHER, VLAD ve Sezgisel (Heuristic) özneliklerinin birleştirildiği füzyon sonucunda %100,00 olarak belirlenmiştir. Bu da 1600 örnek arasında tam doğru sınıflandırılmış test örneği olduğunu göstermektedir. Ayrıca, CVA füzyonun performansı %99,63 doğruluk puanı ile ilk 3'te yer almaktadır. Kodlama metodolojisinden hareketle VLAD ve FISHER, boyut küçültme işlemi olarak kullanılırken Heuristic ve CVA, öznelik alanı üzerinden bilgi harmanlama için kullanılmıştır. Diğer füzyon stratejileri, %99,50'den daha zayıf bir performans sergilemekle birlikte, buğday çekirdeği sınıflandırması için yalnızca RGB (%99,31) ve SWIR (%95,31) görüntüleme sistemini kullanmaktan yine de daha verimlidirler.

Çizelge 4.2. Öznelik uzayında yapılan füzyonun 40 sınıf için genel performansı.

Öznelik/Füzyon	Doğruluk (%)
VNIR	99.38
RGB	99.31
SWIR	95.31
CVA	99.63
Heuristic	100.00
RGB+SWIR	100.00
RGB+VNIR	100.00
SWIR+VNIR	99.88
RGB+SWIR+VNIR	100.00
FISHER	100.00
VLAD	100.00
VNIR+VLAD	99.38
VNIR+FISHER	99.38
VNIR+VLAD+FISHER	99.38

Deney sonuçlarına bakıldığında, imge uzayında RGB-VNIR kanalları ve öznitelik alanında ise RGB + VNIR, RGB + SWIR ve RGB + VNIR + SWIR öznitelikleri birleştirildiğinde umut verici sonuçlar gözlenmiştir. Deneysel sonuçlar sonucunda önerilen füzyon yöntemlerinin 1600 test örneğinin üzerinde tahminler yapılması durumunda imge uzayında %98,19, öznitelik uzayında ise %100,00 doğruluk oranlarına ulaşılmıştır. Elde edilen iyi sonuçlar, önerilen füzyon yöntemlerinin tarım endüstrisinde buğday türlerinin doğru tahmin edilmesi için uygun olacağını açıkça göstermektedir.

4.2 Yöntem-2 Bulguları

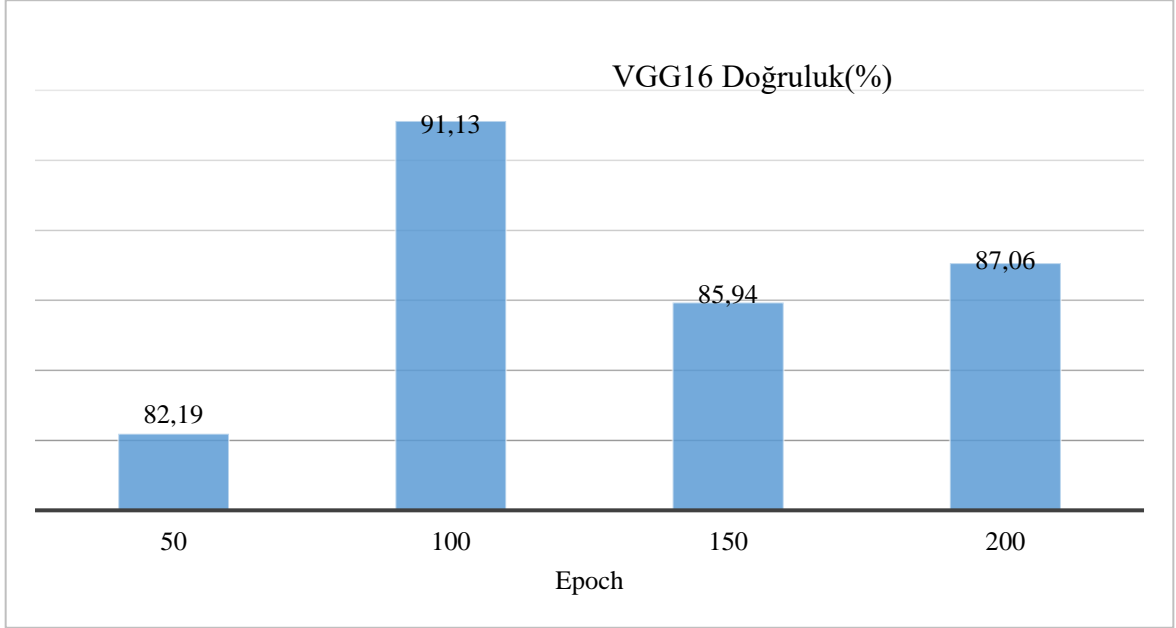
Buğday etiketi tahmini üzerinden derin öğrenme araçlarının sağlamlığını değerlendirmek için performansı doğruluk ve F-ölçütü skorlarına göre değerlendirilmiştir. Geliştirilen Shallow (sığ) ve VGG16 performansı karşılaştırılmıştır.

