

Ülkesel Ekmeklik Buğday Alımı için Derin Öğrenme Tabanlı Buğday Sınıflandırma

Merve Ceyhan

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran 2021



Deep Learning-Based Wheat Classification for National Bread Wheat Purchase

Merve Ceyhan

MASTER OF SCIENCE THESIS

Department of Computer Engineering

June 2021

Ülkesel Ekmeklik Buğday Alımı için Derin Öğrenme Tabanlı Buğday Sınıflandırma

Merve Ceyhan

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

Danışman: Doç. Dr. Kemal Özkan

“Bu Tez TÜBİTAK 120O226 no’lu proje çerçevesinde desteklenmiştir.”

Haziran 2021

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre Doç. Dr. Kemal Özkan danışmanlığında hazırlamış olduğum “Ülkesel Ekmeklik Buğday Alımı için Derin Öğrenme Tabanlı Buğday Sınıflandırma” başlıklı Yüksek Lisans 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.

17/06/2021

Merve Ceyhan

ÖZET

Buğday, beslenme zincirinde kullanım alanı çeşitliliği ile üretimde ve tüketimde ilk sıralarda yer alan tahıl ürünlerinden birisidir. Özellikle unlu mamullerde kullanımı başta olmak üzere buğday gıda sektöründe önemli bir yere sahiptir. Üretilen buğdayın miktarı ve kalitesi gıda sektörünü etkilemekte ve doğrudan gıda maddelerinin fiyatlarına yansımaktadır. Buğdaylar protein, gluten ve fiziksel özellikleri gibi faktörlere göre farklı çeşitlere ayrılmaktadır. Bu çeşitlerin her biri farklı özelliklere sahip olduğu için gıda sektöründe farklı maddelerin üretiminde kullanılmaktadırlar. Bu nedenle buğdaydan verimli şekilde yararlanmak ve çeşitlerine göre buğdayı doğru alanda kullanmak hem ekonomik hem de verimlilik açısından büyük önem taşımaktadır.

Yürütülen tez çalışması kapsamında, Yakın Kızılötesi (Near-Infrared (NIR)) Spektrometre cihazı kullanılarak 24 farklı buğday çeşidinin reflektans değerleri ölçülmüş ve sınıflandırma için makine öğrenmesi ve derin öğrenme yaklaşımlarında girdi parametresi olarak kullanılmıştır. Bu yaklaşımlar birbiriyle karşılaştırılmış ve elde edilen sonuçlar değerlendirilmiştir. Ele alınan yaklaşımlar sonucunda makine öğrenmesi tekniklerinin reflektans değeri ile çeşitleri ayırt etmek için yeterli performansı göstermediği görülmüştür. Derin öğrenme modeli ile sınıflandırma yapıldığında makine öğrenmesi algoritmalarına göre daha yüksek doğruluk değerlerine ulaşılmıştır. Derin öğrenme yaklaşımı hem doğrudan reflektans verileri ile sınıflandırma hem de reflektans verileri üzerinden oluşturulan görüntüler üzerinden sınıflandırma yapmak amacıyla ayrı ayrı ele alınmıştır.

Reflektans değerleri kullanılarak oluşturulan buğday çeşitlerine ait görüntüler, derin öğrenme modeline girdi olarak verildiğinde %99 başarı oranına ulaşan sonuçlar alınmıştır. Bu durum buğday sınıflandırmada görüntü tabanlı derin öğrenme mimarilerinin daha iyi sonuçlar verdiğini ortaya koymaktadır.

Anahtar Kelimeler: Derin Öğrenme, Makine Öğrenmesi, Buğday Sınıflandırma, Yakın Kızılötesi

SUMMARY

Wheat is one of the grain products that ranks first in production and consumption with its variety of usage areas in the food chain. Wheat has an important place in the food industry, especially in bakery products. The amount and quality of the wheat produced affect the food industry and are directly reflected in the prices of foodstuffs. Wheat is divided into different types according to factors such as protein, gluten, and physical properties. Since each of these species has different properties, they are used to produce different substances in the food industry. For this reason, it is of great importance to use wheat efficiently and to use wheat in the right field according to its species, both in terms of economy and productivity.

Within the scope of the thesis study, the reflectance values of 24 different wheat species were measured using the Near-Infrared (NIR) Spectrometer device and used as input parameters in machine learning and deep learning approaches to classify wheat species. These approaches were compared with each other, and the results were evaluated. As a result of the approaches discussed, it has been seen that machine learning techniques do not show sufficient performance to distinguish between reflectance value and species. When classification is made with the deep learning model, higher accuracy values have been achieved than machine learning algorithms. The deep learning approach has been handled separately to classify with direct reflectance data and classify images created from reflectance data.

When the images of wheat species created by using reflection values as input to the deep learning model are given, 99% success rates have been achieved. This situation reveals that image-based deep learning architectures give better results in wheat classification.

Keywords: Deep Learning, Machine Learning, Wheat Classification, Near Infrared

İÇİNDEKİLER

Sayfa

ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	8
2.1. Tarımda Makine Öğrenmesi ve Derin Öğrenme.....	9
2.2. Buğday Üzerine Derin Öğrenme Yaklaşımları.....	11
2.3. Yakın Kızılötesi (NIR) Spektrometre Kullanılarak Yapılmış Çalışmalar.....	15
2.4. Yakın Kızılötesi (NIR) Spektrometre Kullanılarak Buğday Üzerine Yapılmış Çalışmalar	18
3. MATERYAL VE YÖNTEM	21
3.1. Kullanılan Materyal.....	21
3.2. Yöntemler.....	22
3.2.1. Makine Öğrenmesi Yaklaşımları.....	22
3.2.2. Derin Öğrenme Yaklaşımları.....	30
3.2.2.1. <u>Beyaz-sert sınıflandırma</u>	31
3.2.2.2. <u>Kırmızı-sert sınıflandırma</u>	32
3.2.2.3. <u>Reflektans değerleri kullanılarak oluşturulan görüntülerle beyaz-sert /</u> <u>kırmızı-sert sınıflandırma</u>	35
3.2.2.4. <u>Reflektans değerleri ile oluşturulan görüntüler üzerinden tüm buğday türlerinin</u> <u>derin öğrenme ile sınıflandırılması</u>	39
4. SONUÇ VE ÖNERİLER	43
KAYNAKLAR DİZİNİ	44

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
1.1. USDA'nın 2019/20 dönemi verilerine göre Türkiye'nin buğday ihracat yaptığı ülkeler ve yüzdeleri.....	2
2.1. Yapay zeka, makine öğrenmesi ve derin öğrenme kapsamı.....	9
3.1. Tüm buğday çeşitlerinin sütun bazlı reflektans ortalamaları.....	23
3.2. Reflektans değerlerini girdi olarak alan derin öğrenme mimarisi.....	30
3.3. Reflektans değerinin doğrudan kullanımı ile beyaz-sert karmaşıklık matrisi.....	32
3.4. Reflektans değerinin doğrudan kullanımı ile kırmızı-sert karmaşıklık matrisi.....	33
3.5. Reflektans değerinin doğrudan kullanımı ile tüm buğday çeşitlerinin karmaşıklık matrisi.....	35
3.6. Reflektans değerlerinden buğday görüntülerinin oluşturulması.....	36
3.7. Görüntüler üzerinde işlem yapmak amacıyla oluşturulan derin öğrenme mimarisi.....	37
3.8. Beyaz-sert buğday çeşitlerinin görüntüler üzerinden sınıflandırmasıyla elde edilen karmaşıklık matrisi.....	38
3.9. Kırmızı-sert buğday çeşitlerinin görüntüler üzerinden sınıflandırmasıyla elde edilen karmaşıklık matrisi.....	39
3.10. Tüm buğday sınıfları için karmaşıklık matrisi.....	41
3.11. Beyaz-sert, kırmızı-sert, diğer-beyaz, diğer-kırmızı sınıfları için karmaşıklık matrisi....	42

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
1.1. TMO buğday alım baremi ekmeklik buğday fiyatlandırması.....	5
1.2. Çalışmada kullanılan buğday türleri ve ait oldukları üst sınıflar.....	6
2.1. Tarım alanında yapılmış bazı çalışmalar ve sonuçları.....	10
2.2. Buğday tahılı üzerine yapılmış olan bazı çalışmalar ve sonuçları.....	11
2.3. NIR kullanılarak yapılmış olan bazı çalışmalar ve sonuçları.....	16
3.1. Buğday çeşitlerine ait protein oranı, bin dane ağırlığı, hektolitre ağırlığı.....	21
3.2. NIR cihazıyla ölçüm sonucunda elde edilen verilere ait örnekler.....	22
3.3. Beyaz-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR.....	25
3.4. Kırmızı-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR.....	27
3.5. Beyaz-sert sınıflandırma kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	31
3.6. Kırmızı-sert sınıflandırma kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	34
3.7. Tüm buğday çeşitlerinin reflektans değerine göre sınıflandırılmasına ait kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	33
3.8. Beyaz-sert sınıflandırmada kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	37
3.9. Kırmızı-sert sınıflandırmada kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	38
3.10. Tüm buğdayların sınıflandırılmasında kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	40
3.11. Tüm buğdayların beyaz-sert, kırmızı-sert, diğer-beyaz, diğer-kırmızı sınıflarına göre sınıflandırılmasından elde edilen kesinlik, duyarlılık, F1-skor ve doğruluk değerleri.....	41

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

nm

Açıklama

Nanometre

Kısaltmalar

USDA

Amerika Birleşik Devletleri Tarım Bakanlığı

TMO

Toprak Mahsulleri Ofisi

NIR

Yakın Kızılötesi

MIR

Orta Kızılötesi (Medium Infrared)

RGB

Kırmızı – Yeşil – Mavi (Red - Green – Blue)

MVS

Yapay Görme Sistemi (Machine Vision System)

DA

Diskriminant Analizi

KNN

K En Yakın Komşular

SVM

Destek Vektör Makinesi (Support Vector Machine)

ANN

Yapay Görme Ağı (Artificial Neural Network)

DTC

Karar Ağacı Sınıflandırıcı (Decision Tree Classifier)

RFC

Rastgele Orman Sınıflandırıcı (Random Forest Classifier)

LDA

Lineer Diskriminant Analizi (Linear Discriminant Analysis)

GNB

Gauss (Gauss Naive Bayes)

LR

Lojistik Regresyon (Logistic Regression)

SWIR

Kısa Dalga Kızılötesi (Short Wave Infrared)

VNIR

Görünür Yakın Kızılötesi (Visible Near Infrared)


1. GİRİŞ VE AMAÇ

Buğday, birbirinden farklı iklim ve toprak koşullarında yetişebilen, çok sayıda çeşidi bulunan, çevre koşullarına geniş adaptasyon yeteneğine sahip bir tahıl türüdür. Buğday tek yıllık bir bitki türü olup genellikle serin iklim koşullarında yetiştirilmeye uygundur. Besin maddesince zengin, asitlik oranı fazla olmayan, hafif ve orta kireçli topraklar buğday yetiştirilmesi için ideal yapıdadır. Buğdayın belirtilen ortam koşulları dışında farklı ortamlara ve iklimlere uyum sağlayabilen pek çok çeşidi de bulunmaktadır.

Buğday, insan beslenmesinde büyük öneme sahip olması nedeniyle tarih boyunca dünya genelinde ekim ve üretim açısından ilk sıralarda yer alan tarla bitkilerinden birisi olmuştur. Buğday, beslenme açısından taşıdığı önem yanında tarihi, kültürel ve sosyal bir değere de sahiptir. Sahip olduğu bu değerler nedeniyle toplumda kutsal kabul edilen saygı duyulan bir bitki türüdür.

İnsan ve hayvan beslenmesinde en yüksek protein içeriğine sahip tahıl ürünlerinden birisi buğdaydır. Günümüzde dünya tahıl üretiminde buğday birinci sırada yer almakta ve toplam insan gıda kalorisinin %20'sinden fazlasını oluşturmaktadır (Özberk vd., 2016). Dünya çapında buğdayın bu kadar yaygın olması ve beslenmede temel kalori kaynağı olarak görülmesinin pek çok sebebi vardır. Buğday tanelerinin yüksek besleme değerine sahip olması, içinde aminoasitleri bulundurması, yetiştirilmesi, taşınması, saklanmasıdaki kolaylıklar, kolay işlenebilirliği, adaptasyon yeteneği, kullanım alanı çeşitliği gibi özelliklere sahip olması bu sebeplerden bazılarıdır. Bununla birlikte buğday tanesi prolamin grubu proteinleri yani gluten içermesinden dolayı ekme yapımına en elverişli tahıl olarak görülmekte ve içerisindeki aromatik bileşikler buğdayın beslenmede kullanımını artırmaktadır (Shewry ve Hey, 2015). Amerika Birleşik Devletleri Tarım Bakanlığı (USDA)'nın 2020/21 dönemi verilerine bakıldığında 2,7 milyar tonluk dünya toplam tahıl üretiminin %28'i buğday üretimidir ve 464 milyon ton olan dünya toplam tahıl ihracatının %42'sini buğday ihracatı oluşturmaktadır. 2020/21 dönemi itibariyle dünya buğday ekim alanının %55,3'ünü Hindistan, Rusya, Çin ve

ABD oluştururken bu ülkeler dünya buğday üretiminin %65,4'ünü oluşturmaktadır. Türkiye de buğday ihracatı yapan ülkeler arasında yer almaktadır. USDA verilerine göre Türkiye, 2019/20 döneminde 6,1 milyon ton buğday ihracatı ile dünya sıralamasında 9. sırada yer almaktadır. Türkiye'nin ihracat yaptığı ülkeler ve oranları Şekil 1.1'de gösterilmektedir. (Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü, 2021).



Şekil 1.1 USDA'nın 2019/20 dönemi verilerine göre Türkiye'nin buğday ihracat yaptığı ülkeler ve yüzdeleri

Dünya genelinde olduğu gibi Türkiye'de de buğday yüksek öneme sahip stratejik bir bitki türüdür. Türkiye'nin iklim koşulları pek çok buğday türünün yetiştirilmesi için elverişli yapıdadır. Ayrıca ülkemiz coğrafyası buğdayın gen merkezi konumunda olup ıslah edilmiş buğday türlerinin yanında yabancı buğday türlerini, bu buğday türlerinin akraba türlerini de içinde bulundurmaktadır. Bu yapısı nedeniyle ülkemiz buğday türlerinde yüksek çeşitlilik ve zenginliğe sahiptir. Buğday türlerinden yüksek verim elde edilmesi, buğdayın hastalıklara ve zararlılara karşı daha dayanıklı olması, sanayici ve tüketicilerin talep ettikleri özelliklerin karşılanması ve buğday zenginliğinin korunarak artırılması üzerine çalışmalar yapılmaktadır. Bu çalışmaların yapılmasında modern ıslah yöntemleri ve teknolojik gelişmeler etkili

olmaktadır. Yapılmakta olan bu çalışmalarla buğdayın ıslah edilmesinin yanında genetik yapısının korunması ve gelecek nesillere aktarılması da hedeflenmektedir (Atak, 2017).

