

Farklı Dalga Boylu Görüntülerle Buğday Sınıflandırılması

Duygu Zeynep Demirez Örs

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Haziran 2018

Wheat Classification with Different Wavelength Images

Duygu Zeynep Demirez Örs

MASTER OF SCIENCE THESIS

Department of Electrical and Electronics Engineering

June 2018

Farklı Dalga Boylu Görüntülerle Buğday Sınıflandırılması

Duygu Zeynep Demirez Örs

Eskişehir Osmangazi Üniversitesi
Fen Bilimleri Enstitüsü
Lisansüstü Yönetmeliği Uyarınca
Elektrik Elektronik Mühendisliği Anabilim Dalı
Telekomünikasyon Sinyal İşleme Bilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır

Danışman: Dr. Öğr. Üyesi Erol Seke

Bu tez TÜBİTAK 1001-Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı tarafından “116O576” no’ lu proje çerçevesinde desteklenmiştir.

Haziran 2018

ONAY

Elektrik Elektronik Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisi Duygu Zeynep Demirez Örs'ün YÜKSEK LİSANS tezi olarak hazırladığı “Farklı Dalga Boylu Görüntülerle Buğday Sınıflandırılması” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Erol Seke

İkinci Danışman : -

Yüksek Lisans Tez Savunma Jürisi:

Üye : Dr. Öğr. Üyesi Erol Seke

Üye : Dr. Öğr. Üyesi Helin Dutağacı

Üye : Dr. Öğr. Üyesi Muammer Akçay

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve
..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Hürriyet ERŞAHAN
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Dr. Öğr. Üyesi Erol Seke danışmanlığında hazırlamış olduğum “Farklı Dalga Boylu Görüntülerle Buğday 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. 04/06/2018

Duygu Zeynep Demirez Örs

ÖZET

Buğday çeşitlerinin ve kalitelerinin değerlendirmesini kolaylaştırmada, başarısız olabilecek uzman görüşüne yardımcı olmak için çeşitli görüntüleme araçları ve teknikleri kullanılagelmiştir. Uzmanın kararından kaynaklanabilecek riskleri en aza indirmek için, etkili bir sınıflandırma çerçevesi gereklidir. Bu doğrultuda hazırlanan tez çalışması, hiperspektral buğday resimlerinin derin öğrenmeye dayalı sınıflandırılması için bir makine öğrenme sistemi sunmaktadır. Çalışmada iki farklı yöntem uygulanmıştır. İlk çalışmada, Görünür Yakın Kızılötesi (VNIR) kamera ile elde edilen hiperspektral buğday görüntüleri AlexNet modeli ile sınıflandırılmaya çalışılmıştır. Kullanılan sistem önceden eğitilmiş bir Evrişimsel Sinir Ağı (CNN) olan AlexNet' in FC6 ve FC7 özelliklerine dayanmaktadır. Bu çalışmada, ince ayar yaklaşımı göz önünde bulundurulduğunda, AlexNet modelinin son başlığı çıkarılmış ve buğday çeşitlerinin etiketlerini belirlemek için Destek Vektör Makinesi (SVM) sınıflandırıcısı kullanılmıştır. Sistem performansını değerlendirmek için, VNIR buğday görüntü veri seti, numune başına 220 görüntü içeren 50 buğday türü kullanılarak oluşturulmuştur. Doğrusal SVM sınıflandırıcısı ile FC6 ve FC7 özelliklerinde, sırasıyla %99,9695 ve %99,9637'lik ortalama doğruluk oranları elde edilmiştir.

İkinci yöntemde ise, Görünür Işık (VL), VNIR ve Kısa Dalga boyu Kızılötesi (SWIR) görüntülemelerle birlikte geleneksel ve modern özellik çıkarma algoritmaları kullanılmıştır. BoW (Bag of Words) modeli geleneksel özellik çıkarma aracı ve CNN modeli modern özellik çıkarma aracı olarak ifade edilmiştir. Oy çokluğu kuralı, CNN ve BoW çerçevelerinin öngördüğü kararlar üzerine kurulmuştur. Oy çokluğu kuralıyla elde edilen doğruluk sonuçları, CNN ve BoW modeli için sırasıyla %99,94 ve %68,94 'tür. Deneysel sonuçlar, BoW özelliklerinin buğday taneleri gibi tekrarlanan doku modellerini temsil etmesi ve eşleştirmesi için uygun olmadığına işaret ederken, CNN özellikleri bu tür veri kümeleri için geleneksel yöntemlerden daha iyi performans sergileyebileceğini göstermektedir.

Anahtar kelimeler: Buğday, Hiperspektral Buğday Sınıflandırması, VNIR Görüntüleme, SWIR Görüntüleme, RGB Görüntüleme, Görüntü Füzyonu, Derin Öğrenme.

SUMMARY

To facilitate the quality assessment of wheat cultivars, diverse imaging tools and techniques have been applied in order to reduce and eliminate errors in expert decision, which can fail both in the identification of wheat cultivar's label and its quality. To minimize the risks caused by dependency on expert's decision, a promising identification framework is required to more effectively assess the wheat type. Accordingly, this thesis presents a machine learning system for deep learning based classification of hyperspectral wheat data. Two different methods have been applied in this context. In the beginning, hyperspectral wheat images obtained with Visible Near Infrared (VNIR) camera are classified using AlexNet model, a pre-trained Convolutional Neural Network (CNN). System relies on FC6 and FC7 features of the AlexNet. In this study, due to the fine-tuning approach considered, the last head of AlexNet model is omitted and the Support Vector Machine (SVM) classifier is employed to determine the labels of wheat kernels. In order to evaluate the system performance, a hyperspectral wheat image test dataset is constructed using VNIR of 50 wheat species with 220 images per specimen. Excellent classification results are achieved on the experiments with the newly created test dataset. Average accuracy rates of 99,9695% and 99,9637% are obtained with linear SVM classifiers, on FC6 and FC7 features, respectively.

In the second method, conventional and modern feature extraction algorithms, namely BoW and frameworks are tested on Visible Light (VL), VNIR and Short Wave Infrared (SWIR) images. A consensus rule is established on decisions predicted by CNN and BoW frameworks for wheat cultivar detection. The obtained accuracy results by consensus rule show that the we have achieved 99,94% and 68,94% through CNN and BoW frameworks, respectively. Experimental results suggest that the BoW features are not appropriate to represent and match texture patterns like repeated wheat kernels, whereas the CNN features always outperforms handcrafted features for all datasets.

Keywords: Wheat Kernel, Hyperspectral Wheat Classification, VNIR Imaging, SWIR Imaging, RGB Imaging, Fusion of Hyperspectral Images, Deep Learning.

TEŞEKKÜR

Tez konumun belirlenmesinde, tez sürecinde ve tezimin tamamlanmasında, yapılan araştırmalarda, karşılaştığım sorunlarda ve yönlendirmesinde, tezimin tamamlanmasında destek olan tez danışmanım Sayın Dr. Öğr. Üyesi Erol SEKE' ye teşekkür ederim.

Tezimin her aşamasında yardımlarını esirgemeyen, her türlü fikir, görüş, düşünce ve yönlendirmesiyle ilerlememe yardımcı olan değerli hocam Doç. Dr. Kemal ÖZKAN' a teşekkür ederim.

Tezimin tüm aşamasında bana her türlü desteği sağlayıp yardımcı olan, tezimin tamamlanmasında en büyük katkısı olan hocalarımdan biri olan, Araş. Gör. Şahin Işık'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 bu süreçte yanımda olan eşime teşekkür ederim.