Çizelge 4.3. Shallow ve VGG16 modellerimizin diğer çalışmalarla performans karşılaştırması.

Metot İsmi	Doğruluk (%)
Shallow (önerilen)	80,13
VGG16 (önerilen)	91,13
(Singh vd., 2009)	99,30
(González-Martín vd., 2014)	76,00
(Grinblat vd., 2016)	97,00


Çizelge 4.3, önerilen yöntemler ve literatürdeki benzer çalışmaların sonuçlarını göstermektedir. Her yöntem farklı sınıflandırma görevi ve tamamen farklı veri kümeleri için geliştirildiğinden, sonuçlarımızı bu yöntemlerin sonuçlarıyla karşılaştırmak adil değildir. Bununla birlikte, buğday tanımlama konusundaki potansiyel kapasiteleri hakkında genel bir fikir verilebilir. Verilen sonuçlarda (Grinblat vd., 2016)'nin sonucu önerilen yöntemlerimizden daha yüksek olmasına rağmen, gerçekte VGG16, buğday çeşidi sayısı karşılaştırıldığında çok daha etkilidir. Önerilen çalışma 40 buğday çeşidinde yapılırken, diğer çalışmada (Grinblat vd., 2016) sadece 3 tane fasulye türü göz önüne almaktadır.

Softmax sınıflandırıcı durumunda, test numunelerinin etiketleri CNN modellerinden döndürülen aktivasyon olasılığı ile belirlenmiştir. Toplam 1600 test örneği vardır. Çizelge 4.3'te elde edilen sonuçları inceledikten sonra, Sığ model ile yanlış sınıflandırılmış 318 örnek olduğu söylenebilir. Diğer taraftan, VGG16 %0,09 hata oranıyla sahip buğday etiketlerini doğru bir şekilde belirleyebilir, bu da 142 yanlış sınıflandırılmış buğday örneğini göstermektedir.



Şekil 4.1. VGG16 hassasiyeti

VGG16'nın performansı, Şekil 4.1'de, 50 epoch başına tahmin sonuçları raporlanarak verilmektedir. Şekil 4.1'den bakıldığında, VGG16'nın en iyi sonucu 100. epoch'ta elde etmiştir. VGG16'nın 100. epoch'taki performansı 91.13% olarak belirlenmiştir. 100 ve 200 epoch'ları arasında doğruluk oranlarında dalgalanma vardır.



Şekil 4.2. Sığ modelin 100 epoch başına performansı.

Yine, Sığ modelimizin tahmin kabiliyeti Şekil 4.2'de gösterilmektedir. Açık olarak, Sığ CNN modelinin VGG16 modeli kadar iyi bir sınıflandırma performansı üretmediğini söyleyebiliriz. Bu durum genel olarak bilindiğinden ilginç olarak karşılanmaktadır. Yani daha derin modeller sınıflandırma açısından daha iyi demektir. Shallow ve VGG16 modeli arasındaki performans farkı buğday çekirdeği tanımlaması açısından yaklaşık %11'dir.

5. BULGULAR VE TARTIŞMA

Performans değerlendirme aşamasını arttırmak için, önerilen her füzyon yönteminin performansı, çeşitli mahsul ve tahıl türlerini tanımak için geliştirilen son yöntemlerle karşılaştırılmıştır. Adil bir kıyaslama olması için, CNN konseptine dayanan çalışmaların avantajları ve eksik noktaları dikkate alınarak değerlendirilmiştir.