Buğdaylar genetik olarak aktarılan farklı özelliklere sahip olmaları nedeniyle birbirlerinden ayrışmaktadır. Buğdayların özellikleri genetik yapı ile ilgili botanik faktörler olup buğdayların kalitesine bağı olarak kullanım alanını belirlemektedir. Ekmeklik buğday yaygın olarak üretilen ve ekmek yapımı için en uygun olandır. Ekmeklik buğdayın yanında makarnalık ve bisküvilik buğdaylar da bulunmaktadır. Makarnalık ve bisküvilik buğdaylar ekmek yapmaya uygun değıldirler. Makarnalık buğdayların glüten kalitesi ekmeklik buğdaya göre daha düşüktür. Glüten, hamurun elastiklik özelliğinde etkilidir, hamurda sünmeye karşı direnç oluşturur ve gaz tutma sağlar (Güleç vd., 2010). Makarnalık buğday çeşitleri makarna, bulgur gibi besinleri üretmeye elverişlidir. Beslenme zincirinde büyük rol oynayan buğdayın dünya genelindeki üretiminin %95'ini ekmeklik buğday oluştururken diğere %5'ini makarnalık buğday oluşturmaktadır (Peng vd., 2011).

Buğdayın farklı iklim koşullarında yetiştirilmesi sonucu birbirinden farklı kalitede çok sayıda buğday çeşidi ortaya çıkmıştır. Yapılan ıslah çalışmalarında, buğdaylarda belirli özellikler bir araya getirilerek istenilen kalitede ve özelliklerde tahıl ürünleri üretmek amaçlanmaktadır. Buğdayın ve unun ekmeklik kalitesi, hamur yaparken unun su alma miktarına, pişirilen ekmeğın kabarmasına, düzgün biçimli olmasına göre değışmektedir. Ekmeklik olmayan buğdaydan elde edilen unla yapılan ekmeklerde bu özellikler istenileni karşılamamaktadır (Ertugay, 2010). Un kalitesi, üretildiğı buğday çeşidine göre farklılık göstermekte ve buğday kalitesini belirlemede etkili olmaktadır. Una bağı olarak hamurun yapısı, kabarma özelliğı, su tutma miktarı değışmekte ve farklılık gösteren bu özellikler testler ve cihazlar aracılığı ile ölçülmektedir. Farinograf testi, kullanılan testlerden birisidir. Bu test hamurun kabarma zamanı, su emme oranı gibi değıerleri ölçmektedir. Elde edilen sonuçlar buğday kalitesinin belirlenmesinde büyük öneme sahiptir. Kullanılan ekstensograf cihazı da hamurun esnekliğini ve uzamaya karşı direncini ölçmektedir (Şahin vd., 2013). Bu nedenle buğdaylar gösterdikleri özelliklere bağı olarak birbirinden ayrıştırılmakta ve en uygun kullanım alanı belirlenmektedir.

Buğdaylar içerdikleri protein miktarı, protein kalitesi, proteolitik ve amilitik aktivitesine göre farklı sınıflara ayrılmaktadır. Bunun yanında buğday çeşitleri bitki boyu, başak uzunluğu, tek bir başak tanesinin ağırlığı, başaktaki başakçık sayısı, tane ağırlığı, başaklanma gün sayısı, başakta tane sayısının yatma oranı, bin tanenin ağırlığı, nem oranı, tane verimi, glüten oranı, glüten indeks değeri, sedimentasyon ve beklemeli sedimentasyon değerleri bakımından birbirinden farklı özelliklere sahiptir (Kahrıman ve Egesel, 2011). Buğday çeşitleri bu özelliklerine göre birbirinden farklı sınıflara ayrılmakta ve farklı alanlarda üretim yapmak amacıyla kullanılmaktadır. Buğdayın kullanım alanı ekmek ve bisküvi ile sınırlı olmayıp makarna, bulgur, erişte, yufka, lavaş, kadayıf, keşkek, tandır, kömbe, kuskus, bazlama gibi birçok ürünün üretilmesinde kullanılmaktadır. Buğday kalitesi çeşidinin yanında buğday üreticisine, öğütülme biçimine, kullanılan tohum kalitesine göre de değişmektedir (Şanal, 2018).

Ülkemizde buğday alımları Toprak Mahsulleri Ofisi (TMO), Ticaret Borsası, tüccarlar, un fabrikaları aracılığı ile yapılmaktadır. TMO, buğday kalitesini ve alım fiyatlarını kırık tane, cılız ve buruşuk tane, süne/böcek tahribatına uğramış tane, embriyosu kararmış tane, diğer hububat, yabancı madde gibi fiziksel özelliklere ve protein oranını içeren bir indekse göre belirlemektedir (Tarım ve Orman Bakanlığı, 2020). TMO, her yıl Buğday Alım Baremi ile alım yapılacak çeşitleri ve buğdayın alım kriterlerini bildirmektedir. Baremde kırmızı-sert ve beyaz-sert buğday sınıfları oldukça önemlidir ve ülkemizde buğdaya bağlı unlu mamuller sektörünün ihtiyaç duyduğu un grubudur. Numune sayısının fazla olduğu tahıl alım dönemlerinde ürün kalitesinin doğru ve hızlı olarak tespit edilmesi gerekmektedir. Yaş glüten ve Zeleny sedimentasyon analizleri sadece bir numune öğütmeyi gerektirerek uzun sürmesi nedeniyle fiyatlandırmayı belirlemede doğrudan kullanılamamaktadır. Hububat alım dönemlerinde kullanılmak üzere temel kalite özellikleri ile ilişkili, kolay, hızlı ve doğru olarak tespit edilebilen, son ürün kalitesi hakkında fikir veren ve fiyatlandırmaya etki edebilecek nitelikte parametrelere ihtiyaç duyulmaktadır. TMO'nun yayınladığı baremde kalite parametrelerine bağlı olarak kırmızı-sert ve beyaz-sert buğday sınıfları önemli durumdadır. Bu sınıflar dışında kalan buğday çeşitleri, diğer kırmızı ve diğer beyaz sınıflarında yer almaktadır. Temel olarak 4

sınıf altında toplanan buğdayların TMO 2020/2021 yılına ait alım fiyatları Çizelge 1.1’de yer almaktadır (Tarım ve Orman Bakanlığı, 2020).

Çizelge 1.1. TMO buğday alım baremi ekmeklik buğday fiyatlandırması

Ekmeklik Buğday Çeşitleri	2020 Alım Fiyatı (TL/Ton)	2021 Alım Fiyatı (TL/Ton)
Beyaz Sert Buğdaylar	1.650	2.125
Kırmızı Sert Buğdaylar	1.650	2.125
Diğer Beyaz Buğdaylar	1.600	2.080
Diğer Kırmızı Buğdaylar	1.600	2.080

Buğday alım dönemlerinde buğday çeşitlerinin ait olduğu sınıfa göre fiyat vermek büyük önem taşımaktadır. Günümüzde buğday çeşidi, çiftçinin beyanı ve uzman kişinin buğdaya bakıp tespit etmesi ile belirlenmektedir. Bu durumda yüksek bir yanılma payı bulunmaktadır, çünkü buğdayların renk, şekil ve dolgunlukları devam eden ıslah çalışmaları ile birbirine benzemeye başlamıştır. Bunun yanında sıcaklık, yağış, yatma, hasat zamanları ve şekilleri, depolama durumu gibi birçok özellik tane özelliklerinde oldukça büyük varyasyonlar oluşturmaktadır. Bu gibi durumlar buğday çeşidinin tespit edilmesini zorlaştırmaktadır. Buğday üzerinde yakın kızılötesi (NIR) cihazları ile ölçümler de yapılabilmektedir fakat bu cihaz sadece protein ve rutubet miktarını ortaya koyabilmekte sınıflar arasındaki farklılığı doğrudan belirleyememektedir.

Teknolojik gelişmelerle birlikte insanın yetersiz kaldığı, işleyişin pratik olmadığı ya da buğdayda olduğu gibi ayırt etmenin zorlaştığı durumlarda derin öğrenme, yapay zekâ ve makine öğrenmesi gibi yöntemlerden yararlanılmaktadır. Bu yaklaşımların yanında bilgisayarla görü ve makine öğrenimi tarım ürünlerinin çeşidini, kalitesini, olgunluğunu tespit etme amacıyla çalışmalarda kullanılmakta ve başarılı sonuçlar vermektedir. Dijital Kırmızı - Yeşil - Mavi (Red - Green - Blue (RGB)) görüntülemenin yaygınlaşması ve günümüzde multispektral ve hiperspektral kamera teknolojisinin gelişmesiyle, infrared bandından ultraviyole bandına kadar geniş bir bant aralığında yer alan elektromanyetik dalgalar ölçülebilir hale gelmiştir. Bu durum bilgisayarla görü ve makine öğrenimi yüksek doğruluklarla objeleri sınıflandırmayı mümkün kılmıştır. Bu gelişmelerle günümüzde çoğu alanda olduğu gibi tarım alanında da derin öğrenme,

yapay zekâ ve makine öğrenmesi ile kapsamlı çalışmalar yapılmaktadır. Çalışma sonuçları bu yaklaşımların yaygın kullanıldığını, başarılı sonuçlar verdiğini, işleyişi kolaylaştırdıklarını ve hata oranlarını düşürdüklerini ortaya koymaktadır.

Yürütülen çalışmada da 24 farklı buğday çeşidinin sınıflandırılmasında derin öğrenme ve makine öğrenmesi yaklaşımları uygulanmıştır. Çalışmada derin öğrenme ve makine öğrenmesi ile sınıflandırma yapmak amacıyla kullanılan buğday çeşitleri ve ait oldukları sınıflar Çizelge 1.2.'de gösterilmektedir. Her bir buğday çeşidi NIR spektrometre kullanılarak ayrı ayrı ölçülmüştür. NIR spektroskopisi 780-2500 nm dalga boyu aralığında elektromanyetik radyasyon absorpsiyonu temeline dayanmaktadır. Numune üzerinde tahribat oluşturmaması hızlı sonuçlar vermesi nedeniyle besin maddelerinin analizinde yaygın olarak kullanılmaya başlanmıştır. NIR analiz sırasında kimyasal madde kullanımına gerek olmaması, analiz maliyetlerinin düşük olması, bileşenlerin eş zamanlı ve hızlı analizi, diğer analizler için numunenin tekrar kullanılabilirliği ve az miktarda örnekleme yapabilmesi açısından geleneksel yöntemlere göre üstünlüklere sahiptir (Ertugay ve Başlar, 2011). Bu avantajları göz önünde bulundurularak çalışmada kullanılacak olan buğdayların NIR spektrometre cihazı ile ölçümü yapılmıştır.

Çizelge 1.2. Çalışmada kullanılan buğday çeşitleri ve ait oldukları sınıflar

Beyaz Sert	Kırmızı Sert	Diğer Beyaz	Diğer Kırmızı
Kıraç66	Bezostaja	Bayraktar	Ahmetağa
Müfitbey	DropiTarex	Gerek79	Ekiz
Tosunbey	Esperia		Flamura
	Krasunia		Katea
	Maden		Konya2002
	Misiia		Nacibey
	Quality		Nota
	Rumeli		Pehlivan
	Syrena		Sonmez
	Yubileynaya		

Çalışmada kırmızı-sert, beyaz-sert, diğer kırmızı ve diğer beyaz sınıflarına ait buğdayların derin öğrenme tabanlı bir yaklaşım ile birbirinden ayrılması hedeflenmiştir. Derin öğrenme ile buğdayların çeşidi tespit edilerek ait oldukları sınıf ve bu sınıfa ait fiyatlandırma kolaylıkla belirlenebilmektedir. Derin öğrenme yazılımı ile çeşit ayrımı yapılması buğday fiyatını belirme konusunda işleri kolaylaştıracaktır. İnsana bağlılığı ve yüksek hata payını azaltmak, günümüz teknolojisine uygun, hızlı sonuç veren ve var olan işleyişi kolaylaştıran bir yaklaşımı ortaya koymak amacı ile çalışma yürütülmüştür. Tez kapsamında buğday çeşitlerini sınıflandırmak amacıyla buğdaylara ait veriler farklı yaklaşımlarla ele alınarak makine öğrenimi ve derin öğrenme modelleri oluşturulmuş ve modellere ait detaylara, elde edilen sonuçlara yer verilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Derin öğrenme, robotik, doğal dil işleme, görüntü tanıma gibi çeşitli alanların arkasında makine öğrenmesi tekniği bulunmaktadır. Bu teknikte büyük miktarda veri farklı katmanlarda işlenir ve oluşturulan model neyi ne kadar öğrenmesi gerektiğine kendisi karar verir. Derin öğrenmeden farklı olarak makine öğrenmesinde veriler işlenirken çoğunlukla tek katman kullanılır ve verilerle birlikte hangi veri sütunlarına bakılması gerektiği bilgisi de modele verilir. Makine öğrenmesi algoritmaları bu doğrultuda hangi verinin sonuç üzerinde ne kadar etkili olduğunu ortaya koyan bir denklem oluşturur. Derin öğrenmede veri setinde neye odaklanması gerektiği söylenmez, model veriler arasındaki ilişkiyi kendisi öğrenerek verileri kendi içinde ağırlıklandırır. Derin öğrenme, makine öğrenmesinin alt kümesidir ve insanların öğrenme sürecine benzer şekilde matematiksel bir yaklaşımla yapay sinir ağlarını kullanarak ilişkilendirme yapar ve en az bir adet sinir ağı kullanarak algoritmalar ile eldeki verilerden anlamlı sonuçlara ulaşılmasını sağlar. Makine öğrenmesi bu sonuçlara ulaşırken az miktarda veri ile de başarılı olabilirken derin öğrenme için daha fazla veriye ihtiyaç vardır. Makine öğrenmesinde yoğun matematiksel işlemlere ihtiyaç duyulmazken derin öğrenmede uçtan uca çoklu matematiksel hesaplamalar yapılır. Yapay zekâ da insan beyninin çalışmasını temel alan, veriler doğrultusunda kendini sürekli yenileyen bir alandır. Yapay zekâ insan gücü gereken görev ve süreçleri otomatik hale getirerek üretkenliği artırmaktadır. Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki Şekil 2.1’de gösterilmektedir. Günümüzde her alanda ve konuda yeterli miktarda verinin bulunması, bilgisayarların işlem hızlarının ve bellek kapasitelerinin artması derin öğrenme, yapay zekâ, makine öğrenmesi konularına olan ilgiyi arttırmıştır. Yeterli veri ve bilginin olması halinde derin öğrenme, yapay zekâ ve makine öğrenmesi etkili sonuçlar vermekte ve sorunların çözümünde beklentiyi karşılayabilmektedir.