116O576 numaralı proje kapsamında 1001 – Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı ile maddi destek sağlayan TÜBİTAK'a teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
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	13
3.1. Hiperspektral Görüntüleme.....	13
3.1.1. Kısa dalga kızılötesi kamera (Short wave infrared camera)	14
3.1.2. Yakın görünür kızılötesi ışık (Visible light infrared wave)	15
3.2. Görülebilir Işık Dalgaları	15
4. YAPILAN ÇALIŞMALAR YÖNTEM 1	19
4.1. VNIR Kamera ve Alexnet Modelinin Kullanılması	19
4.1.1. Derin öğrenme özeti: CNN özellikleri	19
4.2. Alexnet Modeli	20
4.3. Veri Seti	21
4.4. Deneysel Çalışmalar ve Performans Değerlendirme	23
4.5. Yöntem 1 Değerlendirme.....	26
5. YAPILAN ÇALIŞMALAR YÖNTEM 2	28
5.1. Konsensus Kuralına Dayalı Olarak Buğday Çeşitlerinin Sınıflandırılması	28
5.2. BoW Yöntemi: Geleneksel Özellikler ve Sınıflandırıcılar	30

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
5.3. CNN Çerçevesi: Derin Öğrenme Özellikleri	33
5.4. SWIR, VNIR ve RGB Füzyonu	34
5.5. Araçlar ve Parametreler	37
5.5.1. Özellik çıkarıcı araçlar	37
5.5.2. Sınıflandırıcılar	42
5.6. Deneysel Çalışma	46
5.6.1. Veri Seti.....	46
5.6.2. Deneyler hakkında ayrıntılar.....	47
5.6.3. BoW çerçevesinin değerlendirilmesi	48
5.6.4. CNN çerçevesinin değerlendirilmesi	51
5.6.5. CNN ve BoW çerçevelerinin karşılaştırılması	52
6. BULGULAR VE TARTIŞMA.....	55
7. SONUÇ VE ÖNERİLER.....	57
KAYNAKLAR DİZİNİ	59

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
3.1. Çalışmada kullanılmış olan SWIR kamera	14
3.2. Çalışmada kullanılmış olan VNIR kamera	15
3.3. Çalışmada kullanılmış olan halojen ampuller	16
4.1. AlexNet yapısının genel akışı.....	21
4.2. Buğday örneklerinden hiperspektral görüntüleme ile elde edilen veri seti	22
4.3. Görüntü yakalama düzeni. (a)Çizim düzeni, (b)Gerçek düzen	23
4.4. Test aşaması	24
5.1. Kelimeler çantası temelli imge betimleme.....	30
5.2. Buğday çeşidinin tanımlanması için önerilen önerilen sistemin genel süreci.....	32
5.3. CNN mimarilerine dayanan ikinci yöntemin gösterimi	34
5.4. RGB, SWIR, VNIR ve FUSION veri kümesine ilişkin bazı örnekler	35
5.5. Kırmızı, Yeşil, Mavi, VNIR ve SWIR dahil beş kanalın füzyonu için görselleştirme. 36	
5.6. Şekil tabanlı bir betimleyici çıkarmanın adımları.....	41
5.7. Destek Vektör Makineleri şematik gösterim	43
5.8. ANN yapısının şematik gösterimi	44
5.9. K-NN yapısının şematik gösterimi	45
5.10. Örnek bir çalışmada kullanılan buğday imgeleri	46
5.11. Görüntü yakalama sistemi.....	47
5.12. CNN ve BoW yöntemleri için Fscore ve doğruluk oranları.....	53

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
3.1. İki sınıflı bir örnekte karışıklık matrisi.....	17
4.1. FC6 ve FC7 özellikleri üzerindeki Linear ve Quadratic Kernel SVM skorları	25
5.1. 40 Farklı Sınıfa Ait Veri Seti.....	47
5.2. BoW Özelliklerinin Fusion Üzerinde Doğruluğu	49
5.3. BoW Özelliklerinin RGB Üzerinde Doğruluğu	49
5.4. BoW Özelliklerinin SWIR Üzerinde Doğruluğu	50
5.5. BoW Özelliklerinin VNIR Üzerinde Doğruluğu	50
5.6. CNN Özelliklerinin FUSION, RGB, SWIR, VNIR Üzerindeki Doğruluğu	52

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

Açıklama

AFB1	Aflatoksin B1
AUC	Area Under Curve (Eğri Altında Kalan Alan)
ANN	Artificial Neural networks (Yapay Sinir Ağları)
BOW	Bag of Words (Kelimer Çantası)
BPNN	Back-Propagation Neural Network (Standart Geri Yayılım Nöral Ağ)
CCD	Charge-Coupled Device (Yük-Bağlaşık Aygıt)
CNN	Convolutional Neural Network (Konvolüsyonel Sinir Ağ)
C-SIFT	Color / Scale Invariant Feature Transform (Renk/ Ölçekten Bağımsız Özellik Dönüşümü)
CWRS	Canada Western Red Spring (Kanada Batı Kırmızı Baharı)
CWAD	Canada Western Amber Durum (Kanada Batı Amber Durum)
CVA	Common Vector Approach (Ortak Vektör Yaklaşımı)
DK	Diskriminant Analizi
DPLS	Discriminant Partial Least Square (Diskriminant En Küçük Kareler)
DSIFT	Dense Scale Invariant Feature Transform (Yoğun Ölçekten Bağımsız Özellik Dönüşümü)
FDK	Fusarium Hasarlı Taneler
FN	False Negative (Yanlış Negatif)
FP	False Positive (Yanlış Pozitif)
FT	Fourier Transform (Fourier Dönüşümü)
GLCM	Grey Level Cooccurrence Matrices (Gri Seviye Cooccurrence Matrisi)
GLRM	Grey Level Run Length Matrices (Gri Seviye Çalışma Uzunluğu Matrisi)
HOG	Histogram of Oriented Gradien (Yönlü Gradyan Histogramı)

SİMGELER VE KISALTMALAR DİZİNİ (devam)

Kısaltmalar

Açıklama

HSI	Hyperspectral Imaging (Hiperpektral
inGaAs	Indium Gallium Rsenide Sensörleri
KNN	K-Nearest Neighbors (K-En Yakın Komşuları)
LED	Light Emitting Diode (Işık Yayan Diyot)
LDA	Lineer Diskriminant Analiz
LSP	Local Similarity Patterns (Yerel Benzerlik Modelleri)
LSN	Local Similarity Number (Yerel Benzerlik Sayıları)
MPLS	Multiway Partial Least Square (Çok Yönlü Kısmi En Küçük Kareler)
MLR	Machine Learning in R (R’de Makine Öğrenmesi)
NIR	Near Infrared (Yakın Kızılötesi)
NIRS	Near Infrared Spectrum (Yakın Kızılötesi Spektroskopi)
NB	Naive Bayes (Naive Bayes)
OTA	Oktatoksin A
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
PLS-DA	Kısmi en küçük kareler diskriminant analizi
QDA	Quadratic Diskriminant Analysis (Kuadratik Diskriminant Analizi)
ROI	Region of Interest (İlgi Alanı)
RGB	Red/Green/Blue
SIFT	Scale Invariant Feature Transform (Ölçekten Bağımsız Özellik Dönüşümü)
SVM	Support Vector Machine (Destek Vektör Makineleri)
SBFD	Shape Based Fourier Transform (Şekil Tabanlı Fourier Dönüşümü)
SWIR	Short Wave InfrRED (Kısa Kızılötesi)
TP	True Positive (Doğru Pozitif)
TN	True Negative (Doğru Negatif)
VIS	Visible Infrared Spectrum (Görünür Kızılötesi spektroskopi)

SİMGELER VE KISALTMALAR DİZİNİ (devam)**Kısaltmalar****Açıklama**

VNIR	Visible Near Infrared (Yakın Görünür Kızılötesi)
VGG-16	Görsel Geometri Grubu-16
VGG19	Görsel Geometri Grubu-19
YSA	Yapay Sinir Ağları



1. GİRİŞ VE AMAÇ

Tarımın insan için gerekli besinleri sağlama görevi vardır. Özellikle buğday, insan beslenmesinde ve ekim alanlarında çok önemli bir bitkidir ve üretimi nüfus artışına paraleldir. Üretilen buğdayın miktarı hızla büyüyen nüfusta büyük bir öneme sahiptir. Buğday üretimi Türkiye'nin ve dünyanın hemen her yerinde yapılır. Buğday, dünyada hububat ürünlerinin en eski ve en önemlilerinden biridir ve aynı zamanda en fazla üretilen ve tüketilen hububat çeşididir. Buğday bitkilerinin geniş uyum yeteneğine sahip olması ve çeşitli iklim ve toprak şartlarına uyum sağlaması sebebiyle buğday insan beslenmesi için gerekli olan kültür bitkileri arasında ekiliş ve üretim bakımından birinci sırada yer almaktadır. Ayrıca buğday tohumu, uygun besin değeri, depolama ve işleme kolaylığı nedeniyle yaklaşık 50 ülkenin temel besindir. Verimi yüksek ve tarımı kolaydır. Buğday başta unlu mamuller olmak üzere birçok gıda ve sanayi sektöründe kullanılmaktadır bu sebeple buğday üretiminin azalması söz konusu olduğunda mamullerin miktarları azalacağı ve fiyatları yükseleceği için bu durumdan herkes etkilenecektir. Bu yüzden hem dünyada hem de ülkemizde buğday üretimi ve depolanması büyük bir öneme sahiptir. Ülkemizde buğday üretimi tüketimden fazladır. Yaklaşık 9,4 milyon hektarlık buğday ekilmektedir. Türkiye'nin buğday tüketimi yılda yaklaşık 19-21 milyon tondur. (Gubretas.com.tr, 2018) İklim şartlarına bağlı olarak üretimde dalgalanmalar olabilir. Buğday tarımında birim alandan yüksek ve kaliteli ürün alınması, üreticilerin iyi toprak hazırlığı, mütecanis ekim, bilinçli gübreleme, yabancı otlar, zararlılar ve hastalıklar ile zamanında mücadelelerine bağlıdır.