Her yöntem için, kullanılan görüntüleme sisteminin dalga boyu aralığı, örnek sayısı ve hedef buğday tanesinin tespiti için doğruluk oranıyla beraber Çizelge 5.1’de verilmiştir. Çizelge 5.1, 2016-2019 yılları arasında önerilen her yöntemin ayrıntılarını sunmaktadır.

Çizelge 5.1. 2016'dan beri önerilen bazı yöntemlerle performans karşılaştırması.

Hedef ürün	Görüntüleme modu	Dalga boyu (nm)	# örnekler	# eğitim	# test	# sınıf	doğruluk (%)	Referans
buğday	RGB	-	8000	80%	20%	40	99.38	Önerilen
buğday	VNIR	400-1100	8000	80%	20%	40	99.31	Önerilen
buğday	SWIR	900-1700	8000	80%	20%	40	95.31	Önerilen
buğday	RGB+VNIR	-	8000	80%	20%	40	98.19	Önerilen (İmge Füzyon)
buğday	RGB+SWIR	-	8000	80%	20%	40	100.00	Önerilen (Öznitelik Füzyon)
buğday	RGB+VNIR	-	8000	80%	20%	40	100.00	Önerilen (Öznitelik Füzyon)
buğday bitkileri	Visible	400-700	62118	80%	20%	5	97.30	(Pound vd., 2017)
İşlenmiş pirinç	NIR	900-1100	1392	85%	15%	6	96.20	(Chatnuntawech vd., 2018)
Çeltik pirinç	NIR	900-1100	1656	85%	15%	4	86.30	(Chatnuntawech vd., 2018)
tahıl	RGB	-	8178	-	-	4	96.00	(Picon vd., 2018)
tahıl	RGB	-	17865	17715	750	6	95.60	(Wang vd., 2019)
mısır	NIR	908-1672	400	50%	50%	2	97.10	(Yu vd., 2018)
mısır	RGB	-	2040	80%	20%	2	98.20	(Ni vd., 2019)

Çizelge 5.1’de gösterildiği gibi, belirli bir CNN algoritmasının (Pound vd., 2017) etkinliği bitki fenotiplemesi için değerlendirilmiştir. Gerçekleştirilen CNN yöntemi, sırasıyla %98,4 ve %97,30 doğruluk oranıyla buğday bitkilerinin kök uçlarını ve yaprak uçlarını eşzamanlı olarak tanımlamaktadır.

Sistem performansı, 8.729 kök uç örneği (2 sınıf) ve 12.424 yaprak uç örneği (3 sınıf) ile simülasyonlar yapıldıktan sonra belirlenmiştir.

Eski yöntemlerle elde edilen özneliklerin potansiyel kapasitesi ve DenseNet'e (Huang vd., 2017) CNN yapısı çeltik pirinç (Chatnuntawech vd., 2018) türlerini ayırt etmek için uygulanmıştır. Geleneksel bir öznelik çıkarma stratejisi olarak morfolojik öznelikler, hiper-spektral görüntünün görsel görünümünden elde edilen uzaysal bilgi üzerinden çıkartılarak ayırt etme işlemi gerçekleştirilmiştir. Diğer yandan, NIR kamera ile elde edilen spektral bilgi 3-B veri seti olarak kaydedilmiş ve doğrudan öznelik çıkarma ve sınıflandırma için CNN mimarisi ile birlikte değerlendirilmiştir. Çizelge 5.1'de gösterildiği gibi, CNN ile pirinç çeşitlerinin güvenilirliğinin çeltik pirinç veri setleri için sırasıyla %96,20 ve %86,30 olduğu belirtilmiştir. Belirtilen çalışma (Chatnuntawech vd., 2018), veri kümesi boyutunun artırılmasının daha yararlı olabileceği tahmin etmektedir.

Farklı bir stratejiyle, uyarlanmış ResNet5027 olarak isimlendirilen (He vd., 2016) ve CNN tabanlı algoritma (Picon vd., 2018) Septoria, Tan Spot ve Rust olarak verilen üç Avrupa endemik buğday hastalığına ilişkin erken tanımlama yapmak için mobil uygulama geliştirilmiştir.