Sorunların çözümüne yönelik oluşturulan modellerde elde edilen çıkarımların gerçeğe en yakın doğrulukta olması beklenmektedir. Bu noktada derin öğrenme algoritmaları insanın tecrübelerinden öğrendiklerine benzer bir şekilde elde ettiği sonucun doğruluğunu artırmak amacıyla kendi içinde iyileştirme işlemleri gerçekleştirmektedir. Derin öğrenme modelleri bu iyileştirmeleri yapabilmek için çok fazla miktarda veriye ihtiyaç duymaktadır. Günümüzde her

gün milyonlarca veri üretilmektedir. Verilerin bu kadar çoğalmış olması onların işlenmesi ve anlamlı sonuçların elde etmesi ihtiyacını ortaya koymuştur. Bu ihtiyaç doğrultusunda veriler işlenerek anlamlı hale getirilmekte ve farklı amaçlar doğrultusunda pek çok çalışmada veri seti olarak kullanılmaktadır.



Şekil 2.1. Yapay zekâ, makine öğrenmesi ve derin öğrenme kapsamı

Derin öğrenme, makine öğrenmesi, yapay zekâ ve görüntü işleme üzerine her alanda olduğu gibi tarım alanında da yapılmış olan ve başarılı sonuçlar elde edilen pek çok çalışma bulunmaktadır. Tarım alanındaki çalışmalar ürün yönetimi, verim tahmini, hastalık tespiti, yabancı ot tespiti, mahsul kalitesi ve tür tanıma uygulamaları, su yönetimi, toprak yönetimi gibi alanlar üzerine yapılmaktadır.

2.1. Tarımda Makine Öğrenmesi ve Derin Öğrenme

Günümüz teknolojik gelişmeleri ile birlikte tarım alanında iyileşmeler yaşanmaya başlanmıştır. Yürütülen tez çalışması kapsamında tarım alanında derin öğrenme, makine öğrenmesi, bilgisayarla görü konularında yapılmış olan çalışmalar incelenmiştir. İncelenen çalışmalara ve elde edilen sonuçlara aşağıda yer verilmiştir. Çalışma sonuçları yeni teknoloji ve yöntemlerin tarımda iyileşmelerin yaşanmasında olumlu etkiler oluşturduğu göstermektedir.

Çizelge 2.1. Tarım alanında yapılmış bazı çalışmalar ve sonuçları

İncelenen	Analiz	Yöntem	Sonuçlar
1018 farklı kahve dalı	Kahve çeşitlerini <ul style="list-style-type: none"> • hasat edilebilir, • hasat edilemez, • olgunlaşma aşamasında şeklinde sınıflandırma	Yapay Görme Sistemi (Machine Vision System (MVS))	MVS'nin meyve sayısını tam olarak tahmin ettiği ve meyvelerinin hasat edilmediği dönemde 0.90'dan daha yüksek bir korelasyon gösterdiği sonucuna ulaşmıştır (Ramos vd., 2017).
Turunçgiller	Olgunlaşmamış yeşil turunçgillerin belirlenmesi	Makine Öğrenmesi	Narenciye bahçesinden elde edilen görüntülerde narenciye meyvesinin %80,4'ü doğru bir şekilde tespit edilip sayılmıştır (Sengupta ve Lee, 2014).
Çilek	Parazitlerin sınıflandırılması ve otomatik saptanması	Destek Vektör Makinesi (Support Vector Machine (SVM))	SVM yönteminin kullanılması ile %2,25'ten daha az ortalama hata yüzdesi ile sınıflandırma yapılmıştır (Ebrahimi vd., 2017).
25 farklı bitkiye ait 87.848 yaprak görüntüsü	Hastalık tespiti ve teşhisi	Derin Öğrenme (Evrişimli Sinir Ağı Modelleri)	Bitkinin hastalıklı ya da sağlıklı olarak tespit edilmesinde %99,53'lük başarıya ulaşılmıştır (Ferentinos, 2018).

2.2. Buğday Üzerine Derin Öğrenme Yaklaşımları

Buğdayı ele alan ve derin öğrenme yöntemlerini kullanan birçok çalışma bulunmaktadır. Yapılmış olan bu çalışmalar tür tespiti, ürün yönetimi konularını kapsıyor olmasına rağmen özellikle buğday hastalıkları ve zararlılarının tespiti alanına odaklanılmaktadır. Buğday hastalıkları ve zararlıları buğdayda kalitenin düşmesine, verimin azalmasına ve ürünün kullanılamaz hale gelmesine neden olabilmektedir. Buğday çeşitlerinde pas, leke, rastık, külleme, kök çürüklüğü gibi hastalıklar görülebilmektedir. Süne, kımıl, ekin kambur böceği, buğday karasineği, ekin sap arıları ve hububat hortumlu böceği, buğday zararlıları arasında yer almaktadır (Gıda Tarım ve Hayvancılık Bakanlığı, 2015). Hastalıklar ve zararlılar, buğdayın fiziksel yapısını etkilediği gibi protein oranında da olumsuz etkiye neden olmaktadır. Hastalık ve zararlıların erken aşamalarda tespit edilerek gereken müdahalenin yapılması üründe oluşabilecek zararı ve olumsuzlukları azaltmada etkili olacaktır. Bu amaçlar doğrultusunda buğday tahılı üzerine yapılmış olan çalışmalar incelenmiş ve çalışma detaylarına Çizelge 2.2’de yer verilmiştir. Çalışmalarda SVM , yapay sinir ağları, görüntü işleme teknikleri kullanılmış ve olumlu sonuçlara ulaşıldığı gözlemlenmiştir.

Çizelge 2.2. Buğday tahılı üzerine yapılmış olan bazı çalışmalar ve sonuçları

İncelenen	Analiz	Yöntem	Sonuçlar
Buğday	Hastalık tespiti	SVM	SVM ile sınıflandırma performansı %99'un üzerindedir. Bu sonuçlar biyotik/abiyotik streslerin otomatik tanınmasında SVM'in etkili olduğunu göstermektedir (Moshou vd., 2014).

Çizelge 2.2. Buğday tahılı üzerine yapılmış olan bazı çalışmalar ve sonuçları (devam)

Buğday	Süne zararına uğramış buğdayların Fourier dönüşümü yaklaşımlı şekil tanıma yöntemiyle tespiti	Fourier Dönüşümü	Buğday tanelerinde süne etkisini ortaya koymada Fourier dönüşümünün açı bilgisine dayanan şekil tabanlı yöntemin başarılı sonuçlar verdiği görülmüştür (Kartal ve Özkan, 2019).
Buğday	VGG16'nın buğday tanelerinin kategorizasyon ve sağlamlığını değerlendirmek	RGB Kısa Dalga Kızılötesi (Short Wave Infrared (SWIR)) Görünür Yakın Kızılötesi (Visible Near Infrared (VNIR))	Çalışma derin öğrenme araçlarının farklı tipteki buğday taneleri arasında yeterince ayırım yapabileceği görüşünü desteklemektedir (Özkan vd., 2019).
Buğday (100 ekmeklik ve 100 makarnalık buğday)	Buğday tanelerini ekmeklik veya makarnalık olarak doğru şekilde sınıflandırma	Yapay Sinir Ağı (Artificial Neural Network (ANN))	Bilgisayar görüşüne dayalı sınıflandırıcının çeşitli tahılları sınıflandırmada başarılı bir şekilde kullanılabileceği sonucuna varılmıştır (Sabancı vd., 2017).

Çizelge 2.2. Buğday tahılı üzerine yapılmış olan bazı çalışmalar ve sonuçları (devam)

Buğday	Bir tahıl kurdu olan Rhyzopertha Dominica böcekleri ve bu böceklerin vücut kısımlarını tespit	Dijital Görüntüleme Teknikleri	8×8 piksellik görüntüler üzerinde yapılan incelemelerde böcek, yabancı ot tohumları ve diğer buğday dışı bileşenlerin tanınmasında %90 başarı elde edilmiştir (Zayas ve Flinn, 1998).
Buğday	Yetişkin böceklerin, kemirgen dışkısının ve ergot mantar türünün tespiti	Makine Görme Yöntemi	Ölçümlerde ergot için %87, tahıl böceği için %100'e ulaşan tespit oranları elde edilmiştir. Model, böcek içeren iki ticari numuneye uygulandığında %89 ve %96 tespit oranlarına ulaşılmıştır (Ridgway vd., 2002).
Buğday (3500 görüntü)	Septoria, pas ve bronzluk hastalıklarının erken teşhis edilebilmesi	Görüntü İşleme	Gerçek koşullar altında analiz edilen hastalık türleri için %80 başarıya ulaşılmıştır (Johannes vd., 2017).

Çizelge 2.2. Buğday tahılı üzerine yapılmış olan bazı çalışmalar ve sonuçları (devam)

Buğday	Kalite sınıflandırması	SVM ve Yapay Sinir Ağı	SVM'nin doğruluğu %86,8 ve sinir ağının doğruluğu %94,5 olarak elde edilmiştir. Sonuçlar, sinir ağının SVM'den daha iyi sonuç verdiğini ortaya koymaktadır (Punn ve Bhalla, 2013).
Buğday (3 farklı aydınlatma koşulu ve 4 farklı nem düzeyinde 9600 görüntü)	Çeşit belirlleme	Görüntü İşleme	Buğdayların aynı nem ortamında sınıflandırma doğrulukları akkor, halka floresan ve tüp floresan ışığı için sırasıyla %90, %81 ve %96'dır, farklı nem seviyelerindeyken değerler sırasıyla %66, %53 ve %85 şeklindedir (Manickavasagan vd., 2008).
Buğday-Arpa (10 buğday ve 10 arpa)	Buğday ve arpa tanelerinin birbirinden ayrıştırılması	Diskriminant Analiz ve K-En Yakın Komşular	Tanelerin morfolojik, renk ve doku özellikleri çıkarıldığında arpa ve buğday sınıflandırmada %99 doğruluk değerine ulaşılmıştır (Guevara-Hernandez ve Gil, 2011).

2.3. Yakın Kızılötesi (NIR) Spektrometre Kullanılarak Yapılmış Çalışmalar

Spektroskopideki son gelişmeler, gıda, tahıl, yem ürünlerinin kontrol edilmesi ve izlenmesi için spektroskopik görüntüleme araçlarının kullanımını artırmıştır. Ürünlerin tanınması ve analiz edilmesinde uzman kişiye ihtiyaç duyulmaması, tüm prosedürleri otomatikleştirmesi, birim zaman başına daha fazla numuneyi analiz edebilmesi nedeniyle spektroskopi yaygınlaşmıştır. NIR spektroskopisinin kullanımının tercih edilmesi ve yaygınlaşmasında;

- Kullanımının kolay olması ve örnekler üzerinde ön işleme gerek duyulmaması,
- Çok sayıda verinin eş zamanlı olarak hızlı şekilde analiz imkânı,
- Pul, toz, parçacık gibi farklı yapıdaki örnek türleri için uygun oluşu,
- Ölçümde kullanılan numunelerin tekrar kullanılabilir oluşu,
- Az numunenin ölçümde yeterli oluşu,
- Numuneler üzerinde tahribata neden olmaması,
- Kimyasal ek işlemlere ve ara malzemelere ihtiyaç duyulmaması,

etkili olmuştur. Bu avantajları nedeniyle çalışmada NIR spektrometre cihazının kullanımı tercih edilmiştir. NIR cihazı ile 24 çeşit buğday üzerinde ölçüm işlemleri gerçekleştirilmiştir. Elde edilen veriler çalışmada kullanılacak olan veri setinin oluşturulmasında kullanılmıştır. Yürütülen çalışma kapsamında NIR spektrometre kullanılmış çalışmalar detaylıca incelenmiştir.

İncelenmiş bu çalışmalarda NIR spektrometre cihazının yaygın olarak kullanıldığı, veri setlerinin oluşturulmasında tercih edildiği ve ölçümlerde başarılı sonuçlar verdiği görülmüştür. Alanda yapılmış olan çalışmalara Çizelge 2.3'de yer verilmiştir.

Çizelge 2.3. NIR kullanılarak yapılmış olan bazı çalışmalar ve sonuçları

İncelenen	Analiz	Yöntem	Sonuç
Yem	Yem bileşenlerini içeren karışımın taranması ve içindeki yem varlığını tespit edilmesi	SVM + NIR	SVM, oluşturulan eğitim verilerini analiz etmede ve genellemede başarılı bulunmuştur (Pierna vd., 2006).
Yem	Protein materyallerinin kalitesinin belirlenmesi	NIR	NIR spektroskopisinin protein materyallerinin kalite analizinde verimli bir tarama aracı olduğu görülmüştür (Chen vd., 2013).
Toprak	Toprağın karbon içeriğini belirleme	NIR + Orta Kızılötesi (Medium Infrared (MIR))	Kurutulmuş ve öğütülmüş numunelerde MIR'in en doğru yöntem olduğu fakat topraktaki karbonun hacimsel konsantrasyonun da ölçülmesi gerektiği sonucuna varılmıştır (Bellon-Maurel ve McBratney, 2011).
Tahıl	Şeker pancarı köklerinde kist tespiti	NIR	NIR hiperspektral görüntüleme yöntemi ile kistlerin tespitinde 0.71'lik başarıya ulaşılmıştır (Pierna vd., 2012).