Türkiye'de buğdayın ekim alanı yaklaşık 9,4 milyon hektar, üretim ise yaklaşık 20 milyon ton olarak gerçekleşmekte olup, birim alandan alınan ortalama verim de yaklaşık 230 kg/da'dır. Ülkemizde kişi başı ortalama yıllık 250 kg buğday tüketilmekte, dolayısıyla yaklaşık 80 milyon nüfus için 20 milyon ton buğday üretiminin yapılması gerekmektedir. Yine bu üretimi gerçekleştirmek amacıyla her yıl yaklaşık 9,5 milyon hektarlık alan için dekara 20 kg tohumluktan yaklaşık 2 milyon ton tohum gerekmektedir. Yine Türkiye'de buğday üretimi çoğunlukla kuru tarıma dayanmakta ve ortalama üretilen 20 milyon ton buğday üretiminin 10 milyon tonu ekmek yapımında, 1 milyon tonu ise diğer unlu mamuller yapımında kullanılmaktadır. Ülkemizde günlük kalori ihtiyacının yaklaşık

%53'ünün buğdaydan karşılanması ve kişi başı yıllık un tüketiminin yaklaşık 170 kg civarında olması nedeniyle buğday, stratejik ürün konumdadır.

Buğday üretiminde en önemli faktörlerden birisi buğday bitkisinin kalite düzeyidir. Buğday tanelerinin kalitesi, genetik ya da çevresel faktörlerden etkilenmektedir. Kaliteli bir üretim elde edebilmek için yalnızca buğday bitkisinin kalitesi de yeterli olmamaktadır. Buğday tanelerinin kalitesi, genetik ya da çevresel faktörlerden etkilenmektedir. Yıllardır göz ardı edilen bu durum, büyük maddi kayıplara neden olmaktadır. Buğday kalitesi hem çiftçiler, hem de sanayiciler için önemlidir. Bunun için üreticilerin kaliteli üretim yapmasını teşvik edecek uygulamaların ve desteklerin oluşturulması gerekmektedir. Üreticilerin dünya buğday ticaretinde söz sahibi olabilmesi dünya standartlarında kaliteli buğday üretimi, doğru sınıflandırma ve doğru fiyat politikaları ile gerçekleşir. Tohumluk değerini düşüren etkenlerle de kalite oranı düşmektedir. Aynı zamanda tohumluk değerine olumsuz etki yapan aynı veya başka çeşit tohumların karışması, süne ve kımıl zararı, yabancı madde, iyi temizlememe, uygunsuz depolama şartları gibi faktörler tohumluk kalitesini düşürmektedir. Çeşit karışıklığı ise tohumluk değerini düşüren diğer bir etkidir. 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. Buğday çeşidi ne kadar hızlı ve doğru tanınırsa üretilen buğdayın kalitesi de ona göre belirlenir. Bu sebeple buğdayın tanınması için güvenilir yöntemler geliştirilmelidir.

Buğday alım satımı sırasında buğdayın cinsinin ve kalitesinin belirlenmesi, fiyat tespiti buğday uzmanları tarafından belirlenmektedir. Böylece insan faktörüne duyulan bağımlılık artmaktadır. Ancak farklı uzmanlar aynı buğday çeşidi için farklı fiyatlar verebilmektedir. Kaliteli buğday üretiminde, bilgiye, eğitilmiş personele, teknolojilerin yeterli kullanımına ve yeni teknolojiye erişimin önemi fazladır. Bu nedenle ulusal ve uluslararası trendler göz önünde bulundurularak yeni, üretken, kaliteli, dayanıklı ve ekonomik çeşitler geliştirilmeli ve tüketiciye aktarılmalıdır. Buna bağlı olarak, gelişen teknolojiyle daha objektif kalite yöntemleri denenmeye başlamış ve bu yeni teknolojilere göre buğday çeşitlerinin belirlenmesinin gerekliliği ortaya çıkmıştır. Kaliteli üretim için sadece buğday bitkisinin kalitesi yeterli değildir. Kaliteyi azaltan başka faktörler vardır.

Bunlardan en önemlilerinden biri çeşitlerin karışımıdır. Başka bir sınıfa ait buğdayın karıştırılması, buğdayın çekirdek değerini azaltabilir. Burada sınıflandırmanın önemi tekrar ortaya çıkmaktadır. Buğday çeşitlerinin hızlı ve doğru bir şekilde belirlenmesi, üretilen buğdayın kalitesini belirlemede etkilidir. Bu nedenle buğday çeşitlerinin tanımlanması ve sınıflandırılması için güvenilir yöntemler geliştirilmelidir. Geçmiş yıllardan bu yana buğdayı sınıflandırabilmek, kalite, hastalık ve yabancı maddeleri belirlemek için dijital görüntüleme ile sağlanan hızlı ve tahribatsız analiz kabiliyetleri ile farklı görüntüleme teknikleri yapılmıştır. Günümüzde, sınıflandırma ve tanımlama görevlerinde hiperspektral görüntüleme kullanımı yaygınlaşmaktadır. Hiperspektral görüntüler (HSI), insanlar tarafından görülen dalga boylarından başka elektromanyetik spektrumdaki çeşitli bölgelerdeki görüntüleri yakalayan özel kameralar tarafından üretilir. İnsan gözü ~ 400 ile ~ 700 nm arasındaki dalga boyu aralığını görebilir. Hiperspektral görüntüleme, bu aralıkların diğer dalga boyundaki görüntülerle birleştirilmesiyle elde edilen görüntülerin analizini sağlar. Farklı dalga boylarına sahip buğday görüntüleri, protein, gluten ve nem değerinin, erdemlilik ve tane verimi vb. tahminleri için çeşitli yöntem ve sınıflamalar yoluyla araştırmaya tabi tutulmuştur.

Örüntü tanıma yoluyla tarım ürünlerinin çeşidini, kalitesini, olgunluğunu tespit etme çalışmalarının kısa olmayan bir geçmişi vardır. Dijital RGB görüntülemenin yaygınlaşması ve günümüzde de multispektral ve hiperspektral kamera teknolojisinin gelişmesiyle, infrared bandından ultraviyole bandına kadar olan spektruma kadar geniş bir bantta yer alan elektromanyetik dalgalar ölçülebilir hale gelmiştir. Bu da örüntü tanıma yoluyla objeleri sınıflandırmayı yüksek bir doğruluk oranıyla yapılabilir hale getirmiştir. İlk yapılan çalışmalarda ağırlıklı olarak RGB görüntüleme yani görülebilir tayfi ölçerek ve bu yolla öznitelik çıkarımıyla sınıflandırma çalışmaları literatürde daha yaygındır. Ancak RGB görüntülemekten elde edilebilecek bilgiler sadece görünür ışık tayfindan gelen veriler olup, özellikle gıda sınıflandırma çalışmalarında diğer dalga boyları da önemlidir. 700-2500 nm dalga boyu aralığındaki elektromanyetik radyasyonun absorpsiyonu temeline dayanan, son zamanlarda gıda bileşenlerinin analizinde giderek yaygınlaşan, numuneyi tahrip etmeyen yöntemler hızlı bir alternatif teknoloji olarak karşımıza çıkmaktadır. Bu teknik, gıdalardaki çeşitli bileşenlerin nicel (kantitatif) analizlerinde kullanılmaktadır. Bu tür görüntülemeler diğer geleneksel yöntemlerle karşılaştırıldığında; analizlerin yapılması sırasında kimyasal madde kullanımına gerek olmaması, dolayısıyla analiz maliyetinin

düşük olması, birçok bileşenin eş zamanlı ve hızlı analizi ve analiz edildikten sonra yapılacak olan diğer analizler için numunenin tekrar kullanılabilirliği ve az miktarda örnek ihtiyacının olması gibi çeşitli üstünlüklere sahiptir.



2. LİTERATÜR ARAŞTIRMASI

Farklı buğday sınıfları tahıl endüstrisinde zorluklara sebep olmaktadır. Bu zorlukları biraz daha olsa ortadan kaldırabilmek ve buğday çeşitlerini sınıflandırabilmek için Miralbés vd. (2008) NIR spektrometresini ve kemometriyi birlikte kullanmıştır. Farklı buğday çeşitlerinden toplamda 249 adet buğday örnek alınmıştır. 400-2500 nm arasındaki dalga boyu ve yöntem olarak da Temel bileşenler analizi (PCA) ile Mahalanobis (GH) kullanılmıştır. Buğday çeşitleri kalibrasyon örneği için %99.5 doğrulukla tanınmıştır ve bu başarı oranı doğrulama örneği seti için ise %94 tür.