Septoria, Tan Spot ve Rust ve Sağlıklı tipler üzerinde daha fazla deney yapılarak, ResNet50 kullanımı ile %84,00 bir doğruluk oranı elde etmektedir. Fakat tanıma oranı Almanya'nın pilot bölgesinde hastalık tespiti için bir Tam Konvolüsyon Ağı (FCN) (Long vd., 2015) ile %96,00 tespit oranına yükseltilmiştir.

Benzer şekilde, bir ResNet mimarisi mısır tanıma amacıyla kullanılmıştır (Ni vd., 2019). CNN'lerin ileri ve geri işlemlerini uygulamadan önce mısır çekirdeklerinin gerçek bölgelerini ortaya çıkarmak için K-means'a dayalı bölge tespiti gerçekleştirilmiştir. CNN modeli 1,632 görüntü ile eğittikten sonra, tahmin performansı 408 test örneğinde %98,20 olarak belirlenmiştir. Elde edilen yüksek performansa rağmen, CNN tabanlı tahmin çerçevesini gerçek zamanlı tahminler için genelleştirmek söz konusu olduğunda, ele alınan eğitim ve test örneklerinin sayısı yetersiz kabul edilmektedir.

Ayrıca, belirli bir ekolojik sulama alanındaki yabancı ot türlerini sınıflandırmak için çok umut verici bir yaklaşım sunulmuştur (Wang vd., 2018). Önerilen bir Sığ CNN mimarisini eğitmek ve test etmek için 3 mahsul türü (yer fıstığı fidesi, buğday, *Xanthium sibiricum* Patr. ex Widder) ve 3 ot türü (*Chenopodium album*, *Humulus scandens*, mısır) dâhil olmak üzere önceden belirlenmiş 6 bitki türü kullanılmıştır. Veri büyütme ile numune boyutunu arttırdıktan sonra, 750 test numunesi için sistemin performansı %95,60'a ulaşmıştır. Bununla birlikte, daha gerçekçi performans değerlendirmesi yapmak için test örneklerini artırmak daha iyi olacaktır.

Geleneksel öznitelik çıkarma metodolojisinin (Yu vd., 2018) kabiliyetini keşfetmek için haploid mısır tohumlarının ve hibrit mısır tohumlarının sınıflandırılması amacıyla Supervised Virtual Sample Kernel Locality Preserving Projection (SVSKLPP) yöntemi araştırılmıştır. İkili sınıflandırma yöntemi olarak, SVM sınıflandırıcısı mısır tohumlarıyla ilgili NIR spektrum verilerinden çıkarılan SVSKLPP özniteliklerine uygulanmıştır. Sistem 200 test numunesi üzerinden %95,20 doğru tanımlama oranı vermiştir. Tatmin edici bir sonuç belirlenmesine rağmen, ticari veya endüstriyel uygulamalar için eğitim ve test örneklerini arttırmak daha faydalı olacaktır.

Çizelge 5.1'de sergilenen sonuçları inceleyerek, önerilen CNN tabanlı öznitelik çıkarma stratejilerinin, gelişmiş öğrenme verimliliği elde etmenin yanı sıra buğday çekirdeği sınıflandırması için tahmin doğruluğunu arttırmak için özgün ve değerli olduğu vurgulanabilir. Diğer yöntemlere kıyasla, bu çalışmada ülkemizin farklı bölgeleriyle ilgili 40 buğday çeşidinden oluşan büyük veri setleri üzerinde deneyler yapılmıştır.

Açıkçası, RGB ve VNIR öznitelikleri için neredeyse %99 doğruluk oranına ulaşılırken, SWIR öznitelikleri durumunda %95,31 tahmin oranı belirlenmiştir. Elde edilen düşük doğruluk skoru, muhtemelen SWIR görüntüleme durumunda yakalanan buğday örneklerine karışan bazı kamera gürültüsü etkilerinden kaynaklanmaktadır.

RGB + VNIR öznitelikleri veya RGB + SWIR öznitelikleri füzyonu durumunda daha fazla performans ilerleme gözlemlenebilir. Sonuçlar öznitelik ve imge uzayı üzerinde füzyon yoluyla iyileştirilmiş olduğu gözükmemektedir. Yine, önerilen öznitelik füzyon sistemi, sadece

bir görüntüleme tekniđi göz önüne alındığında, buđday sınıflandırmasına ilişkin doğrulukta %1'lik bir artış gösterebilmiştir.