Çizelge 2.3. NIR kullanılarak yapılmış olan bazı çalışmalar ve sonuçları (devam)

Mısır	Mısır unundaki bileşenlerin NIR ile analizinde kalibrasyon modelleri karşılaştırması	Kısmi En Küçük Kareler Regresyon ve Çoklu Doğrusal Regresyon + NIR	Protein analizinin başarıyla yapıldığı görülürken karbonhidrat ve yağ için NIR cihazının yeterli olmadığı görülmüştür. Dalga boylarına ilişkin yapılan analizde, dalga boylarının regresyon katsayıları düşük olduğunda tahmin gücünün düştüğü görülmüştür (Egesel ve Kahrıman, 2012).
Elma	Kalite analizi	NIR	4 farklı noktadan yapılan NIR ölçümlerinin kalite parametrelerini kesin olarak tahmin etmek için uygun olduğu sonucuna varılmıştır (Pissard vd., 2012).
Tahıl	Ergot tespiti	NIR Hiperspektral Görüntüleme	NIR hiperspektral görüntüleme kamerası ile elde edilen sonuçların kararlı ve tekrarlanabilir olduğu görülmüştür (Vermeulen vd., 2013).

2.4. Yakın Kızılötesi (NIR) Spektrometre Kullanılarak Buğday Üzerine Yapılmış Çalışmalar

Temelinde buğday çeşitlerinin birbirinden ayırmaya yönelik olarak ele aldığımız çalışmada veri setinin oluşturulması amacıyla NIR spektrometre kullanılmıştır. NIR spektrometrenin kullanılması nedeniyle buğday ve NIR spektrometre kullanımını içeren çalışmalar ayrıca ele alınmıştır. Çalışmalarda NIR spektrometrenin hangi amaçlarla, nasıl kullanıldığı elde edilen sonuçlar, karşılaşılan zorluklar ve bu zorlukların nasıl giderildiği incelenmiştir.

Buğday sınıfının belirlenmesi, işlevsellik ve ticaret değerindeki farklılıkları ortaya koymak için gerekli bir işlemdir. Çok sayıda buğday çeşit olması nedeniyle, çeşitlere göre ayırma genellikle hasat sonrası işleme sırasında pratik değildir. Buğday çeşitlerine bazen farklı tür mahsuller yanlışlıkla karıştırılır, bu da buğdayların karma bir kategori halinde sınıflandırılmasına ve dolayısıyla değerinin düşmesine neden olur.

Bu kapsamda incelenen çalışmada yakın kızılötesi yansıma taramaları ile iki buğday sınıfının çeşitli kombinasyonları üzerinde analizler yapılmıştır. Renge dayalı ayrımlar için 551-750 nm, içsel özelliklere dayalı ayrımlar için 1120-2476 nm aralığı kullanılmıştır. Çalışmada sert beyaz, sert kırmızı, sert kırmızı kış, yumuşak kırmızı kış ve yumuşak beyaz şekilde 5 sınıf mevcuttur. Bu sınıflarda 56 ile 72 arasında değişen numune bulunmaktadır. Her bir sınıf için toplamda 318 numuneden alınan 10'ar örnekte sert beyaz ve sert kırmızı kış gibi birbirinden farklı sınıflarda ikili sınıflandırma yapıldığında doğruluk oranları %99'lara kadar ulaşmıştır. Sınıflar renk olarak birbirine benzedikçe modelin ayırt etme oranı düşmekte ve doğruluk oranları %78 olarak elde edilmektedir (Delwiche ve Massie, 1996).

Bir diğer çalışmada buğday taneleri içindeki tane böceği larvaları ve pupaların tespiti için 700 nm ile 1100 nm yakın kızılötesi aralığında yansıma spektroskopisi araştırılmıştır. 982 nm-1014 nm ve 972 nm-1032 nm aralığında iki farklı dalga boyu ile 80 tane buğday tanesi üzerinde inceleme yapılmıştır. Kullanılan buğday taneleri böcekli ve böceksiz şeklinde iki örnek içermektedir. Çalışmada spektral farklılıkların, tekrar tekrar taranan numunelerde daha genç

böcek larvalarının ve daha sonraki gelişim aşamalarının tespitinde etkili olduğu görülmüştür. İleriki çalışmalarda 982 nm-1014 nm dalga boyu aralığında, yakın kızılötesi görüntüleme sistemine kamera lens filtreleri dahil edilerek, tahıldaki böcekleri tespit etmek için ucuz, hızlı ve güvenilir bir makine görüşü yöntemine yol açabileceğine de değinilmiştir (Ridgway vd., 1999).

Yakın kızılötesi spektroskopisi kullanılarak bir tahıl ürünü için homojenlik kontrolü gerçekleştirilebilir. Çalışmada önerilen yöntemin performansını incelemek için, heterojen buğday numuneleri yapay olarak hazırlanmıştır. Kullanılan buğday örnekleri 952 nm-2631 nm aralığında analiz edilmiştir. Homojen numuneler arasında heterojen numuneleri tespit etmek için NIR ölçümleri ile elde edilen protein ve nem içerikleri sonuçlarına aykırı değer tespiti (Grubbs Testi) gerçekleştirilmiştir. Önerilen bu yaklaşımla NIR tekniğinin yapay olarak hazırlanan numuneler arasında homojenliği kontrol etmede daha verimli olduğu görülmüştür (Lafargue vd., 2003).

Vitrözlük (camsı yapı), protein içeriği ile ilişkilidir ve makarnalık buğdaylar için önemli bir derecelendirme faktörüdür. Ele alınan çalışmada spektroskopi ve dijital görüntüleme birleştirilerek yakın kızılötesi hiperspektral görüntüleme sistemi ile buğday tanelerinin vitrözlüklerine göre sınıflandırılması ele alınmıştır. 650 nm-1100 nm dalga boyu aralığında farklı vitrözlük oranlarına sahip buğday tanelerinin hiperspektral reflektans görüntüleri alınmıştır. Görüntülerde vitröz ve vitröz olmayan taneler arasında ayırıştırma sonuçları %94 doğruluk oranlarına ulaşmıştır (Gorretta vd., 2006).

Bir diğer çalışmada yakın kızılötesi hiperspektral görüntüleme kullanılarak böceklerden zarar görmüş buğday tanelerinin tespiti incelenmiştir. Sağlıklı buğday taneleri ve *Sitophilus Oryzae*, *Rhizopertha Dominica*, *Cryptolestes Ferrugineus* ve *Tribolium Castaneum* cinsi böcekler tarafından gözle görülür şekilde zarar görmüş buğday taneleri, NIR hiperspektral görüntüleme sistemi kullanılarak 1000-1600 nm dalga boyu aralığında taranmıştır. Görüntüler üzerinde doğrusal diskriminant analizi ve kuadratik diskriminant analiz sınıflandırıcıları kullanılarak %85-100 sağlıklı ve böceklerden zarar görmüş buğday taneleri doğru bir şekilde sınıflandırılmıştır (Singh vd., 2009).

Endüstride farklı toz gıdaların işlenmesi için ortak bir çalışma ortamının kullanılması, toz gıdalarda fıstık izleri bulunma ihtimalini artırmaktadır. Bu ihtimali ortaya koymak için yapılan bir çalışmada temel bileşen analizi kullanılarak yakın kızılötesi hiperspektral görüntüleme spektroskopisi ile buğday unundaki yer fıstığı izlerinin tespiti ele alınmıştır. Yer fıstığının saptanması için yaygın olarak kullanılan analitik yöntemler zaman alıcıdır ve uzman kişi gerektirir. Yer fıstığı izleri ile karıştırılmış buğday ununa ait NIR hiperspektral görüntüleri incelendiğinde yer fıstığı tespitinde kimyasal yöntemlerin yanında NIR hiperspektral görüntüleme sistemlerinin de kullanılabileceği ortaya konmuştur (Mishra vd., 2015).

3. MATERYAL VE YÖNTEM

3.1. Kullanılan Materyal

Çalışmada buğday çeşitlerinin derin öğrenme yaklaşımı ile sınıflandırmasına odaklanılmıştır. Bu kapsamda 24 farklı çeşit buğday kullanılmıştır (Bkz. Çizelge 1.2). Kullanılan bu buğday çeşitlerinin her biri renk, şekil, protein miktarı olarak farklı özellikler taşımaktadır. Bunun yanında bin dane ağırlığı, hektolitreye ağırlığı gibi farklılıkları bulunmaktadır (Karaduman vd., 2020). Her bir buğday sınıfına ait protein oranı, bin dane ağırlığı, hektolitreye ağırlığı Çizelge 3.1’de gösterilmektedir. Bu farklılıklar buğdayların ait olduğu sınıfı belirlerken buna bağlı olarak da kullanım alanlarını belirlemede etkili olmaktadır. Buğdaylar kırmızı-sert, beyaz-sert, diğer kırmızı, diğer beyaz şeklinde sınıflarda toplanmaktadır. Bu sınıflarda bulunan buğdaylar benzer özellikleri taşımaktadır ve fiyatlandırma bu sınıflara göre yapılmaktadır.

Çizelge 3.1. Buğday çeşitlerine ait protein oranı, bin dane ağırlığı, hektolitreye ağırlığı

	Protein Oranı (%)	Bin Dane Ağırlığı (gr)	Hektolitreye Ağırlığı (kg/hl)
Ahmetağa	14-16	42-48	80-83
Bayraktar	11-14	32-34	78-80
Bezostaja	13-15	40-44	80-84
DropiTarex	13-15	39-45	77-83
Ekiz	13-15	36-38	78-80
Esperi	14-15	35-40	80-84
Flamura	13-14	37-41	78-82
Gerek79	10-12	32-36	68-72
Kıraç66	10-14	30-36	80-82
Konya2002	12-14	40-49	78-82
Krasunia	13-15	37-42	79-83
Maden	14-16	42-45	82-85
Missiia	11-16	33-39	75-80
Müfitbey	12-13	33-35	75-76
Nacibey	11-13	38-42	79-82

Çizelge 3.1. Buğday çeşitlerine ait protein oranı, bin dane ağırlığı, hektolitre ağırlığı (devam)

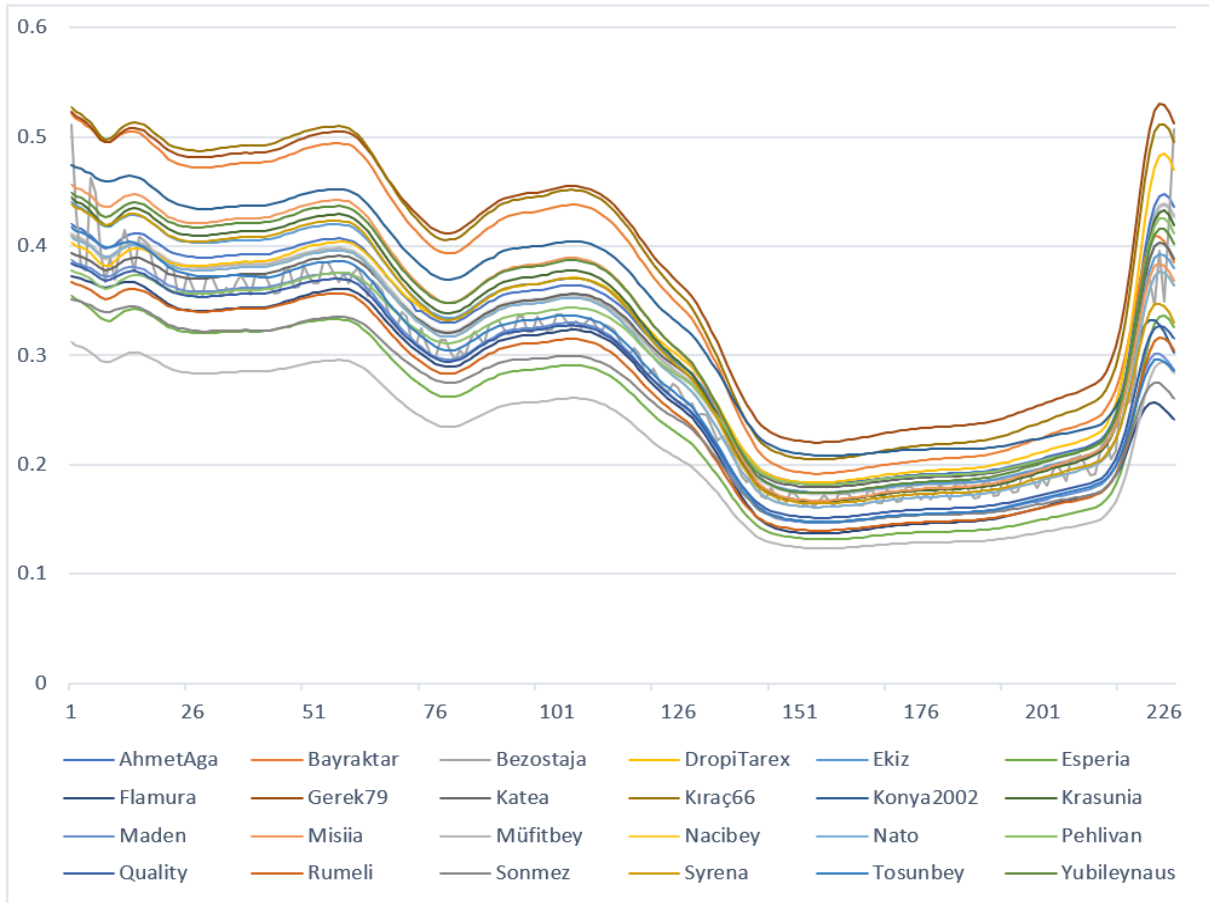
Nota	10-13	36-38	77-79
Pehlivan	12-14	45-46	80-82
Quality	12-15	40-44	80-82
Rumeli	13-16	44-46	82-84
Sönmez	12-15	36-42	76-86
Syrena	12-14	38-44	80-84
Tosunbey	10-12	34-36	78-80
Yubileynaus	12-15	40-44	78-82

Sınıflandırma amacıyla kullanılan veri seti NIR cihazı ile yapılan ölçümlerle oluşturulmuştur. Yapılan çalışmalara girdi olarak kullanılmak üzere NIR cihazı ile buğdayların reflektans değerleri ölçülmüştür. Ölçüm işlemleri DLP NIRscan arayüzü kullanılarak gerçekleştirilmiştir. Spektral aralık her bir ölçüm için 900 – 1700 nm olarak ayarlanmıştır. Elde edilen veriye ait örnekler Çizelge 3.2’de gösterilmektedir. Bu ölçüm işlemi her bir buğday sınıfı için 4000’er kere tekrarlanmıştır. Toplam olarak 96000 (24 x 4000) veriden oluşan bir veri seti oluşturulmuştur.