Bu doğrultuda başka çalışmalar da yapılmıştır. Bunlara örnek olarak R. Choudhary vd. (2008) 'nin çalışmasını verebiliriz. Kanada Batı Kırmızı Bahar (CWRS) buğdayı, Kanada Batı Amber Durum (CWAD) buğday, arpa, yulaf ve çavdarın çekirdeklerinin görüntüleri bir alan tarama kamerası kullanılarak elde etmişlerdir. Bu görüntülerden 51 morfolojik özellik, 93 renk özelliği, 56 dokusal özellik ve 135 dalgacık özelliği çıkarmışlardır. Tüm morfolojik, renk, dokusal ve dalgacık özelliklerini birleştiren Lineer Diskriminant sınıflandırıcıyı (LDA) CWRS buğdayında kullanmışlar ve %99.4 sınıflandırma doğruluğu ile en iyi sınıflandırmayı elde etmişlerdir. Ardından çavdar, arpa, yulaf ve CWAD buğdayı için sırasıyla %99,3, %98.6, %98.5 ve %89.4 izlemiştir. Bu çalışmanın sahipleri diğer çalışmalarında ise (Choudhary vd. 2009), Kızılötesi hiperspektral (VNIR) görüntüleme yöntemini kullanarak 960-1700 nm dalga boyu aralığında 10 nm aralıklı elde ettikleri hiperspektral görüntüleri Wavelet texture analizinde kullanarak Batı Kanada buğdaylarını sınıflandırmaya çalışmışlardır. Lineer Diskriminant analiz (LDA) temel alınarak en iyi 100 özellik seçilmiş ve buğday çeşitlerinin sınıflandırılması için kullanılmıştır. Bu özellikler kullanılarak, sınıflandırma için doğrusal ve kuadratik istatistiksel sınıflandırıcılar ve standart bir geri yayılım nöral ağ (BPNN) sınıflandırıcısı kullanılmıştır. Diğer yaklaşımlarında ise, hiperküplerden elde edilen temel bileşen (PC) skor görüntülerini, dalgacık analizi ve sınıflaması için kullanılmışlardır. En iyi 90 özellik LDA sınıflandırıcıda kullanıldığında, 8 sınıfın ortalama en yüksek sınıflandırma doğruluğu %99.1'dir. Top 70 özellik için BPNN kullanıldığında ise başarı oranı %92.1' dir. Hiperspektral görüntülemeden elde edilen wavelet texture özellikleri kullanıldığında ise en yüksek başarı oranı %79.9' dur.

Buğday sınıfları dış görünüş bakımından benzer görünseler de kimyasal yapıları farklıdır ve bu da buğdayın kalitesini belirlemektedir. Bu yüzden S. Mahesh vd. (2008) Kanada'daki buğday sınıflarını daha doğru bir şekilde ayırabilmek için çalışmalarında dalga boyu 960-1700 nm arasında değişen yakın kızılötesi spektrometresi (NIR) kullanmışlardır. NIR kamera kullanarak numuneler 10 nm aralıklarla taramış ve lineer diskriminat analiz yöntemi (LDA) ve Quadratic Diskriminat Analiz yöntemleri (QDA) uygulamışlardır. Tüm bu yöntemlere dayanarak elde edilen sınıflandırma işleminde %86 başarıya ulaştıklarını bildirmişlerdir.

Böcek hasarı buğdayın kalitesini etkileyen olumsuz faktörlerden birisidir. C. Singh vd. (2009) çalışmalarında böcek hasarına uğramış olan buğdayları near-infrared (NIR) hyperspektral görüntüleme tekniği ile araştırmışlardır 1000-1600 nm dalga boyu aralığını kullanmışlardır. Bu görüntülerden 6 tane istatistiksel ve 10 tane histogram özelliği çıkarılmıştır ve sınıflandırmada istatistiksel ayırıcı sınıflandırıcılar (doğrusal, kuadratik ve Mahalanobis) kullanılmışlardır. Doğrusal ayırıcı ve kuadratik diskriminant analizi sınıflandırıcıları ile sağlıklı ve böcek hasarına uğramış buğday çekirdeği %85-100 oranında doğru sınıflandırılmıştır.

Hiperspektral görüntüleme yöntemini kullanıldığı diğer bir çalışma ise Xing vd. (2009)' nin çalışmasıdır. Yazılarında, tek tek buğday tanelerinin a-amilaz aktivitesini tahmin etmek için bir SWIR hiperspektral görüntüleme sistemi (1000-2500 nm) kullanmışlardır. Kanada Batı Kırmızı Baharı (CWRS) ve Kanada Batı Amber Durum (CWAD) buğdaylarını kullanmışlardır. CWRS çekirdeklerinin yüksek a-amilaz aktivitesi seviyesi ile düşük a-amilaz aktivitesi olanlardan %80'in üzerinde bir doğruluk sağlaması için bir sınıflandırma yöntemi önerilmiştir. Diğer çalışmalarında ise (J. Xing S. S., 2010) görünür yakın kızılötesi (VNIR) kamera kullanarak CWRS buğday çeşidinin görüntülerini elde etmişlerdir. Temel Bileşenler Analizi (PCA) ile buğdayın farklı kalitesini ayırt etmeye katkıda bulunan dört dalga boyunu tanımlamışlardır. Hem spektral hem de uzamsal özellikleri birleştiren bir sınıflandırma prosedürü kullanılarak, ses çekirdeklerinin %100'ünü, filizlenen tanelerin yaklaşık %94'ünü ve ağır filizlenen tanelerin %98'ini doğru şekilde sınıflandırılmıştır.

Botsalı vd. (2010) ise bir buğday çeşidinin camsı ve camsı olmayan tanelerini masaüstü tarayıcıdan elde ettikleri görüntülerden her bir taneye ait histogram kullanarak Yapay Sinir Ağları (YSA) ile sınıflandırmaya çalışmışlardır. İki set uygulamışlardır. Her bir sette 50 camsı ve 50 camsı olmayan 100 adet buğday bulunmaktadır. Sınıflandırma işleminde ortalama test başarısını %97,5 olarak elde etmişlerdir.

NIR görüntüleme tekniğinin kullanıldığı diğer bir çalışma ise Singh vd. (2010)'nin çalışmasıdır. Bunun yanında alan tarama renkli kamera da kullanmışlardır. Bu kameralarla sağlıklı ve orta hasarlı buğdayı sınıflandırmaya çalışmışlardır. Altı istatistiksel özelliğin (maksimum, minimum, ortalama, medyan, standart sapma ve varyans) ve hiperspektral verilerin önemli dalga boyu görüntülerinden histogram özelliklerini çıkarmışlardır ve üç istatistiksel sınıflandırıcıya (doğrusal, kuadratik ve Mahalanobis) girdi olarak vermişlerdir. NIR hiperspektral görüntü özellikleri, en iyi 10 renkli görüntü özellikleriyle birleştğinde, sağlıklı ve orta dereceli buğday tanelerinin sınıflandırılmasında %95.3-99.3 arasında en yüksek ortalama doğruluk elde etmişlerdir.

Shahin vd. (2011) Kanada buğday örneklerinde fusarium hasarlı tanelerin (FDK) saptanması için VNIR (400-1000 nm) dalga boyu aralığında bir hiperspektral görüntüleme sisteminden faydalanmışlardır. PCA ve LDA kullanmışlardır. Bir LDA modeli, buğday tanelerini ses ve FDK kategorilerine, %92 veya daha iyi bir genel doğrulukla sınıflandırmışlardır.

Mutlu vd. (2011) tarafından yapılan çalışmada yakın kızılötesi kamera yani NIR (400–2,498 nm) ve yapay sinir ağları yöntemi kullanılarak protein, rutubet, Zeleny sedimantasyon, farinograf su absorpsiyonu gibi parametreler kullanılarak unun kalitesi belirlenmeye çalışılmıştır. Bunu uygulayabilmek için Türkiye' nin 79 farklı bölgesinde yetiştirilen buğday çeşitlerinden un örnekleri almışlardır ve bunları hem kimyasal olarak hem de NIR spektrometre cihazında analiz etmişlerdir. Bu analizi yaparken ANN yapay sinir ağları yönetimini kullanmışlardır. Bu yönetimin kullanılması ile birlikte nem, protein, alveograph P, P / G, farinografik su emme ve Zeleny sedimantasyonunun yüksek doğrulukla başarıyla tahmin edilebileceğini belirtmişlerdir. Bu sonuçlara dayanarak buğday unu kalitesini tahmin edebilmek için ANN ile birlikte NIR kameranın kullanılabileceğini bildirmişlerdir.