Ayrıca, önerilen görüntü füzyonu yaklaşımı, neredeyse tüm son teknoloji tekniklerin performanslarını bastırmaktadır. Özetle, VGG16'nın CNN öznelikleri, buđday çekirdeđi tipi etiketini tahmin ederken daha doğru tanımlama sonuçları sağladığını vurgulayabiliriz. Ayrıca, bu çalışmanın bulguları, buđday türlerinin tatmin edici objektif sonuçlarla tanımlanması için gelişmiş yöntemlerin performansını artırmaya yardımcı olabilir.

6. SONUÇ VE ÖNERİLER

Buğday çekirdeğinin tanımlanması, zorlu bir süreçtir ve insanların algılama sürecini daha da zorlaştıran sınıflar arası yüksek benzerlik ve renk özniteliklerinin zayıflığı gibi faktörler nedeniyle çok fazla çaba gerektirmektedir. Önceki yıllarda yapılan buğday tanımlama yaklaşımları genellikle farklı sınıflar arasında bir karar sınırı oluşturularak önceden belirlenmiş bir sınıflandırıcı ile birlikte manuel özelliklere dayanmaktadır. Fakat performans karşılaştırmaları değerlendirildiğinde, derin öğrenme yöntemleri eski yöntemlerle yapılan nesne sınıflandırma metodolojilerini geride bırakarak çok daha umut vadeden sonuçlar sunmaktadır. Bu bağlamda, popüler bir konvolüsyonel sinir ağı (CNN) mimarisi olan VGG16'nın buğday çekirdeği sınıflandırmasına katkısı da analiz edilmiştir.

İki farklı çalışma yapılmış olup ilk çalışmada RGB, VNIR ve SWIR olmak üzere üç farklı görüntüleme sistemi ile elde edilen buğday çekirdeği görüntülerinin tanımlanması amacıyla önerilen füzyon yöntemlerinin hem imge hem de öznitelik uzayı üzerinden yapılan deneyler sonucunda performansları değerlendirilmiştir.

Simülasyonlar iki özel görevden oluşur:

- (i) İmge uzayında VGG16 modeli ile buğday çekirdeği görüntülerinin ayırt edici farklarını bularak sistemin performansının ölçülmesi.
- (ii) Buğday tanımlama amacıyla VGG16 mimarisi ile elde edilen füzyon edilmiş özniteliklerinin katkılarının değerlendirilmesi.

Simüle edilen sonuçlar, önerilen füzyon yöntemlerinin hem görüntü hem de öznitelik alanı üzerinden 1600'den fazla test örneği üzerinde tahminlerde bulunulması durumunda sırasıyla %98,19 ve %100,00'ü oluşturan iyi performanslar sağladığını göstermektedir. Ayrıca, görüntü alanındaki RGB + VNIR kanallarını ve öznitelik alanındaki RGB + VNIR, RGB + SWIR veya RGB + VNIR + SWIR özniteliklerini birleştirirken ümit verici sonuçlar gözlemlenmiştir. Elde edilen iyi sonuçlar, önerilen füzyon yöntemlerinin tarım endüstrisindeki buğday türlerinin doğru tahmini için uygun olduğunu açıkça göstermektedir. Yapılan diğer çalışmada, buğday sınıflandırması için derin ve sığ CNN modellerinin genel performansları araştırılmıştır ve sınıflandırma üzerindeki performans analizi yapılmıştır. Bu

çalışmada, buğday örneklerini sınıflandırmak için yeni bir VNIR veri seti üzerinde VGG16 ve bir Shallow (Sığ) CNN derin öğrenme modelleri uygulanmıştır. Veri seti 400 ile 1100nm arasındaki bantları yakalayan özel bir kamera kullanılarak (Visible Near Infrared- VNIR) oluşturulmuştur. Her buğday çeşidi için 40 sınıf ve her sınıf içerisinde 200 örnek vardır. Sığ modelin performansı %80,13'lük bir kesinliğe ulaşırken, VGG16 modeli %91,13 doğruluğa ulaşmıştır. Simülasyonlarla elde edilen sonuçlara göre, %91,13'lük değerli doğruluk oranına dayanarak, VGG16 derin öğrenme yöntemlerinin parametrik bağımlılara göre daha başarılı olduğu görülmüştür.