Çizelge 3.2. NIR cihazıyla ölçüm sonucunda elde edilen verilere ait örnekler

	0	1	2	3	4	5	6	7	...	227
0	0.480415	0.469703	0.465529	0.455258	0.448437	0.457173	0.445813	0.445119	...	0.653714
1	0.387132	0.394785	0.38446	0.397638	0.389037	0.374043	0.376035	0.366599	...	0.662087
2	0.426975	0.414249	0.407927	0.404255	0.398753	0.394643	0.380572	0.385765	...	0.670889
3	0.430071	0.432856	0.424545	0.427873	0.408287	0.403517	0.39591	0.395924	...	0.541434
...
3999	0.304617	0.298201	0.302605	0.278123	0.286369	0.283016	0.282422	0.279773	...	0.648347
4000	0.434513	0.407027	0.41444	0.422376	0.418278	0.396434	0.397854	0.401482	...	0.562903

Ölçümler sonucunda elde edilen verilerin dağılımını görmek amacıyla buğday çeşitlerinin kendi içinde sütun bazlı olarak reflektans değerlerinin ortalaması hesaplanmıştır. Elde edilen bu verilere ait çizim Şekil 3.1’de yer almaktadır. Şekle bakıldığında verilerin benzer bir dağılım gösterdiği görülmektedir.



Şekil 3.1. Tüm buğday çeşitlerinin sütun bazlı reflektans ortalamaları

3.2. Yöntemler

3.2.1. Makine öğrenmesi yaklaşımları

Buğday çeşitlerinin sınıflandırılması amacıyla ilk olarak makine öğrenmesi algoritmalarından yararlanılmıştır. Bu aşamada amaç buğday çeşitlerinin beyaz-sert ya da kırmızı-sert sınıfları içinde ayırt edilme durumunu ortaya koymaktır. Aynı sınıf içinde yer alan buğdaylar diğer sınıflardaki buğdaylara göre daha fazla benzerlik göstermektedir. Bu durum onların aynı sınıf altında ayrıştırılmalarını zorlaştırmaktadır. Tüm buğday çeşitleri için reflektans değerlerine bakıldığında değerler birbirine yakın özellikler göstermektedir (Bkz Şekil

3.1). İnsan gözünün ayırt edemediği durumlarda sayısal ilişkileri ortaya çıkarmak amacıyla makine öğrenmesi algoritmalarından yararlanılabilir. Kullanılan algoritmalar, bakıldığında benzer görünen şekil, resim ve ifadeler arasındaki farklılıkları matematiksel olarak ortaya koyabilmektedir. Sınıflandırma işlemleri temel olarak:

1. İkili (Binary) Sınıflandırma
2. Çok sınıflı (Multi-Class) Sınıflandırma
3. Çok Etiketli (Multi-Label) Sınıflandırma
4. Dengesiz Dağılımlı (Imbalanced) Sınıflandırma

başlıkları altında toplanabilmektedir. Yürütülen çalışma ikiden fazla buğday çeşidinin bulunması, bir buğday çeşidinin sadece bir sınıfa ait olması ve kullanılan verilerde dengesiz bir dağılım olmaması nedeniyle sınıflandırma işlemleri çok sınıflı sınıflandırma ile ele alınmıştır.

Çok sınıflı sınıflandırma için kullanılacak popüler algoritmalar, Karar Ağacı Sınıflandırıcısı (Decision Tree Classifier (DTC)), Destek Vektör Sınıflandırıcısı (Support Vector Classifier (SVM)), K En Yakın Komşu Algoritması (K Neighbors Classifier (KNN)), Rastgele Orman Sınıflandırıcısı (Random Forest Classifier (RFC)), Lineer Diskriminant Analizi (Linear Discriminant Analysis (LDA)), Gauss (Gauss Naive Bayes (GNB)), Lojistik Regresyon (Logistic Regression (LR)) algoritmaları sınıflandırma yapmak amacıyla kullanılmıştır (Geron, 2019; Müller ve Guido, 2016). Kullanılan algoritmaların detaylarına, kullanım biçimlerine ve parametrelerine Pedregosa vd. (2011) çalışmasında yer verilmiştir. (Pedregosa vd., 2011). Reflektans değerleri kullanılarak makine öğrenmesi algoritmaları yardımıyla çeşitlerin birbirinden istenilen seviyede ayırt edilip edilemediği test edilmiştir. Buğday çeşitlerinin birbirinden ayrıştırılması beyaz-sert ve kırmızı-sert sınıfları için ayrı ayrı denenerek ayrılma durumu incelenmiştir. Algoritmaların ayrı ayrı kullanılmasıyla beyaz-sert sınıfı için elde edilen sonuçlar Kesinlik (Precision), Duyarlılık (Recall), F1-Skor (F1-Score) ve Doğruluk (Accuracy) Çizelge 3.3’de yer almaktadır. Kırmızı-sert buğday sınıfı için elde edilen sonuçlara da Çizelge 3.4’de yer verilmiştir.

Çizelge 3.3. Beyaz-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR

(a)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.73	0.75	0.74
Müfitbey	0.79	0.72	0.75
Tosunbey	0.52	0.65	0.58
Doğruluk	0.68		

(b)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.84	0.88	0.86
Müfitbey	0.91	0.73	0.81
Tosunbey	0.64	0.79	0.71
Doğruluk	0.79		

(c)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.81	0.74	0.77
Müfitbey	0.84	0.68	0.75
Tosunbey	0.49	0.71	0.58
Doğruluk	0.71		

(d)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.75	0.65	0.70
Müfitbey	0.81	0.59	0.68
Tosunbey	0.25	0.25	0.34
Doğruluk	0.60		

Çizelge 3.3. Beyaz-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR (devam)

(e)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.80	0.81	0.80
Müfitbey	0.81	0.73	0.77
Tosunbey	0.64	0.71	0.67
Doğruluk	0.75		

(f)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.82	0.81	0.82
Müfitbey	0.84	0.75	0.79
Tosunbey	0.64	0.73	0.68
Doğruluk	0.76		

(g)

	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.79	0.75	0.77
Müfitbey	0.78	0.67	0.72
Tosunbey	0.51	0.65	0.57
Doğruluk	0.69		

Beyaz-sert sınıfındaki buğdaylara DTC, SVC, KNN, RFC, LDA, GNB ve LR algoritmaları uygulandığında doğruluk değeri %60 ve %79 aralığında bulunmuştur. Ulaşılan bu sonuçlar beyaz-sert sınıfındaki buğdayları sınıflandırmada belirli bir başarıyı ortaya koysa da buğdayları birbirinden tamamen ayırt etmede tam yeterli değildir.

Çizelge 3.4. Kırmızı-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR

(a)

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.21	0.27	0.23
DropiTarex	0.56	0.36	0.44
Esperia	0.76	0.22	0.33
Krasunia	0.42	0.32	0.36
Maden	0.29	0.25	0.27
Misiia	0.11	0.39	0.17
Quality	0.05	0.24	0.08
Rumeli	0.01	0.19	0.02
Syrena	0.16	0.23	0.18
Yubileynaus	0.08	0.32	0.13
Doğruluk	0.27		

(b)

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.21	0.27	0.23
DropiTarex	0.56	0.36	0.44
Esperia	0.76	0.22	0.33
Krasunia	0.42	0.32	0.36
Maden	0.29	0.25	0.27
Misiia	0.11	0.39	0.17
Quality	0.05	0.24	0.08
Rumeli	0.01	0.19	0.02
Syrena	0.15	0.23	0.18
Yubileynaus	0.08	0.32	0.13
Doğruluk	0.27		

Çizelge 3.4. Kırmızı-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR (devam)

(c)

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.30	0.25	0.27
DropiTarex	0.56	0.31	0.40
Esperia	0.43	0.32	0.37
Krasunia	0.30	0.33	0.32
Maden	0.27	0.22	0.24
Misiia	0.19	0.27	0.23
Quality	0.18	0.19	0.18
Rumeli	0.15	0.19	0.17
Syrena	0.14	0.29	0.19
Yubileynaus	0.15	0.25	0.19
Doğruluk	0.28		

(d)

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.01	0.11	0.02
DropiTarex	0.38	0.20	0.26
Esperia	0.36	0.19	0.25
Krasunia	0.07	0.18	0.10
Maden	0.21	0.13	0.16
Misiia	0.13	0.27	0.17
Quality	0.13	0.15	0.17
Rumeli	0.26	0.12	0.16
Syrena	0.01	0.40	0.01
Yubileynaus	0.23	0.16	0.19
Doğruluk	0.16		

Çizelge 3.4. Kırmızı-sert sınıfına ait buğdayların makine öğrenmesi algoritmaları ile sınıflandırılması: (a) DTC (b) SVC (c) KNN (d) RFC (e) LDA (f) GNB (g) LR (devam)

(e)

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.29	0.29	0.29
DropiTarex	0.55	0.40	0.47
Esperia	0.52	0.37	0.43
Krasunia	0.35	0.34	0.35
Maden	0.25	0.24	0.24
Misiia	0.21	0.36	0.23
Quality	0.18	0.19	0.19
Rumeli	0.18	0.21	0.19
Syrena	0.17	0.25	0.21
Yubileynaus	0.22	0.27	0.24
Doğruluk	0.30		

(f)

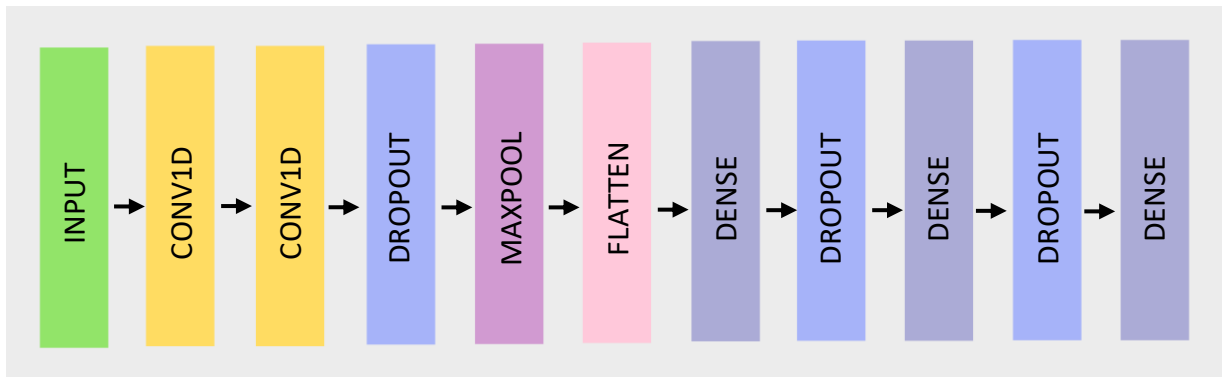
	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.15	0.22	0.18
DropiTarex	0.63	0.42	0.50
Esperia	0.48	0.41	0.44
Krasunia	0.45	0.36	0.40
Maden	0.26	0.27	0.27
Misiia	0.38	0.41	0.39
Quality	0.12	0.18	0.14
Rumeli	0.24	0.27	0.25
Syrena	0.49	0.38	0.43
Yubileynaus	0.15	0.25	0.19
Doğruluk	0.34		

Makine öğrenmesi algoritmaları kullanılarak reflektans değerleri ile buğday çeşitleri birbirlerinden ayırt edilerek sınıflandırma yapmak amacıyla kullanılmıştır. Beyaz-sert ve kırmızı-sert buğday çeşitleri için ayrı ayrı makine öğrenmesi algoritmaları kullanıldığında Çizelge 3.3 ve Çizelge 3.4'de yer alan sonuçlara ulaşılmıştır. Beyaz-sert buğday türlerini sınıflandırmada makine öğrenmesi algoritmalarıyla (SVM) %79'lara ulaşan doğruluk değeriyle

kırmızı-sert buğday sınıfına göre daha yüksek oranda sınıflandırma yapılmıştır. Beyaz-sert buğday olarak 3 çeşit buğday bulunurken kırmızı-sert buğday olarak 10 çeşit bulunmaktadır (Bkz Çizelge 1.2). Reflektans değerleri çeşit sayısı arttıkça buğdaylar arasındaki ayrımı ortaya koyamamıştır. Elde edilen sonuçlar buğday çeşitlerinin sınıflandırılmasında makine öğrenmesi algoritmalarının beklenen başarıyı göstermediğini ve reflektans değerleri ile buğday sınıflandırması yapmak için kullanımının yeterli olmadığını göstermektedir.

3.2.2. Derin öğrenme yaklaşımları

Buğday çeşitlerinin sınıflandırılması amacıyla makine öğrenmesi algoritmalarının kullanımının yeterli olmadığı görülmüştür. Alanda yapılmış olan çalışmalar incelendiğinde derin öğrenme yaklaşımının sınıflandırmada daha iyi sonuçlar verebileceği görülmüştür. Bunun üzerine derin öğrenmeye dayalı modeller oluşturularak sınıflandırma yapılmış ve elde edilen sonuçlar değerlendirilmiştir.



Şekil 3.2. Reflektans değerlerini girdi olarak alan derin öğrenme mimarisi

Farklı modeller oluşturularak en iyi sonuca ulaşmak üzere denemeler yapılmıştır. Şekil 3.2’de yer alan derin öğrenme mimarisi kullanılmıştır.

- Input: Modele giriş verisi olarak 228 uzunluğundaki reflektans değeri verilmiştir.
- Conv1D: Bu katman verilerdeki özellikleri ortaya koymak için filtreler uygular.
- Dropout: Belirli bir eşik değeri altında kalmış olan düğümler rastgele şekilde elenir.

- MaxPool1D: Boyut indirgeme amacıyla kullanılır. Gezdirilen filtre içinde en büyük değeri alır.
- Flatten: Verileri düz bir hale getirerek diziye dönüştürür.
- Dense: Katmanlar arası düğümleri birbirine bağlar.

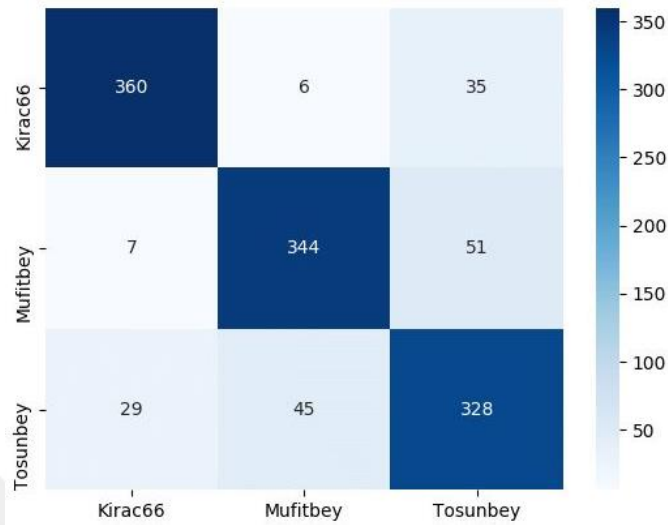
Bu model beyaz-sert, kırmızı-sert ve tüm buğday çeşitlerini reflektans değeri üzerinden sınıflandırılması amacıyla oluşturuldu.