Hernandez ve Gil (2011) çalışmalarında buğday ve arpa tanelerinin sınıflandırılması için makine görme sistemi kullandılar. Bu sınıflandırma nesneleri iki sınıfa ayrılır. Sınıflandırma eğitim ve test aşamasından oluşur. Test aşamasında nesne sınıflandırması, diskriminant analizi (DK) ve K-en yakın komşuluk (K-NN) metotları kullanılmıştır. Eğitim için 10'ar tane buğday ve arpa tane resmi kullanıldı. Bu resimlerin her biri yaklaşık 60 adet buğday ve arpa tanesi içeriyordu. Toplamda test için 545 tane buğday ve arpa kullanıldı. Bu resimler Jpeg formatında ve RGB alanı üzerinde ve 5 megapiksel çözünürlüktedir ($2,560 \times 1,920$ piksel). Tahıllardan 99 özellik çıkarılmıştır. Bunların listesi şöyledir: 21 morfolojik özellik, 6 renk özelliği, 72 doku özelliği. Normalizasyon ve bu özellikler kullanılarak elde edilen sınıflandırma sonucu yaklaşık olarak %99 bir başarı elde edilmiştir.

Singh vd. (2012) diğer çalışmalarında ise 700–1100 nm dalga boyu aralığında kısa dalga boyu yakın kızıl ötesi hiperspektral görüntüleme sistemi kullanmışlardır. Sağlıklı ve fungal-hasarlı buğday taneleri kullanmışlardır. Birinci ana bileşenin en yüksek faktör yüklemesine karşılık gelen 870 nm dalga boyunu önemli kabul edip, 870 nm dalga boyu görüntüsünden elde edilen istatistiksel ve histogram özellikleri seçip bunları istatistiksel diskriminant sınıflandırıcılara (doğrusal, kuadratik ve Mahalanobis) girdi olarak kullanmışlardır. Renkli görüntülerden toplam 179 özellik (123 renk ve 56 dokusal) çıkarmışlardır. Doğrusal diskriminant analiz sınıflandırıcısı ile birlikte hiperspektral görüntü özelliklerini ve renk görüntülerinden ve dokusal özelliklerinden seçilen ilk on özelliği kullanarak sağlıklı ve mantarla enfekte olmuş buğday tanelerini %97.3–100.0 oranında doğru sınıflandırmışlardır.

Pourreza vd. (2012) çalışmalarında dokuz yaygın İran buğday tohumu çeşidinin belirlenmesi için gri seviye görüntüler elde etmiştir ve bu tohum görüntülerinin çeşitli dokusal özellik gruplarını incelenmişlerdir. Bütün olarak, toplu buğday tohumlarının (her çeşidin 120 görüntüsü) 1080 gri ölçekli görüntülerini kararlı bir aydınlatma koşulunda (floresan halka ışığı) elde etmişlerdir. Gri düzeyden, GLCM (gri seviye cooccurrence matrisi), GLRM (gri seviye çalışma uzunluğu matrisi), LBP (yerel ikili desenler), LSP (yerel benzerlik modelleri) ve LSN (yerel benzerlik sayıları) matrislerinden toplamda 131 metinsel özellik çıkarılmıştır. En iyi seçilmiş özellikleri kullanılarak sınıflandırma için

LDA (lineer diskriminant analizi) sınıflandırıcıyı kullanmışlardır. Sınıflandırıcıda özelliklerden en iyi 50'si kullanıldığında %98.15 doğruluk elde etmişlerdir.

Derin öğrenmenin kullanıldığı çalışmalardan biri ise Krizhevsky vd. (2012)' in çalışmalarıdır. Araştırmalarında ImageNet LSVRC-2010'deki 1,3 milyon yüksek çözünürlüklü resimleri 1000 farklı sınıfa ayırmak için büyük, derin bir konvolüsyonal ağ kullanmışlardır. Sinir ağı 60 milyon parametre ve 650,000 nörona, 5 evrimsel katman ve 1000-yollu softmax katmanına sahiptir. Top 1 ve Top 5 test veri setlerinde %37,5 ve %17,0 hata oranları elde etmişlerdir.

(Soto-Cámara vd. (2012) çalışmalarında Güney İspanya'nın 4 farklı bölgesinde farklı koşullarda yetiştirilen buğdaylardan 213 tane makarnalık buğday örneği almışlardır ve bu çalışmada mantar tedavili buğday örneklerinin tespitini amaçlamışlardır. VIS+NIR (400nm–2500nm) ve NIR (1100nm–2500nm) görüntüleme teknikleri ile görüntülemeleri yapılmıştır. Bunlardan elde edilen veriler üzerinde modifiye edilmiş kısmi en küçük kareler (MPLS) yöntemi kullanılmıştır. Bu yöntemle birlikte %84 oranında başarı elde ettiklerini belirtmişlerdir. Çalışmalarında elde ettikleri sonuçlara dayanarak NIR spektrometresinin mantar tedavili buğdayları ayırt etmede başarılı olacağını öne sürmüşlerdir.

Serranti vd. (2013) çalışmalarında 3 farklı buğday çeşidi kullanmışlardır. Bunlar vitroz, sarı çilek ve Fusarium hasarlı buğday çeşitleridir. Bu üç numune spektral görüntüleme tekniği ile görüntülenmiştir. Görüntülemelerde spektral aralığı 1000-1700 nm arasında değişen NIR spektral kamera kullanılmıştır. 3 örnekten her biri 20-30 tane aynı tip tahılı içeren 3 paralel çizgiye ayrılmışlardır. Bunları sınıflandırmak için bir model geliştirmişlerdir. Ana bileşen analizi (PCA) uygulamışlardır. Elde edilen sonuçlara göre en düşük yanlış sınıflandırma %1 den az olacak şekilde vitroz sınıfına aittir. Sarı çilek sonuçları fusarium hasarlıya göre biraz daha iyi olsa da ikisinde de sınıflandırma yapılırken elde edilen hata düşüktür. Bu sonuçlara dayanarak sınıflandırmada başarılı sonuçlar elde ettiklerini belirtmişlerdir.

González-Martín vd. (2014) Şili'nin farklı bölgelerinde üretilen buğday tohumlarını ve un örneklerini kullanarak bunları sınıflandırmayı ve coğrafi kökenlerini tahmin etmeyi amaçlamışlardır. Yakın kızıl ötesi spektroskopi (NIRS) ile kemometrik

yöntemleri birleştirmişlerdir. NIR spektropisinden elde edilen verileri model tanıma yönteminde kullanmışlardır. Bu yöntemin kısmi en küçük kareler (DPLS) olduğunu belirtmişlerdir. Bu yöntem ile buğdayları sınıflandırmada %76 başarı elde etmişlerdir. Un örneklerini ise coğrafi kökenlerine göre %90-%96 arasında doğru bir şekilde sınıflandırmışlardır. Bu sonuçlar, buğday tanelerini ve un örneklerini NIR spektrometri ve kemometrik yöntemlerle başarıyla sınıflandırabildiklerini göstermektedir.

Ronge vd. (2014) çalışmalarında, buğday türlerinin görüntülerinin farklı doku özelliklerinin incelenmesiyle, en etkili doku özellikleri grubundaki buğday tohumu çeşitlerinin ne kadar etkili sınıflandırılacağını araştırmışlardır. Hepsini dahil olmak üzere, standart hale getirilmiş aydınlatma koşulu altında (floresan ışık), 60 tane gri seviyede toplu buğday tohumu türü fotoğrafı çekilmiştir. LBP, LSN, LSP, gri seviye, GLRM (gri seviye çalışma uzunluğu matrisi) ve GLCM (gri seviye eş oluşum matrisi) nden 131 dokusal özellik çıkarılmıştır. Önemli olan 60 özellik alınarak ve YSA kullanılarak sınıflandırmada %76 doğruluk elde edilmiştir.

SWIR görüntüleme tekniğinden Kandpal vd. (2015) de faydalanmışlardır. Buğdaydan farklı olarak mısır çekirdeklerinde aflatoksin kontaminasyonunu tespit etmeye çalışmışlardır. Mısır örneklerine dört farklı aflatoksin B1 (AFB1) konsantrasyonu (10, 100, 500 ve 1000 mg / kg) inoküle etmişlerdir ve kontrol örnekleri ise bir PBS çözeltisi ile yüzey dezenfekte etmişlerdir. Enfekte olmuş ve kontrol numuneleri, 1100-1700 nm spektral aralığı üzerinde bir SWIR hiperspektral sistemi ile taramışlardır. Kontrol ve enfekte çekirdeklerin sınıflandırılması için kısmi en küçük kareler diskriminant analizi (PLS-DA) modeli geliştirilmiş ve geliştirilen modelden elde edilen en yüksek genel sınıflama doğruluğu %96,9 elde etmişlerdir.

Jaillais vd. (2015) buğday tohumunun kalitesini ve buğdaydaki mantar zararını tespit etmek için çalışmışlardır. Bunun için multispektral görüntüleme ve kemometriye dayalı bir yöntem geliştirmişlerdir. Ana bileşen analizi (PCA) ve çoklu doğrusal regresyon (MLR) yöntemlerini uygulamışlardır. 360 ile 950 nm arasında eşit aralıklarla algılama yapan CCD kamera ve aydınlatmak için de 8 farklı dalga boyunda ışınım yapan bir LED ile birlikte bir sistem önermişlerdir. Sadece görünür ışıktaki (CCD kamera) veri elde edilmiştir.