KAYNAKLAR DİZİNİ

- Abdollahzadeh, M., Malekzadeh, T., Seyedarabi, H., 2016, Multi-focus image fusion for visual sensor networks, *Electrical Engineering (ICEE), 2016 24th Iranian Conference on, IEEE*, pp. 1673-1677.
- Ariana, D.P., Lu, R., Guyer, D.E., 2006, Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers, *Computers and Electronics in Agriculture*, 53(1), 60-70.
- Champ, J., Lorieul, T., Bonnet, P., Maghnaoui, N., Sereno, C., Dessup, T., Boursiquot, J.-M., Audeguin, L., Lacombe, T., Joly, A., 2016, Categorizing plant images at the variety level: Did you say fine-grained? *Pattern Recognition Letters* 81 (2016): 71-79.
- Chang, C.C., Lin, C.J.J., 2011, LIBSVM: a library for support vector machines, *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 1-27.
- Chatnuntawech, I., Tantisantisom, K., Khanchaitit, P., Boonkoom, T., Bilgic, B., Chuangsuwanich, E., 2018, Rice Classification Using Spatio-Spectral Deep Convolutional Neural Network, *Computer Science*, arXiv:1805.11491.
- Cheng, X., Chen, Y.R., Tao, Y., Wang, C.Y., Kim, M.S., Lefcourt, A.M., 2004, A novel integrated PCA and FLD method on hyperspectral image feature extraction for cucumber chilling damage inspection, *Transactions of the ASAE*, 47(4), 1313-1320.
- Choudhary, R., Mahesh, S., Paliwal, J., Jayas, D.S., 2009, Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples, *Biosystems Engineering*, 102, 115–127.
- Cogdill, R.P., Hurburgh Jr., C.R., Rippke, G.R., 2004, Single-kernel maize analysis by near-infrared hyperspectral imaging. *Trans, ASAE*, 47 (1), 311-320.
- Dyrmann, M., Karstoft, H., Midtiby, H.S., 2016, Plant species classification using deep convolutional neural network, *Biosystems Engineering*, 151, 72-80.
- ElMasry, G., Wang, N., ElSayed, A., Ngadi, M., 2007, Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry, *Journal of Food Engineering*, 81, 98-107.
- Ghosh, S., Mishra, P., Mohamad, S.N.H., de Santos, R.M., Iglesias, B.D., Elorza, P.B.J., 2016, Discrimination of peanuts from bulk cereals and nuts by near infrared reflectance spectroscopy, *Biosystems Engineering*, 151, 178-186.

KAYNAKLAR DİZİNİ (devam)

- Gillespie, A.R., Kahle, A.B., Walker, R.E., 1987, Color enhancement of highly correlated images. II. Channel ratio and “chromaticity” transformation techniques, *Remote Sensing of Environment*, 22, 343-365.
- González-Martín, M.I., Moncada, G.W., González-Pérez, C., San Martín, N.Z., López-González, F., Ortega, I.L., Hernández-Hierro, J.M., 2014, Chilean flour and wheat grain: tracing their origin using near infrared spectroscopy and chemometrics, *Food Chemistry*, 145, 802-806.
- Gowen, A.A., Taghizadeh, M., O'Donnell, C.P., 2009, Identification of mushrooms subjected to freeze damage using hyperspectral imaging, *Journal of Food Engineering*, 93, 7-12.
- Grinblat, G.L., Uzal, L.C., Larese, M.G., Granitto, P.M., 2016, Deep learning for plant identification using vein morphological patterns, *Computers and Electronics in Agriculture*, 127, 418-424.
- Gulmezoglu, M., Dzhafarov, V., Barkana, A., 2001, The common vector approach and its relation to principal component analysis, *Speech and Audio Processing, IEEE Transactions on Speech and Audio Processing*, 9(6), 655-662.
- Haghighat, M.B.A., Aghagolzadeh, A., Seyedarabi, H., 2010, Real-time fusion of multi-focus images for visual sensor networks, *Machine Vision and Image Processing (MVIP), 2010 6th Iranian, IEEE*, 1-6.
- He, K., Zhang, X., Ren, S., Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778.
- Huang, G., Liu, Z., Van Der Maaten, L., Weinberger, K.Q., 2017, Densely connected convolutional networks, 2017, *Conference on Computer Vision and Pattern Recognition (CVPR), IEEE*, pp. 2261-2269.
- Jégou, H., Douze, M., Schmid, C., Pérez, P., 2010, Aggregating local descriptors into a compact image representation, *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference*, pp. 3304-3311.
- Kim, M.S., Lefcourt, A.M., Chao, K., Chen, Y.R., Kim, I., Chan, D.E., 2002, Multispectral detection of fecal contamination on apples based on hyperspectral imagery: Part I. application of visible and near-infrared reflectance imaging, *Transactions of the ASAE*, 45(6), 2027-2037
- Koenig A., Konitzer K., Wieser H., Koehler P., (2015), Classification of spelt cultivars based on differences in storage protein compositions from wheat, *Food Chemistry*, 168, 176–182.