3.2.2.1. Beyaz-sert sınıflandırma

Sınıflandırma işlemlerinde birbirinden farklı yöntemler denenmiştir. Bu yöntemlerin her birinde veri seti alt parçalara ayrılarak farklı yönleriyle ele alınmıştır. Ele alınan ilk yöntemde beyaz-sert sınıfına ait olan Kırış 66, Müfitbey ve Tosunbey buğday çeşitlerinin sınıflandırılması üzerinde durulmuştur. Bu buğday çeşitleri kendi içinde protein oranı, hektolitre ağırlığı, bin dane ağırlığı gibi temel farklılıklara sahip olmasının yanında ekim alanı, sap uzunluğu (saman üretimi), soğuşa dayanıklılık, hastalık ve zararlılara karşı dirençlerinde de farklılıkları bulunmaktadır. Sınıf bazlı bu farklılıklardan yola çıkarak beyaz-sert sınıfına ait çeşitler kendi içinde ayrıştırılmıştır. Oluşturulan derin öğrenme modeli ile Çizelge 3.5'te verilen değerlere ulaşarak %86 doğruluk değeri ile sınıflar ayrıştırılmıştır. Oluşan karmaşıklık matrisi Şekil 3.3'de verilmiştir. Sınıf bazlı olarak kesinlik değeri %89'lere ulaşırken duyarlılık %91'e ulaşmıştır.

Çizelge 3.5. Beyaz-sert sınıflandırma kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

	Kesinlik	Duyarlılık	F1-Skor
Kırış66	0.91	0.90	0.90
Müfitbey	0.87	0.86	0.86
Tosunbey	0.79	0.82	0.80
Doğruluk	0.86		



Şekil 3.3. Reflektans değerinin doğrudan kullanımı ile beyaz-sert karmaşıklık matrisi

3.2.2.2 Kırmızı-sert sınıflandırma

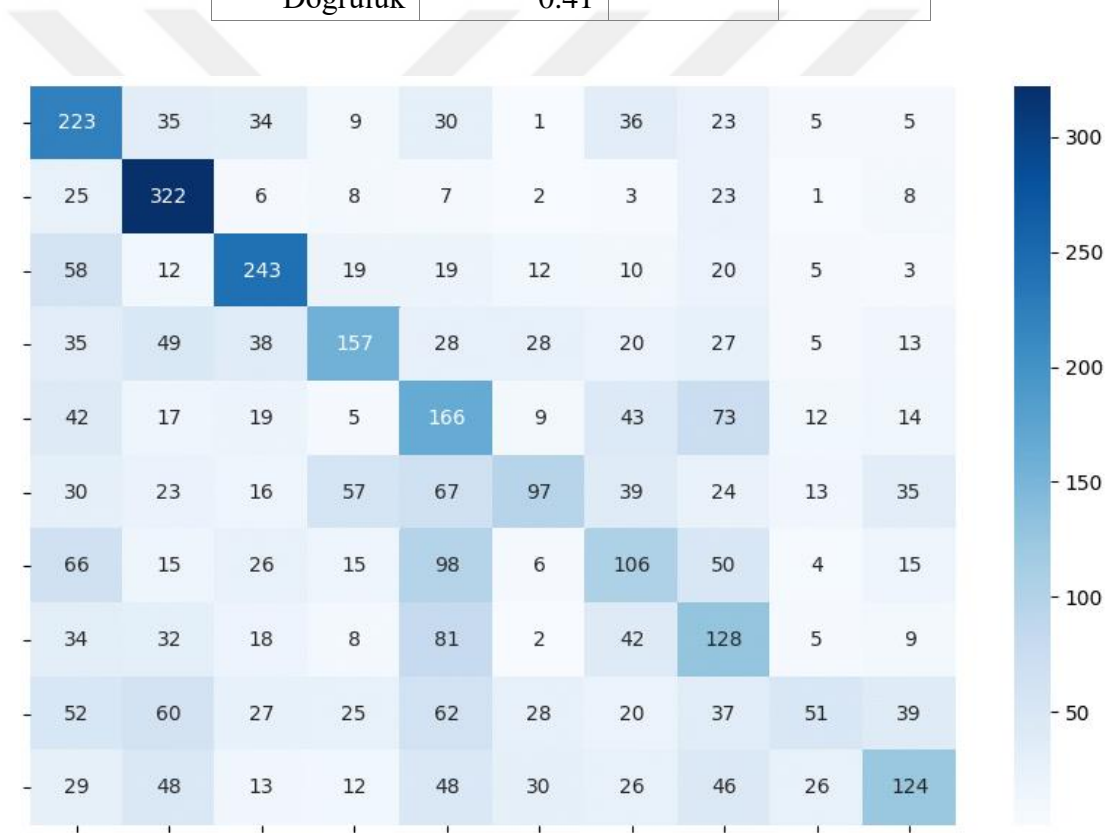
Beyaz-sert için ele alınan yaklaşım kırmızı-sert buğday sınıfında bulunan Bezostaya, DropiTarex, Esperia, Krasunia, Maden, Misiiia, Quality, Rumeli, Syrena, Yubileynaus buğday çeşitleri için de yapılarak buğdaylar çeşitlerine göre sınıflandırılmıştır. Bu buğday sınıfları da kendi içinde protein miktarlarına, yetiştirilme iklim özelliklerine, hastalıklara göre gösterdikleri dirençlere göre farklılaşmaktadır. Bu farklılardan yola çıkılarak kırmızı-sert buğday çeşitleri de kendi içinde sınıflandırılmıştır. Derin öğrenme modeli ile yapılan sınıflandırmada elde edilen doğruluk, kesinlik, F1-skor değerleri Çizelge 3.6'da ve oluşan karmaşıklık matrisi Şekil 3.4'de yer almaktadır. Tablodaki değerlere bakıldığında daha fazla sayıda çeşit içeren kırmızı-sert sınıfı için ayırma işleminin beyaz-sert sınıfı kadar başarılı olmadığı görülmüştür.

Çizelge 3.6. Kırmızı-sert sınıflandırma kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.38	0.56	0.45
DropiTarex	0.53	0.80	0.63
Esperia	0.55	0.61	0.58

Çizelge 3.6. Kırmızı-sert sınıflandırma kesinlik, duyarlılık, F1-skor ve doğruluk değerleri (devam)

Krasunia	0.50	0.39	0.44
Maden	0.27	0.41	0.33
Misiia	0.45	0.24	0.31
Quality	0.31	0.26	0.28
Rumeli	0.28	0.36	0.32
Syrena	0.40	0.13	0.19
Yubileynaus	0.47	0.31	0.37
Doğruluk	0.41		

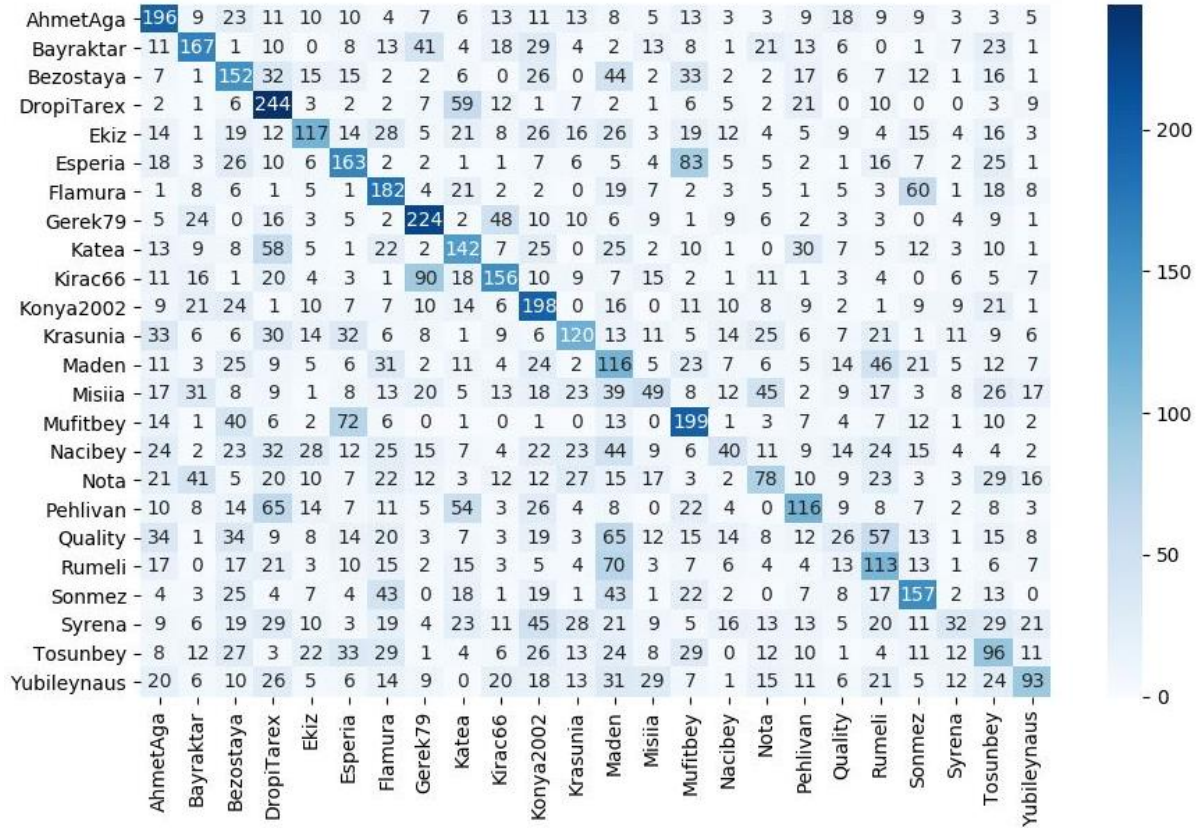


Şekil 3.4. Reflektans değerinin doğrudan kullanımı ile kırmızı-sert karmaşıklık matrisi

Reflektans değerleri üzerinden sınıflandırma işlemi beyaz-sert ve kırmızı-sert buğdaylar dışında tüm buğday çeşitleri için de gerçekleştirilmiştir. Elde edilen sonuçlar Çizelge 3.7’de yer almaktadır.

Çizelge 3.7. Tüm buğday çeşitlerinin reflektans değerine göre sınıflandırılmasına ait kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

	Kesinlik	Duyarlılık	F1-Skor
AhmetAğa	0.39	0.49	0.43
Bayraktar	0.44	0.42	0.43
Bezostaya	0.29	0.38	0.33
DropiTarex	0.36	0.60	0.45
Ekiz	0.38	0.29	0.33
Esperia	0.37	0.41	0.39
Flamura	0.35	0.50	0.41
Gerek79	0.47	0.56	0.51
Katea	0.32	0.36	0.34
Kıraç66	0.43	0.39	0.41
Konya2002	0.34	0.49	0.40
Krasunia	0.37	0.30	0.33
Maden	0.18	0.29	0.22
Misiia	0.23	0.12	0.16
Müfitbey	0.37	0.50	0.42
Nacibey	0.23	0.10	0.14
Nota	0.27	0.20	0.23
Pehlivan	0.36	0.28	0.32
Quality	0.14	0.16	0.19
Rumeli	0.26	0.31	0.28
Sönmez	0.40	0.39	0.39
Syrena	0.24	0.18	0.12
Tosunbey	0.22	0.24	0.23
Yubileynaus	0.40	0.23	0.29
Doğruluk	0.33		



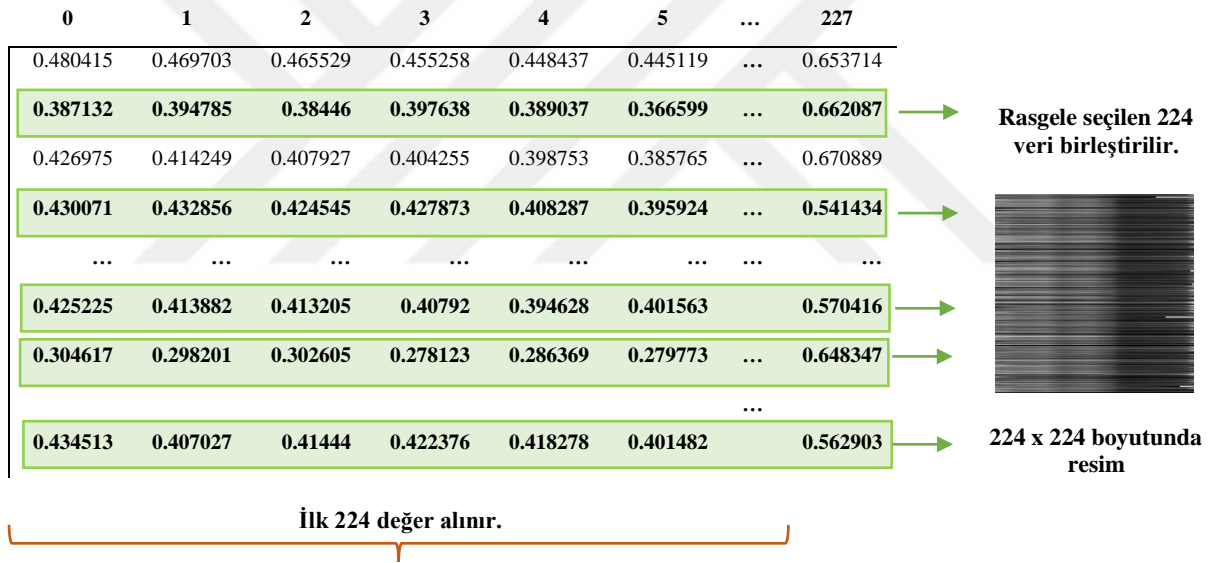
Şekil 3.5. Reflektans değerinin doğrudan kullanımı ile tüm buğday çeşitlerinin karmaşıklık matrisi

3.2.2.3 Reflektans değerleri kullanılarak oluşturulan görüntülerle beyaz-sert / kırmızı-sert sınıflandırma

Buğday çeşitlerinin sınıflandırılmasında temel alınan veri NIR spektrometre cihazı ile elde edilen reflektans değerleridir. Her bir ölçümde 228 uzunluğunda reflektans değerlerini içeren bir vektör dönmektedir. Ölçümler sonucunda toplanan bu reflektans vektörleri derin öğrenme modellerine giriş verisi olarak verilmiş ve beyaz-sert, kırmızı-sert buğday sınıflandırmada doğrudan kullanılmıştır.