NIR görüntüleme tekniğinin kullanıldığı bir diğer çalışma ise Ravikanth vd. (2015) 'in çalışmasıdır. Spektral ön işleme tekniğinin en iyi kombinasyonlarını tanımlamak için üç deney yapmışlardır. Amaçları yedi yabancı madde türü (arpa, kanola, mısır, keten tohumu, yulaf, çavdar ve soya fasulyesi), altı adet rıhtı türü (kırık buğday taneleri, karabuğday, saman, buğday spikeletleri, taşlar ve yabancı yulaf) ve iki hayvan dışkı türü (geyik ve tavşan pisliği) gibi Kanada Batı Kırmızı Baharı (CWRS) buğdayındaki farklı kirletici sınıfları sınıflandırmaktır. Buğdaydaki yabancı madde türlerinin sınıflandırılması için NIR yansıma spektrumları ile birlikte SVM, NB ve k-NN sınıflandırıcılar kullanıldığında sırasıyla, 79.0 ± 0.8 , 60.9 ± 0.8 ve 90.1 ± 0.6 oranında doğruluk elde edilmiştir.

Senthilkumar vd. (2015) çalışmalarında fungal enfeksiyonun farklı evrelerini tespit etmek için yakın kızıl ötesi (NIR) hiperspektral görüntüleme sistemi kullanmışlardır. Önemli dalga boyları olarak 1100, 1130, 1250 ve 1300 nm dalga boylarını belirlenmişlerdir ve istatistiksel diskriminant analizinde kullanmışlardır. İkili, iki sınıf ve altı sınıf sınıflandırma modellerini mantar enfekte olmuş örneklerin sağlıklı ve farklı aşamalarını sınıflandırmak için geliştirilmişlerdir. Lineer, kuadratik ve Mahalanobis diskriminant sınıflandırıcılarını, *A. glaucus*'un beş aşamasını ve *Penicillium* spp ile enfekte olmuş kanola tohumlarının beş aşamasını sınıflandırmak için kullanmışlardır. Tüm üç sınıflandırıcı, sağlıklı ve mantar enfekte kanola tohumlarını, sağlıklı kanola tohumları için %95'ten fazla ve *A. glaucus* ve *Penicillium* spp ile enfekte edilmiş kanola tohumlarının başlangıç safhaları için %90'dan fazla bir sınıflandırma doğruluğu ile sınıflandırmışlardır.

HSI tekniğinin kullanıldığı diğer bir çalışma ise Barbedo vd. (2015)' nın çalışmalarıdır. Buğdayda *Fusarium* başak yanıklığının otomatik tespiti için bir algoritma önermişlerdir ve NIR kamera kullanmışlardır. Geliştirmiş oldukları algoritma, %91'in üzerinde bir sınıflandırma doğruluğu ile, çekirdeklerin şekli, oryantasyonu, gölgelenmesi ve kümelenmesi gibi faktörlere karşı sağlamlık göstermiştir.

Daha hızlı ve daha güçlü bir sistem için Ziegler vd. (2016) çalışmalarında NIR kullanmışlardır. 5 çeşit buğday kullanmışlardır. Bunlar ekmek, spelt, durum, emmer ve

einkorn buğdaylarıdır. Sınıflandırmada kısmi en küçük kareler ayırt etme analizini (PLSDA) kullanmışlardır ve %80-100 doğruluk elde etmişlerdir.

Derin öğrenme başka çalışmalarda da kullanılmıştır. Ghosh vd. (2016) ise çalışmalarında Yakın Kızılötesi Spektroskopisini (NIRS) kullanarak otuz farklı hububat ve on dokuz farklı kuru tane cinsinden karışımların içeriğini (yabancı tane oranını) bulmayı hedeflemişlerdir. 384 spektrumdan oluşan bir veri kümesinden toplam 276 spektrum fındık karışımı sınıf olarak tanımlanmıştır.

Derin öğrenme yöntemleri tıp alanında da yoğun şekilde kullanılmaya başlanmıştır. Gardezi vd. (2017) çalışmalarında derin öğrenme yaklaşımını kullanarak mamogramlarda normal ve anormal dokuların sınıflandırılması için bir yöntem sunmaktadırlar. 3x3 konvolüsyon filtreli VGG-16 CNN derin öğrenme mimarisi, IRMA veri kümesindeki mamogramların ROI' leri üzerinde uygulanmıştır. Sonuçlar SVM, ikili ağaçlar, basit lojistik ve KNN ($k = 1, 3, 5$) sınıflandırıcılarında 10 katlı çapraz doğrulama kullanılarak değerlendirilmiştir. Metot AUC 1,0 ile %100 sınıflandırma doğruluğu elde etmişlerdir.

Senthilkumar vd. (2017) çalışmalarında Yakın kızılötesi (NIR) hiperspektral görüntüleme sistemini, kontamine buğday çekirdeklerinde beş konsantrasyonda okratoksin A (OTA) tespit etmek için kullanmışlardır. Buğdayda OTA kontaminasyonunu belirlemede daha önemli olan anahtar dalga boylarını belirlemek için iki boyutlu verilere Temel Bileşen Analizi (PCA) uygulamışlardır. Sınıflandırma modelleri OTA kontamine buğday çekirdeklerinden ve OTA olmayan P. verrucosum aşılınmış buğday çekirdeklerinden %100 doğrulukta ayırmıştır. Aynı zamanda sınıflandırma modelleri, OTA kontamine buğday tanelerinin beş konsantrasyon seviyesi ve OTA olmayan P. verrucosum aşılınmış buğday çekirdeklerinin beş enfeksiyon seviyesi arasında %98'den daha fazla bir sınıflandırma doğruluğuna sahiptir.

3. MATERYAL VE YÖNTEMLER

Günümüzde hububat kalitesinin kontrolünde, bilgisayar destekli kalite denetim sistemleri geliştirilmektedir. Görsel denetime alternatif olarak sunulan bu sistemler, genel olarak buğday yığını ve tanelere ait sayısal resimlerin bilgisayar ortamına aktarılarak görüntü işleme teknikleri yardımıyla tanımlayıcı bilgilerin elde edilmesi ve bu bilgilerin sınıflandırılması prensibine dayanmaktadır. Yapmış olduğumuz çalışmada hiperspektral görüntüleme için 3 farklı kamera kullanılmıştır. Bunlar SWIR, VNIR ve RGB kameralardır.

3.1. Hiperspektral Görüntüleme

Hiperspektral görüntüleme veya spektroskopisi, dijital görüntüleme ve spektroskopinin gücünü birleştirir. Hiperspektral bir kamera, bir görüntüdeki her bir piksel için, çok sayıda (tipik olarak bir kaç ile yüzlerce) bitişik spektral bant için ışık yoğunluğunu alır. Böylece görüntüdeki her piksel sürekli bir spektrum (parlaklık veya yansıma) içerir ve sahnede bulunan nesneleri büyük hassasiyet ve ayrıntılarla karakterize etmek için kullanılabilir.

İnsan gözü çoğunlukla üç bantta (kırmızı, orta dalga boyları - yeşil olarak algılanan uzun dalga boyları ve mavi olarak algılanan kısa dalga boyları) görünür ışığın rengini görürken, spektral görüntüleme spektrumu çok daha fazla gruba ayırır. Görüntülerin bantlara bölünmesi tekniği görünür olanın ötesine genişletilebilir. Hiperspektral görüntülemeye, kaydedilen spektrumlar dalga boyu çözünürlüğüne sahiptir ve geniş bir dalga boyu aralığına sahiptir. Hiperspektral görüntüleme, aralıklı spektral bantları ölçen multispektral görüntülemenin aksine, bitişik spektral bantları ölçer.

Sensör tasarımı ve işlem hızındaki son gelişmeler ile birlikte, uydudan / havadan uzaktan algılama ve askeri hedef tespiti ile endüstriyel kalite kontrol ve ilaç ve biyofizikte laboratuvar uygulamalarına kadar geniş bir yelpazede uygulamalar ortaya koyulmaktadır. Hiperspektral görüntüleme, zengin bilgi içeriği nedeniyle, ister çevrimiçi endüstri izleme ister uzaktan algılama için olsun, otomatik görüntü işleme için benzersiz şekilde uygundur.

3.1.1. Kısa dalga kızılötesi ışık (Short wave infrared)

Kısa dalga kızılötesi (SWIR) ışık tipik olarak 0.9 - 1.7 μ m dalga boyu aralığında ışık olarak tanımlanır, ancak 0.7 - 2.5 μ m arasında da sınıflandırılabilir. Silikon sensörler yaklaşık 1.0 μ m'lik bir üst sınıra sahip olduğundan, SWIR görüntüleme, spesifik SWIR aralığında performans gösterebilen benzersiz optik ve elektronik bileşenler gerektirir. Indium gallium arsenide (InGaAs) sensörleri, tipik SWIR aralığını kapsayan ve SWIR görüntülemede kullanılan birincil sensörlerdir.