KAYNAKLAR DİZİNİ (devam)

- Kuo, T.-Y., Chung, C.-L., Chen, S.-Y., Lin, H.-A., Kuo, Y.F., 2016, Identifying rice grains using image analysis and sparse-representation-based classification, *Computers and Electronics in Agriculture*, 127, 716-725.
- Li, H., Wu, X.-J., Kittler, J., 2018a. Infrared and Visible Image Fusion using a Deep Learning Framework, 2018 24th International Conference on Pattern Recognition (ICPR), IEEE (pp. 2705-2710).
- Li, Z., Niu, B., Peng, F., Li, G., Yang, Z., Wu, J., 2018b. Classification of Peanut Images Based on Multi-features and SVM, *IFAC-PapersOnLine*, 51(17), 726-731.
- Liu, D., Ning, X., Li, Z., Yang, D., Li, H., Gao, L., 2015, Discriminating and elimination of damaged soybean seeds based on image characteristics, *Journal of Stored Products Research*, 60, 67-74.
- Long, J., Shelhamer, E., Darrell, T., 2015, Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431-3440.
- Lu, R., 2003, Detection of bruises on apples using near-infrared hyperspectral imaging, *Transactions of the ASAE* 46 (2), 523-530.
- Lu, R., Peng, Y., 2005, Hyperspectral scattering for assessing peach fruit firmness, *Biosystems engineering*, 93 (2), 161-171.
- Mahesh, S., Jayas, D.S., Paliwal, J., White, N.D.G., 2011, Identification of wheat classes at different moisture levels using near-infrared hyperspectral images of bulk samples, *Sensing and Instrumentation for Food Quality and Safety*, 5(1), 1-9.
- Mehl, P.M., Chen, Y.R., Kim, M.S., Chan, D.E., 2004, Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations, *Journal of Food Engineering*, 61(1), 67-81.
- Nagata, M., Tallada, J. G., Kobayashi, T., Toyoda, H., 2005, NIR hyperspectral imaging for measurement of internal quality in strawberries, *ASAE Annual International Meeting*, Tampa, Florida, USA.
- Nagata, M., Tallada, J.G., Kobayashi, T., Cui, Y., Gejima, Y., 2004, Predicting Maturity Quality Parameters of Strawberries Using Hyperspectral Imaging, *ASABE*, St. Joseph, MI.
- Ni, C., Wang, D., Vinson, R., Holmes, M., Tao, Y., 2019, Automatic inspection machine for maize kernels based on deep convolutional neural networks, *Biosystems engineering*, 178, 131-144.

KAYNAKLAR DİZİNİ (devam)