Görüntü işleme dayanan sınıflandırma yaklaşımlarının başarılı sonuçlar verdiği bilinmektedir. Yapılan literatür taramasında da elde edilen sonuçlarda yüksek doğruluk değerlerine ulaşıldığı görülmüştür. Bu başarısından dolayı buğday çeşitlerini sınıflandırmak amacıyla da görüntü verilerini temel alan bir model uygulamanın başarılı sonuçlar verebileceği

düşünülmüştür. Çalışmada kullanılan görüntüler buğdaylar çeşitlerine ait reflektans verileri üzerinden üretilmiştir. Buğday sınıfına ait görüntüler oluşturulurken her bir sınıf içinden reflektans değerlerini içeren 228 uzunluğundaki veri vektörlerinden rastgele (random) şekilde 224 tane seçilmiştir ve 228 uzunluğundaki verilerin ilk 224 tanesi görüntü oluşturmak amacıyla kullanılmıştır. Seçilen ilk 224 değeri okunarak 224x224 boyutunda resimler oluşturulmuştur. Resimlerin oluşturulma yapısı Şekil 3.6 'de görselleştirilmiştir. Her bir sınıf için 2000 eğitim verisi ve 400 test verisi olmak üzere 2400 resim oluşturulmuştur. Toplam olarak 57600 adet veri içeren veri seti ile sınıflandırma işlemleri gerçekleştirilmiştir. Bu veri seti de diğer araştırmacıların çalışmalarında kullanması amacıyla paylaşılacaktır.



Şekil 3.6. Reflektans değerlerinden buğday görüntülerinin oluşturulması

Oluşturulmuş olan bu görüntüler derin öğrenme modeline girdi olarak verilmiş ve görüntüler üzerinden buğday çeşitlerinin sınıflandırılması yapılmıştır. Sınıflandırma yapmak amacıyla kullanılan derin öğrenme modeli Şekil 3.7'da yer almaktadır.

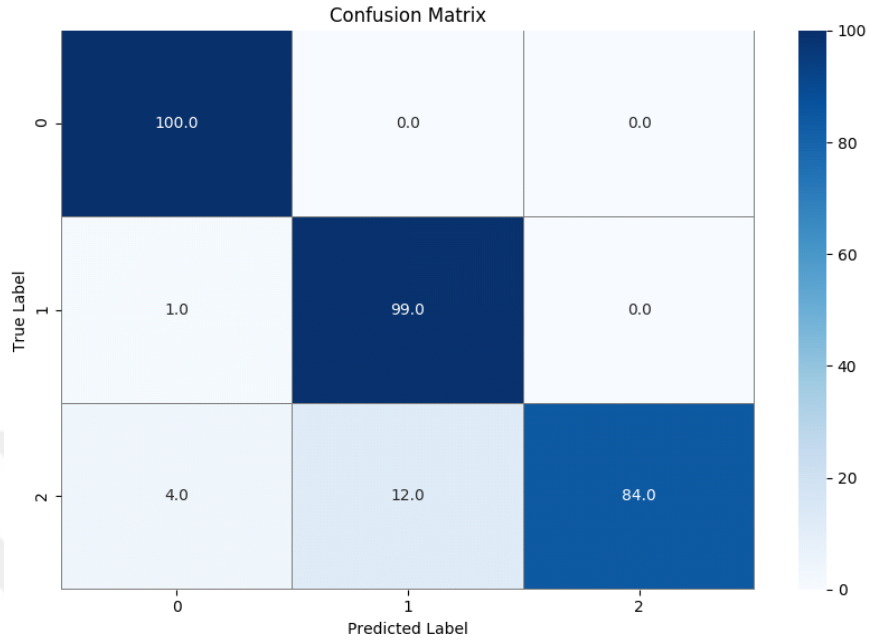


Şekil 3.7. Görüntüler üzerinde işlem yapmak amacıyla oluşturulan derin öğrenme mimarisi

Görüntüler üzerinden sınıflandırma yapıldığında doğrudan reflektans değerlerinin kullanımına göre %99.26 oranlarına ulaşan daha yüksek bir başarı oranı elde edilmiştir. Görüntüler üzerinden sınıflandırmaya dayanan yöntem hem beyaz-sert grubu hem de kırmızı-sert grubu buğday görüntüleri için ayrı ayrı uygulanmıştır. Her iki sınıf içinde yüksek doğruluk değerlerine ulaşılmıştır. Görüntüler üzerinde yapılan çalışmada sonucunda elde edilen sonuçlar Çizelge 3.8 ve Çizelge 3.9’de yer almaktadır.

Çizelge 3.8. Beyaz-sert sınıflandırmada kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

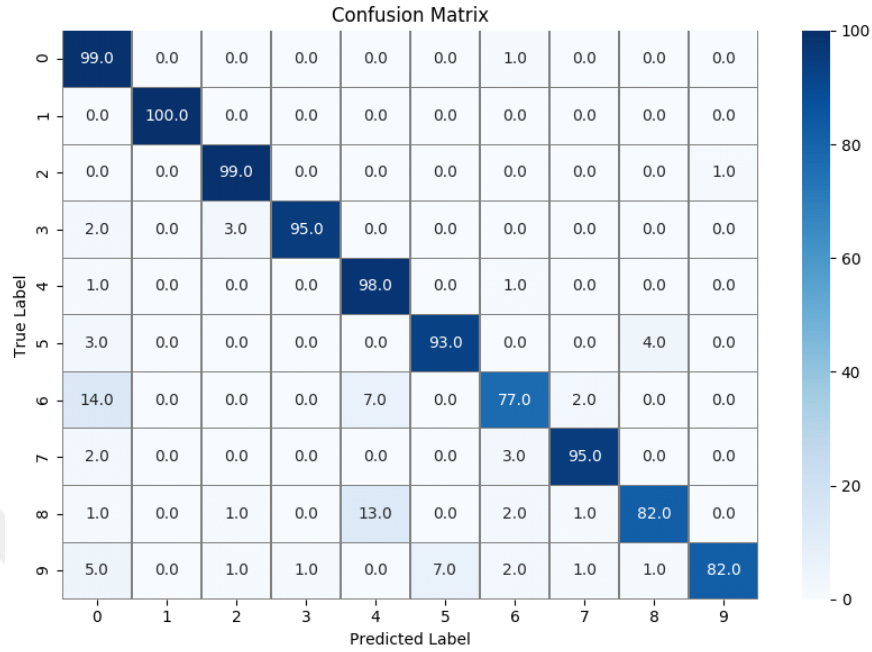
	Kesinlik	Duyarlılık	F1-Skor
Kıraç66	0.98	1.00	0.99
Müfitbey	0.89	0.99	0.94
Tosunbey	1.00	0.84	0.91
Doğruluk	0.9655	Loss	0.1735



Şekil 3.8 Beyaz-sert buğday çeşitlerinin görüntüler üzerinden sınıflandırmasıyla elde edilen karmaşıklık matrisi

Çizelge 3.9. Kırmızı-sert sınıflandırmada kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

	Kesinlik	Duyarlılık	F1-Skor
Bezostaya	0.99	0.99	0.99
DropiTarex	1.00	1.00	1.00
Esperia	0.95	0.99	0.97
Krasunia	0.98	0.96	0.97
Maden	0.83	0.98	0.90
Misiia	0.93	0.93	0.93
Quality	0.87	0.80	0.83
Rumeli	0.96	0.97	0.97
Syrena	0.85	0.90	0.87
Yubileynaus	0.97	0.88	0.92
Doğruluk	0.9870	Loss	0.045



Şekil 3.9. Kırmızı-sert buğday çeşitlerinin görüntüler üzerinden sınıflandırmasıyla elde edilen karmaşıklık matrisi

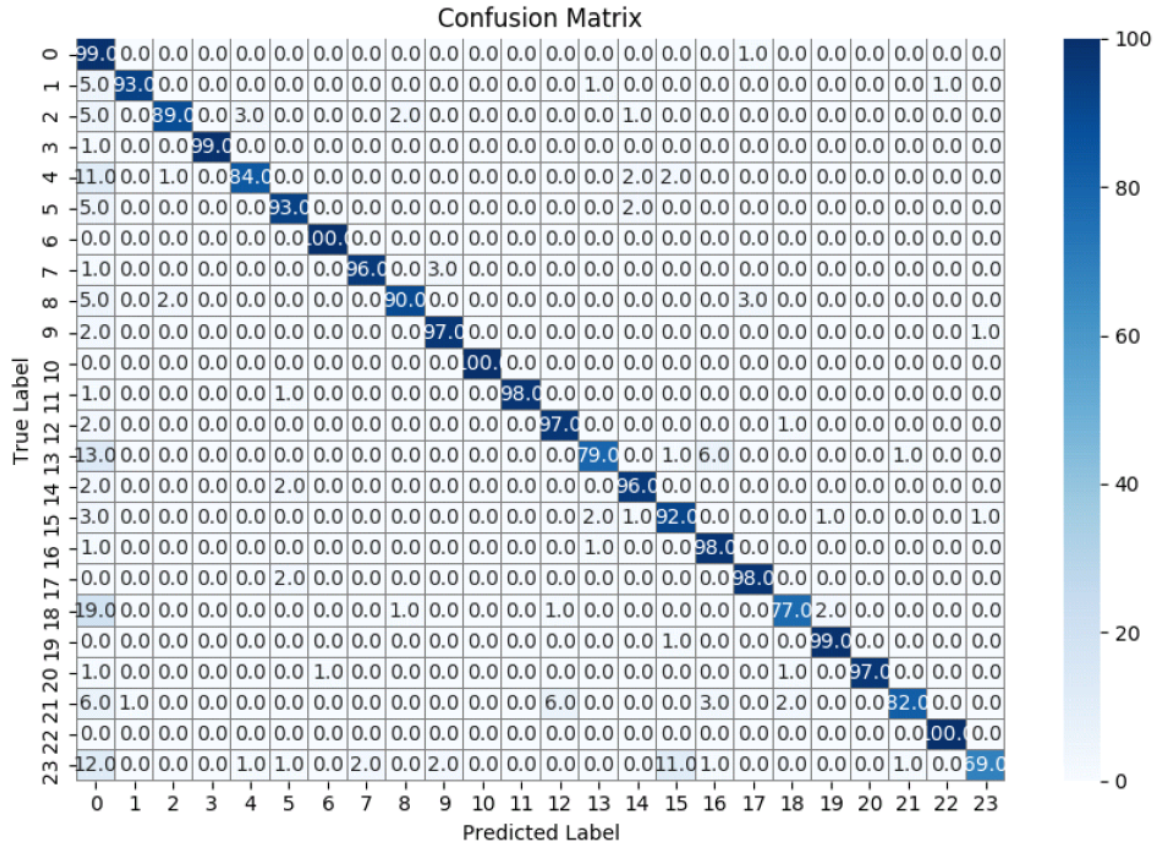
3.2.2.4 Reflektans değerleri ile oluşturulan görüntüler üzerinden tüm buğday çeşitlerinin derin öğrenme ile sınıflandırılması

Reflektans değerleri kullanılarak elde edilen resimler ile oluşturulan derin öğrenme modelinde beyaz-sert ve kırmızı-sert buğday grupları için yapılan sınıflandırmalarda yüksek başarı oranlarına ulaşılmıştır. Bu doğrultuda çalışmada kullanılan 24 buğday çeşidini sınıflandırma için görüntüye dayalı olan model kullanılmıştır. Modelin eğitilmesi ve test edilmesi için oluşturulan veri seti 24000 eğitim verisi ve 2400 test verisi olarak ayrılmıştır. Beyaz-sert ve kırmızı-sert buğday gruplarının ayrıştırılması ile yüksek doğruluk, duyarlılık, kesinlik değerlerinin elde edildiği gibi tüm buğday sınıflarının ayrıştırılmasında da yüksek değerlere ulaşılmıştır. Model tüm buğday sınıflarının sınıflandırılmasında %99.26 başarı değerini vermektedir. Ulaşılan bu değer ıslah çalışmaları ile benzer fiziksel özelliklere sahip olmaya başlayan buğday sınıflarının birbirinden ayrılmasında derin öğrenme yönteminin kolaylık sağlanacağını göstermektedir.

Buğday çeşitlerinin sınıflandırılmasında görüntü işleme dayalı bir yöntemin kullanılmasının, doğrudan reflektans değerlerinin kullanılmasına göre daha iyi sonuçlar verdiğini ortaya koymaktadır (Çizelge 3.10). Tüm buğday sınıflarına sınıflandırmak için uygulanan derin öğrenme modelinden Şekil 3.10'da yer alan karmaşıklık matrisi elde edilmiştir. Matriste yer alan sonuçlar modelin sınıflandırmada %84 ile %100 arasında doğruluk değeri verdiği görülmektedir. Modelin eğitimi süresi ve resim sayısı artırıldığında başarı oranlarında artış sağlanabilmektedir.