Mikro Tasarım' a ait MT-CL-MicroCAM-SW6415 (MikroTasarım, 2018) SWIR Kamera kullanılmıştır. Özellikleri Şunlardır:

- MT6415CA ROIC üzerinde Hibrit SWIR Görüntüleme Sensörü
- 640x512 Format, 15 μ m Piksel
- 900-1700nm Spektral Bant
- 70 fps
- 5V, CamLink Çıkış
- 40mm x 40mm x 40mm (w/o optik)
- 72 gr (w/o optik)



Şekil 3.1. Çalışmada kullanılmış olan SWIR Kamera

3.1.2. Yakın görünür kızılötesi ışık dalgası (Visible infrared light wave)

Elektromanyetik spektrumun görünür ve yakın kızılötesi (VNIR) kısmı, yaklaşık 400 ve 1400 nanometre (nm) arasında dalga boylarına sahiptir. Tam görünür spektrumu, kızılötesi tayfın bitişik kısmı ile 1400 ve 1500 nm arasında birleştirir. Bazı tanımlar ayrıca, 1400 nm'den 2500 nm'ye kadar kısa dalga boylu kızılötesi bandı içerir. VNIR çoklu spektral görüntü kameraları uzaktan algılama ve görüntüleme spektroskopisinde geniş uygulamalara sahiptir. Çalışmamızda ise şekilde gösterildiği gibi Mikro Tasarım'a ait MT-CL-CAM-VNIR6415 VNIR kamera kullanılmıştır.



Şekil 3.2. Çalışmada kullanılmış olan VNIR Kamera

3.2. Görülebilir Işık Dalgaları

Görülebilir ışık dalgaları, görebildiğimiz tek elektromanyetik dalgalardır. Bu dalgaları gökkuşağının renkleri olarak görüyoruz. Her rengin farklı bir dalga boyu vardır. Kırmızı en uzun dalga boyuna ve mor en kısa dalga boyuna sahiptir. Bütün dalgalar birlikte görüldüğünde, beyaz ışığı oluştururlar.

Gözlerimizdeki koniler, görünür ışık dalgaları için alıcılardır. Güneş, görünür ışık dalgaları için doğal bir kaynaktır ve gözlerimiz, bu güneş ışığının etrafımızdaki nesnelerden yansımaları görür. Gördüğümüz bir nesnenin rengi, yansıyan ışığın rengidir. Diğer tüm renkler emilir.

Işık ampulleri, başka bir görünür ışık dalgası kaynağıdır. Çalışmada görünür ışık dalgaları için RGB kamera kullanılmıştır. Görüntüleme sistemi iki adet 100-W halojen ışık ampul tarafından aydınlatılmıştır. Bu halojen lambalar, ilgili spektral aralığı kapsamaktadır. (Univie.ac.at., 2018)



Şekil 3.3. Çalışmada kullanılmış olan Halojen Ampuller

Literatürde yapılan çalışmalar incelendiği zaman buğday çeşitlerini sınıflandırmak için RGB ve NIR görüntüleme, buğdayın kalitesini düşüren süne, mantar gibi hastalıkları tespit edebilmek için de NIR ve SWIR görüntülemelerin kullanıldığı görülmüştür. Bundan dolayı buğday kalitesini belirlemek için her bir görüntülemeden gelen görüntülerin birleştirilmesi akılcı bir çözüm olarak karşımıza çıkmaktadır. Bu sayede 400 nm den 1700 nm ye kadar olan tüm dalga boylarındaki verilerin kullanılması mümkün olacaktır. Bu nedenle görüntü birleştirilmesine (füzyon) büyük ihtiyaç duyulmaktadır. Görüntü füzyonu, verilen iki görüntüde aynı anda var olmayan ayrıntıları kullanarak

görüntüleri birleştirmek, maksimum bilgi içeriğine sahip tek bir görüntü elde etmek ve bu görüntülerin bilgi kalitesini artırmak için uygulanan bir mekanizmadır. Görüntü füzyonu ile uzaysal çözünürlüğü artırmak, belirsizliği azaltmak, sınıflandırma hassasiyetini geliştirmek ve görüntü kalitesi iyileştirmek gibi hedeflere ulaşılabilir.

Tasarlanan sistemin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atanan örnek sayısı nicelikleri ile ölçülür. Testler sonucunda elde edilen sonuçların başarımları bilgileri karışıklık matrisi ile belirtilmektedir. Karışıklık matrisinde yer alan satırlar test kümesindeki örnekler için gerçek sayıları ifade etmektedir. Sütunlar ise modelin tahminlenmesini göstermektedir. İki sınıflı bir örnekte karışıklık matrisi aşağıdaki gibi olmaktadır. Pietikäinen vd. (2010)

Çizelge 3.1: 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.

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

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

Kesinlik, sınıfı A olarak tahminlenmiş Gerçek Pozitif sayısının, sınıfı A olarak tahminlenmiş tüm örnek sayısına oranıdır.



4. YAPILAN ÇALIŞMALAR YÖNTEM 1

Endüstriyel uygulamalardaki tanımlama ve sınıflandırma işlemlerini kolaylaştırmak için, geleneksel yöntemlerle karşılaştırıldığında daha yüksek doğruluk oranı vaat etmesi nedeniyle derin öğrenme fikirleri üzerine yoğun ilgi vardır. Çalışmamızın bu kısmında, hiperspektral buğday resimlerini derin öğrenmeye dayalı olarak sınıflandırmak için akıllı bir makine öğrenme sistemi sunulmaktadır.

4.1. VNIR Kamera ve Alexnet Modelinin Kullanılması

Hiperspektral buğday resimlerinin sınıflandırılması için AlexNet modelinin özellik çıkarımı performansı araştırılmıştır. Kullanılan sistem, önceden eğitilmiş Evrişimli Sinir Ağı (CNN) olan AlexNet' in FC6 ve FC7 özelliklerine dayanmaktadır. Bu bölümde, ince ayar yaklaşımı dikkate alınarak, AlexNet modelinin son başı atlanmış ve Destek Vektör Makinesi (SVM) sınıflandırıcısı, buğday tohumu sınıflarını belirlemek için kullanılmıştır. Sistem performansını değerlendirmek için, 50 tane buğday türünün Görünür Yakın Kızılötesi görüntüleri (VNIR) kullanılarak örnek başına 220 görüntü ile bir hiperspektral buğday görüntüsü testi veri seti oluşturulmuştur. Yeni oluşturulan test veri kümesiyle yapılan deneylerde yüksek sınıflandırma başarımları elde edilmiştir.

4.1.1. Derin öğrenme özeti: CNN özellikleri

Desen tanıma uygulamaları, bir deseni diğerinden sağlam bir şekilde ayırabilmek için kullanılabilecek bazı ayırt edici özelliklere dayanır ve bu nedenle araştırmacılar bu özellikleri belirlemeye çalışır. Bununla birlikte, pratik uygulamada başarılı özellik çıkarımını engelleyebilecek birkaç zorluk ortaya çıkmaktadır. Görüntü deseni tanımda, örneğin, aydınlatma değişkenlikleri, ölçekleme ve hareket başarılı kararlara ulaşma ihtimalini düşürebilir. Bu düşünceyle, kullanılan özellik çıkarma yöntemi, sınıflar arasındaki benzerliği en aza indirip en düşük düzeye getirmelidir. Bu argümanı destekleyerek, Kelime Çantası (BOW) modeliyle birlikte Yerel İkili Örüntü(LBP), Yönlü Gradyan Histogramı (HOG), Ölçekten Bağımsız Özellik Dönüşümü (SIFT) ve Yoğun Ölçekten Bağımsız Özellik Dönüşümü (DSIFT) kullanılmaktadır. BOW, bir k-means kümeleme işleminden sonra çıkarılan görsel özellikler (kelimeler) üzerindeki kümeleme basamağıdır. Kümeleme, milyonlarca görsel kelimededen (görsel kelimelerin havuzu denir)

yönetilebilir D boyutlu kelimeler sağlar. Görsel özellikler ve ilgili kümeler arasındaki benzerliği belirledikten sonra, her görüntü için bir histogram oluşturulur. Böylece, bir görüntü D boyutlu olan bir histogramla temsil edilir. Eğitim verileri doğrusal / doğrusal olmayan bir sınıflandırıcı (ör. Destek Vektör Makinesi (DVM)) üzerinden yürütülür. Her bir test örneği için bir histogram elde edilir ve etiketleri sınıflandırıcı tarafından belirlenir. Bu yaklaşım neredeyse tüm makine öğrenme sistemlerinin özetidir.