- Nicolai, B.M., Lotze, E., Peirs, A., Scheerlinck, N., Theron, K.I., 2006, Non-destructive measurement of bitter pit in apple fruit using NIR hyperspectral imaging, *Postharvest Biology and Technology*, 40(1), 1-6.
- Olgun, M., Onarcan, A.O., Özkan, K., Işık, Ş., Sezer, O., Özgişi, K., Ayter, N.G., Başçiftçi, Z.B., Ardiç, M., Koyuncu, O., 2016, Wheat grain classification by using dense SIFT features with SVM classifier, *Computers and Electronics in Agriculture*, 122, 185-190.
- Patrício, D.I., Rieder, R., 2018, Computer vision and artificial intelligence in precision agriculture for grain crops: a systematic review, *Computers and Electronics in Agriculture*, 153, 69-81.
- Perronnin, F., Dance, C., 2007, Fisher kernels on visual vocabularies for image categorization, 2007 IEEE conference on computer vision and pattern recognition. IEEE, pp. 1-8.
- Perronnin, F., Sánchez, J., Mensink, T., 2010, Improving the fisher kernel for large-scale image classification, *European Conference on Computer Vision*, Springer, pp. 143-156.
- Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., Johannes, A., 2018, Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild, *Computers and Electronics in Agriculture*, 161, 280-290.
- Pound, M.P., Atkinson, J.A., Townsend, A.J., Wilson, M.H., Griffiths, M., Jackson, A.S., Bulat, A., Tzimiropoulos, G., Wells, D.M., Murchie, E.H., Pridmore, T.P., French, A.P., 2017, Deep machine learning provides state-of-the-art performance in image-based plant phenotyping, *Gigascience*, 6(10), gix083.
- Pourreza, A., Pourreza, H., Abbaspour-Fard, M.-H., Sadrnia, H., 2012, Identification of nine Iranian wheat seed varieties by textural analysis with image processing, *Computers and Electronics in Agriculture*, 83, 102-108.
- Radhika V.R., Sardeshmukh M., 2014, Indian Wheat Seed Classification Based On Texture Analysis Using ANN, *International Journal of Electrical, Electronics and Data Communication*, 2(7), 96-99
- Ravikanth, L., Singh, C.B., Jayas, D.S., White, N.D., 2015, Classification of contaminants from wheat using near-infrared hyperspectral imaging, *Biosystems Engineering*, 135, 73-86.
- Ronge, R., Sardeshmukh, M., 2014, Comparative analysis of Indian wheat seed classification, 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI), IEEE, pp. 937-942.

KAYNAKLAR DİZİNİ (devam)

- Schetselaar, E., 1998, Fusion by the IHS transform: Should we use cylindrical or spherical coordinates? *International Journal of Remote Sensing* 19, 759-765.
- Simonyan, K., Zisserman, A., 2014, Very deep convolutional networks for large-scale image recognition, *Computer Science*, arXiv:1409.1556.
- Singh, C., Jayas, D., Paliwal, J., White, N.D.G., 2009, Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging, *Journal of Stored Products Research*, 45(3), 151-158.
- Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2009, Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging, *Journal of Stored Products Research*, 45(3), 151-158.
- Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2010a, Identification of insect damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging, *Computers and Electronics in Agriculture*, 73(2), 118-125.
- Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2010b, Detection of midge-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging, *Biosystems Engineering*, 105, 380-387.
- Tarım ve Orman Bakanlığı, Tarım ürünleri Piyasası: Buğday, <https://arastirma.tarimorman.gov.tr/tepge/belgeler/pdf%20tar%c4%b1m%20%c3%9cr%c3%bcnleri%20piyasalar%c4%b1/2019-ocak%20tar%c4%b1m%20%c3%9cr%c3%bcnleri%20raporu/2019-ocak%20bu%c4%9fday.pdf>, erişim tarihi: 18.03.2020.
- Wang, S., Liu, H., Han, Y., Chen, J., Pan, Y., Cao, Y., Meng, H., Zheng, Y., 2018, Low-Altitude Remote Sensing Based on Convolutional Neural Network for Weed Classification in Ecological Irrigation Area, *IFAC-PapersOnLine*, 51(17), 298-303.
- Williams, P., Geladi, P., Fox, G., Manley, M., 2009, Maize kernel hardness classification by near infrared (NIR) hyperspectral imaging and multivariate data analysis, *Analytica Chimica Acta*, 653(2), 121-130.
- Xing, J., Bravo, C., Jancsok, P.T., Ramon, H., Baerdemaeker, J.D., 2005, Detecting bruises on 'Golden Delicious' apples using hyperspectral imaging with multiple wavebands, *Biosystems Engineering*, 90 (1), 27-36.
- <
- Yu, S., Jia, S., Xu, C., 2017, Convolutional neural networks for hyperspectral image classification, *Neurocomputing*, 219, 88-98.

KAYNAKLAR DİZİNİ (devam)

Zhang, H., Paliwal, J., Jayas, D.S., White, N.D.G., 2007, Classification of fungal infected wheat kernels using near-infrared reflectance hyperspectral imaging and support vector machine, Transactions of the ASABE, 50(5), 1779-1785.