Çizelge 3.10. Tüm buğdayların sınıflandırılmasında kesinlik, duyarlılık, F1-skor ve doğruluk değerleri


	Kesinlik	Duyarlılık	F1-Skor
AhmetAğa	0.99	0.99	0.99
Bayraktar	0.99	0.93	0.96
Bezostaya	0.97	0.89	0.93
DropiTarex	1.00	0.99	0.99
Ekiz	0.93	0.84	0.88
Esperia	0.94	0.93	0.93
Flamura	0.99	1.00	1.00
Gerek79	0.98	0.96	0.97
Katea	0.96	0.92	0.94
Kıraç66	0.94	0.97	0.96
Konya2002	1.00	1.00	1.00
Krasunia	1.00	0.98	0.99
Maden	0.93	0.97	0.95
Misiia	0.95	0.79	0.86
Müfitbey	0.87	0.97	0.92
Nacibey	0.84	0.94	0.89
Nota	0.91	0.98	0.94
Pehlivan	0.93	1.00	0.96
Quality	0.91	0.78	0.84
Rumeli	0.94	1.00	0.97
Sönmez	1.00	0.99	0.99
Syrena	0.95	0.89	0.92
Tosunbey	0.96	1.00	0.98
Yubileynaus	0.93	0.75	0.83
Doğruluk	0.9952	Loss	0.0141



Şekil 3.10. Tüm buğday sınıfları için karmaşıklık matrisi

Çizelge 3.11. Tüm buğdayların beyaz-sert, kırmızı-sert, diğer-beyaz, diğer-kırmızı sınıflarına göre sınıflandırılmasından elde edilen kesinlik, duyarlılık, F1-skor ve doğruluk değerleri

	Kesinlik	Duyarlılık	F1-Skor
Beyaz-sert (0)	0.45	0.69	0.55
Kırmızı-sert (1)	0.47	0.15	0.23
Diğer-beyaz (2)	0.76	0.83	0.79
Diğer-kırmızı (3)	0.80	0.85	0.83
Doğruluk	0.82		



Şekil 3.11. Beyaz-sert, kırmızı-sert, diğer-beyaz, diğer-kırmızı sınıfları için karmaşıklık matrisi

4. SONUÇ VE ÖNERİLER

Yürütülen tez çalışması kapsamında buğday çeşitlerinin yüksek doğruluk değerlerinde sınıflandırılmasına odaklanılmıştır. Bu amaç doğrultusunda NIR cihazı ile buğdaylara ait reflektans değerlerinden oluşan bir veri seti oluşturulmuştur. Oluşturulan veri seti farklı yaklaşımlarla ele alınarak kullanılmış ve elde edilen sonuçlar değerlendirilmiştir. Makine öğrenmesi algoritmaları ve derin öğrenme modelleri ayrı ayrı ele alınarak sınıflandırmada başarıları karşılaştırılmıştır. Beyaz-sert ve kırmızı-sert alt veri kümeleri oluşturularak makine öğrenmesi algoritmaları, derin öğrenme modelleri ile incelenmiştir. Sınıflandırmada doğrudan reflektans değerleri ve reflektans değerleri üzerinden oluşturulan görüntü verilerinden yararlanılmıştır.

Ele alınan yaklaşımlarda makine öğrenmesi algoritmalarının reflektans değeri üzerinden sınıflandırmada yeterli başarıyı göstermediği görülmüştür. Bu nedenle derin öğrenme modelleri oluşturularak sonuçlar değerlendirilmiştir. Oluşturulan derin öğrenme modellerinde makine öğrenmesine göre daha yüksek başarı oranlarına ulaşılmıştır.

Çalışma kapsamında görüntüler üzerinde yapılan buğday çeşidi sınıflandırma işlemlerinde derin öğrenme modelleri %99 doğruluk değerlerine ulaşmaktadır. Bu sonuç buğday benzeri tahıl sınıfında bulunan fiziksel özellikleri yüksek oranda benzerlik gösteren mahsullerin sınıflandırılmasında reflektans değerlerinin doğrudan kullanımının sınıflandırmada yeterli düzeyde ayırt edicilik sağlamadığı ve görüntü üzerinde yapılan derin öğrenme tabanlı sınıflandırma işlemlerinin beklenen performansı karşıladığı sonucuna ulaşılmıştır.

KAYNAKLAR DİZİNİ

- Atak, M., 2017, Buğday ve Türkiye Buğday Köy Çeşitleri, Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi, 22(2), 71-88, <https://dergipark.org.tr/en/download/article-file/375073>, erişim tarihi: 10.05.2021.
- Bellon-Maurel, V., McBratney, A., 2011, Near-infrared (NIR) and Mid-Infrared (MIR) Spectroscopic Techniques for Assessing the Amount of Carbon Stock in Soils–Critical Review and Research Perspectives, *Soil Biology and Biochemistry*, 43(7), 1398-1410.
- Chen, L., Yang, Z., Han, L., 2013, A Review on The Use of Near-Infrared Spectroscopy for Analyzing Feed Protein Materials, *Applied Spectroscopy Reviews*, 48(7), 509-522.
- Delwiche, S. R., Massie, D. R., 1996, Classification of Wheat by Visible and Near-Infrared Reflectance From Single Kernels.
- Ebrahimi, M. A., Khoshtaghaza, M. H., Minaei, S., Jamshidi, B., 2017, Vision-Based Pest Detection Based on SVM Classification Method, *Computers and Electronics in Agriculture*, 137, 52-58. doi:10.1016/j.compag.2017.03.016.
- Egesel, C., Kahrıman, F., 2012, Determination of Quality Parameters in Maize Grain by NIR Reflectance Spectroscopy, *Journal of Agricultural Sciences*, 18(1), 31-42.
- Ertugay, M. F., Başlar, M., 2011, Gıdaların Kalite Özelliklerinin Belirlenmesinde Yakın Kızılötesi (NIR) Spektroskopisi, *Gıda*, 36(1), 49-54, <https://dergipark.org.tr/en/download/article-file/78556>, erişim tarihi:10.05.2021.
- Ertugay, Z., 2010, Buğday, Un ve Ekmek Arasındaki Kalite İlişkileri, Atatürk Üniversitesi Ziraat Fakültesi Dergisi, 13(1-2), <https://dergipark.org.tr/en/download/article-file/35019>, erişim tarihi: 10.05.2021.
- Ferentinos, K., 2018, Deep Learning Models for Plant Disease Detection and Diagnosis, *Computers and Electronics in Agriculture*, 145, 311-318. doi:10.1016/j.compag.2018.01.009.
- Geron, A., 2019, Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems: O'Reilly Media.
- Gıda Tarım ve Hayvancılık Bakanlığı, 2015, Bitki Sağlığı Uygulama Programı, https://www.tarimorman.gov.tr/GKGM/Belgeler/Bitki%20Sa%C4%9Fl%C4%B1%C4%9F%C4%B1%20Hizmetleri/2015_BitkiSagligi.pdf, erişim tarihi: 11.05.2021.

KAYNAKLAR DİZİNİ (devam)

- Gorretta, N., Roger, J. M., Aubert, M., Bellon-Maurel, V., Campan, F., vd., 2006, Determining Vitreousness of Durum Wheat Kernels Using Near Infrared Hyperspectral Imaging, *Journal of near infrared spectroscopy*, 14(4), 231-239. doi:10.1255/jnirs.640.
- Guevara-Hernandez, F., Gil, J. G., 2011, A Machine Vision System for Classification of Wheat and Barley Grain Kernels, *Spanish Journal of Agricultural Research*(3), 672-680.
- Güleç, T. E., Sönmezoğlu, Ö. A., Yıldırım, A., 2010, Makarnalık Buğdaylarda Kalite ve Kaliteyi Etkileyen Faktörler.
- Johannes, A., Picon, A., Alvarez-Gila, A., Echazarra, J., Rodriguez-Vaamonde, vd., 2017, Automatic Plant Disease Diagnosis Using Mobile Capture Devices, Applied on A Wheat Use Case. *Computers and Electronics in Agriculture*, 138, 200-209. doi:10.1016/j.compag.2017.04.013.
- Kahrıman, F., Egesel, C. Ö., 2011, Farklı Ekmeklik Buğday Çeşitlerinin Agronomik ve Kalite Özellikleri Bakımından Değerlendirilmesi, *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 1(1), 22-35, <https://dergipark.org.tr/en/download/article-file/113873>, erişim tarihi: 12.05.202.
- Karaduman, Y., Belen, S., Olgun, M., Ceyhan, M., Kartal, Y., vd., 2020, Ülkesel Ekmeklik Buğday Alım Bareminde Ekmeklik Buğday Çeşitlerinin Ayrımı: Yapay Zeka Destekli Örüntü Tanıma Uygulamalarının Kullanılabilirliği.
- Kartal, Y., Özkan, K., 2019, Shape-Based Descriptor for Sunn Pest Damaged Wheat Kernel Detection. Paper presented at the 2019 27th Signal Processing and Communications Applications Conference (SIU).
- Lafargue, M. E., Feinberg, M., Daudin, J.-J., Rutledge, D. N., 2003, Detection of Heterogeneous Wheat Samples Using Near Infrared Spectroscopy, *Journal of Near Infrared Spectroscopy*, 11(2), 109-121. doi:10.1255/jnirs.359.
- Manickavasagan, A., Sathya, G., Jayas, D. S., 2008, Comparison of Illuminations to Identify Wheat Classes Using Monochrome Images, *Computers and Electronics in Agriculture*, 63(2), 237-244.
- Mishra, P., Herrero-Langreo, A., Barreiro, P., Roger, J. M., Diezma, B., vd., 2015, Detection and Quantification of Peanut Traces in Wheat Flour by Near Infrared Hyperspectral Imaging Spectroscopy Using Principal-Component Analysis, *Journal of near infrared spectroscopy*, 23(1), 15-22. doi:10.1255/jnirs.1141.

KAYNAKLAR DİZİNİ (devam)

- Moshou, D., Pantazi, X.-E., Kateris, D., Gravalos, I., 2014, Water Stress Detection Based on Optical Multisensor Fusion with a Least Squares Support Vector Machine Classifier, *Biosystems Engineering*, 117, 15-22. doi:10.1016/j.biosystemseng.2013.07.008.
- Müller, A. C., Guido, S., 2016, Introduction to Machine Learning with Python: a Guide for Data Scientists: " O'Reilly Media, Inc.".
- Özberk, F., Karagöz, A., Özberk, İ., Atlı, A., 2016, Buğday Genetik Kaynaklarından Yerel ve Kültür Çeşitlerine; Türkiye'de Buğday ve Ekmek. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 25(2), 218-233, <https://dergipark.org.tr/en/pub/tarbitderg/issue/26719/281346>, erişim tarihi: 11.05.2021.
- Özkan, K., Işık, Ş., Yavuz, B. T., 2019, Identification of wheat kernels by fusion of RGB, SWIR, and VNIR samples, *Journal of the Science of Food and Agriculture*, 99(11), 4977-4984.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., vd., 2011, Scikit-learn: Machine learning in Python, the *Journal of Machine Learning research*, 12, 2825-2830.
- Peng, J., Sun, D., Nevo, E., 2011, Wild Emmer Wheat, 'Triticum dicoccoides', Occupies a Pivotal Position in Wheat Domestication Process, *Australian Journal of Crop Science*, 5(9), 1127-1143.
- Pierna, J. F., Baeten, V., Dardenne, P., 2006, Screening of Compound Feeds Using NIR Hyperspectral Data, *Chemometrics and Intelligent Laboratory Systems*, 84(1-2), 114-118.
- Pierna, J. F., Vermeulen, P., Amand, O., Tossens, A., Dardenne, P., vd., 2012, NIR Hyperspectral Imaging Spectroscopy and Chemometrics for The Detection of Undesirable Substances in Food and Feed, *Chemometrics and Intelligent Laboratory Systems*, 117, 233-239.
- Pissard, A., Baeten, V., Romnee, J.-M., Dupont, P., Mouteau, A., vd., 2012, Classical and NIR Measurements of The Quality and Nutritional Parameters of Apples: a Methodological Study of Intra-Fruit Variability. *BASE*.
- Punn, M., Bhalla, N., 2013, Classification of Wheat Grains Using Machine Algorithms, *International Journal of Science and Research (IJSR)*, 2(8), 363-366.
- Ramos, P., Prieto, F. A., Montoya, E., Oliveros, C. E., 2017, Automatic Fruit Count on Coffee Branches Using Computer Vision, *Computers and Electronics in Agriculture*, 137, 9-22.

KAYNAKLAR DİZİNİ (devam)

- Ridgway, C., Chambers, J., Cowe, I. A., 1999, Detection of Grain Weevils Inside Single Wheat Kernels by a Very Near Infrared Two-Wavelength Model, *Journal of Near Infrared Spectroscopy*, 7(4), 213-221. doi:10.1255/jnirs.251.
- Ridgway, C., Davies, E., Chambers, J., Mason, D., Bateman, M., 2002, Rapid Machine Vision Method for the Detection of Insects and Other Particulate Bio-Contaminants of Bulk Grain in Transit.
- Sabancı, K., Kayabaşı, A., Toktaş, A., 2017, Computer Vision-Based Method For Classification of Wheat Grains Using Artificial Neural Network, *Journal of the Science of Food and Agriculture*, 97(8), 2588-2593. doi:10.1002/jsfa.8080.
- Şahin, M., Akçacık Göçmen, A., Aydoğan, S., Demir, B., Önmez, H., vd., 2013, Ekmeklik Buğday Ununda Ekmek Hacmi ile Bazı Fizikokimyasal ve Reolojik Özellikler Arasındaki İlişkilerin Tespiti, *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 22(1), 13-19.
- Şanal, T., 2018, Bazı Yerel Buğday Çeşitlerinin Kalite Parametreleri, <http://www.turktob.org.tr/dergi/makaleler/dergi23/38.pdf>, erişim tarihi: 12.05.2021.
- Sengupta, S., Lee, W. S., 2014, Identification and Determination of The Number of Immature Green Citrus Fruit in A Canopy Under Different Ambient Light Conditions, *Biosystems Engineering*, 117, 51-61. doi:10.1016/j.biosystemseng.2013.07.007.
- Shewry, P. R., Hey, S. J., 2015, The Contribution of Wheat to Human Diet and Health, *Food and Energy Security*, 4(3), 178-202. doi:10.1002/fes3.64.
- Singh, C., Jayas, D., Paliwal, J., White, N., 2009, Detection of Insect-Damaged Wheat Kernels Using Near-Infrared Hyperspectral Imaging. *Journal of Stored Products Research*, 45(3), 151-158.
- Tarım ve Orman Bakanlığı, 2020a, Buğday Alım Baremi, <https://www.tmo.gov.tr/Upload/Document/alim/2020/hubalimbaremi.pdf>, erişim tarihi: 15.05.2021.
- Tarım ve Orman Bakanlığı, 2020b, Buğday Ekim Bülteni, <https://www.tarimorman.gov.tr/BUGEM/Belgeler/B%C3%BCltenler/OCAK%202021/Bu%C4%9Fday%20Ocak%20B%C3%BClteni.pdf>, erişim tarihi: 15.05.2021.
- Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü, 2021, Tarım Ürünleri Piyasa Raporu, <https://arastirma.tarimorman.gov.tr/tepege/Menu/27/Tarim-Urunleri-Piyasalari>, erişim tarihi: 15.05.2021.

KAYNAKLAR DİZİNİ (devam)

Vermeulen, P., Pierna, J. F., Van Egmond, H., Zegers, J., Dardenne, P., vd., 2013, Validation and Transferability Study of a Method Based on Near-Infrared Hyperspectral Imaging for The Detection and Quantification of Ergot Bodies in Cereals, *Analytical and Bioanalytical Chemistry*, 405(24), 7765-7772.

Zayas, I., Flinn, P. W., 1998, Detection of Insects in Bulkwheat Samples with Machine Vision. *Transactions of the ASAE*, 41(3), 883.