Büyük veri setleri için makine öğrenme sistemlerinin performansını artırma çabalarında, derin CNN'ler Krizhevsky ve diğerlerinin, yani AlexNet'in Krizhevsky vd. (2012) çalışmasından faydalanılmıştır. AlexNet, itibarını nesne tanıma konusunda etkileyici sonuçlar elde ederek kazanmıştır. Derin CNN'in başarıyla uygulanmasıyla, geleneksel özellik çıkarma NN stratejileri dönemi hemen hemen sona ermektedir ve makine öğrenimini değiştirmiştir.


4.2. Alexnet Modeli

AlexNet, imagenet yarışmasında yıldızı parlayan ve CNN öz nitelikleri tabanlı modelleme olarak bilinmektedir. Daha önce önerilen LeNet yapısının sadece büyük imgelere göre ayarlanması olarak düşünülebilir. LeNet modeli ilk olarak digit sınıflandırma için önerilmiş ve gelecek vaadedilen başarıyı gösterdiği izlenmiştir.

CNN yapılarının en büyük avantajı anlamlı öz nitelikleri kademeli bir şekilde oluşturmasıdır. AlexNet modelinde konvolüsyon katmanı aslında sinir ağlarının modelindeki ağırlıklandırma katsayıları ile girdi verisini çarpmaya benzer. Ancak ağırlıklandırma katsayıları sabit bir sayı yerine 5x5 veya 3x3'lük filtrelerle denk gelmektedir. Yani filtre imge üzerinde gezdirilerek bir çıktı elde edilmektedir. Eğer 227x227x3 lük resim üzerinden, boyutları 5x5x3'lik ve 6 tane filtre gezdirirsek sonuç olarak 6 tane 224x224'lik çıktılar verecektir. Havuzlama işleminde ise bu boyut yarıya indirilmektedir. Bu işlem blokların ortalaması veya maksimum alınarak yapılmaktadır. Aktivasyon katmanında basit olarak girdi verisi belli bir aktivasyon fonksiyonundan geçirilmektedir. Aktivasyon fonksiyonları sigmoid, tanh ve relu kullanılması oldukça yaygındır. Kullanılacak aktivasyon fonksiyonu türevlenebilir olmalıdır, çünkü geri

beslemede konvolüsyon filtrelerini güncellemek için aktivasyon fonksiyonun türevi kullanılmaktadır.

Örüntüleri ayırmak için genel olarak AlexNet modelinin tam bağlı katmanlar (full connected layers) adını verdiğimiz ve Şekil 4.1. 'de en sağ kısımda gösterilen FC7 veya FC6 katmanları öznelik çıkarmak için kullanılmaktadır. $227 \times 227 \times 3$ boyutlu bir girdi imgesi ileri yönde tüm katmanlardan geçirilerek 4096×1 boyutlu bir öznelik vektörü ile temsil edilmektedir. Birçok çalışmada 4096×1 vektörü sınıflandırma ve benzeri amaçlar için kullanılmaktadır. Bu çalışmada FC7 ve FC6 katmanlarından dönen 4096×1 'lik vektörler buğday sınıfı tahmin etmek için kullanılmıştır.



Şekil 4.1. AlexNet yapısının genel akışı.

4.3. Veri Seti

Şekil 4.2. bu çalışmada kullanılan buğdayların örnek görüntülerini göstermektedir. Görüntüler üzerinde çıplak gözle hızlı bir inceleme yaptığımızda bir sınıfın temsili örneklerini diğerlerinden ayırmanın çok zor olduğu sonucuna varmak oldukça kolaydır. İnsan gözü nispeten birkaç gri seviyeye hassastır ve görüntülerde bulunan ince mekansal ayrıntıları algılayamaması normaldir. Sınıflar arasındaki yüksek benzerlik nedeniyle, göz testi çoğunlukla yanlış sınıflandırmaya neden olur. Bu nedenle, insan gözünün ayırtamadığı özellikleri de dahil eden makine destekli karar verme algoritmalarının geliştirilmesi mantıklıdır. Örneğin, NIR dalga boyu kullanılarak elde edilen hiperspektral görüntülerin sınıflandırılması, makine destekli tanıma / sınıflandırma amacıyla iyi bir adaydır.




Şekil 4.2. Buğday örneklerinden hiperspektral görüntüleme ile elde edilen veri seti

Burada sunulan çalışmada, buğday numunelerinin Yakın Görünür Kızılötesi yani Visible-Near Infrared (VNIR, dalga boyu: 400-1100 nm) kamera ile elde edilen görüntüleri kullanılarak yeni hiperspektral veri kümesi oluşturuldu. Veri seti, her biri 220 imge içeren 50 buğday sınıfından elde edilen toplamda 11000 örnekten oluşmaktadır. Veri seti, derin öğrenme özellikleri oluşturmak için önceden eğitilmiş AlexNet modelinden geçirilir. Sınıflandırma sonuçları, farklı buğday örnekleri için Destek Vektör Makinesi (SVM) yöntemi kullanılarak elde edilmiştir. Aşağıdaki bölümlerde sunulduğu gibi, bu özellikler üzerinden oldukça yüksek doğrulukta sınıflandırma sonuçları elde edilmiştir.


4.4. Deneyisel Çalışmalar ve Performans Değerlendirme

50 sınıftan oluşan veri seti, Eskişehir'de yaygın olarak yetiştirilen buğday tanelerinin kontrollü ortam fotoğraflarından üretilmiştir. Şekil 4.2. , bu 50 tipin örnek fotoğraflarını ve etiketlerini göstermektedir. Her sınıf için, 640x512 boyutundaki 55 görüntü yakalanıp, her biri 227x227'lik 4 görüntüye ayrılarak görüntü sayısı 220'ye yükseltildi. Görüntüler, MT-CL-CAM-VNIR-6415 (Micro-Tasarım Co.) kamerasıyla çekilmiştir. Kamera Visible-Near Infrared (VNIR) olup, spektral bandın 400 nm ile 1100 nm aralığındaki dalgaları algılamakta ve bu aralıktaki dalga boylarının ışınım alanlarının toplamı olarak gri-seviye görüntü üretmektedir. Kontrollü bir ortam Şekil 4.3.'de gösterildiği gibi oluşturulmuştur. Kamera, numune düzlemi üzerinde yaklaşık 9x7 cm² bir alan görüntülemektedir ve numunelerin yaklaşık 30 cm üzerine yerleştirilmiştir. Örnekler ana eksenin her iki yanında yaklaşık 45°'lik açı ile yerleştirilen iki adet 100-W halojen ışık ampul tarafından aydınlatılmaktadır. Halojen ampullerin ışınım aralığı, kameranın algıladığı spektral aralığı kapsamaktadır. Pozlama süresi 17 ms'ye kalibre edilmiştir.



Şekil 4.3. Görüntü yakalama düzeni. (a) Çizim düzeni, (b) Gerçek düzen.

Önceden eğitilmiş AlexNet, bu tür görüntüler üzerinde çalışacak şekilde tasarlandığından, resimler her biri 227x227 boyutlarındaki dört alt görüntüye göre kırılır. AlexNet modeli, sınıflandırma performansının değerlendirilmesi için toplamda $50 \times 220 = 11000$ görüntü veri kümesinde yürütülür. Her bir test görüntüsü için test akışı Şekil 4.4'te özetlenmiştir.



Şekil 4.4. Test aşaması

Rastgele seçilen %20'lik veri, SVM sınıflandırıcısını eğitmek için, kalanları ise test ve performans değerlendirmesinde kullanılmıştır. Eğitimde ve testte, test görüntülerinin hiçbir versiyonu kullanılamamıştır. Bu işlem 100 kez farklı eğitim ve test seti tekrarlanmıştır ve doğruluk ortalamaları ve standart sapmalar kaydedilmiştir.

Çizelge 4.1. , hem FC6 hem de FC7 özellikleri üzerine SVM' in doğrusal ve kuadratik çekirdeğinin iletilmesine ilişkin sınıflandırma sonuçlarını sergilemektedir. Açıkçası, doğrusal olarak sınıflandırılmış FC6 özelliklerinin FC7'den biraz daha iyi olan %99,9695 toplam doğruluk sonucu verdiğini gözlemliyoruz. Eğitim ve test verilerini 100 kez değiştirdikten sonra standart sapma %0,0018 olarak bulunmuştur. Kuadratik kernel, genel doğruluk ve standart sapma için sırasıyla 99,6331 ve 0,0520 olan oldukça güçlü sayısal sonuçları vermiştir.

FC6 özellikleri yerine FC7 kullanımı, doğruluk ve standart sapma açısından yine benzer sonuçlar vermiştir.

Çizelge 4.1 FC6 ve FC7 özellikleri üzerindeki Linear ve Quadratic Kernel SVM skorları

Name	On FC6 features				On FC7 features			
	Linear Kernel		Quadratic K.		Linear Kernel		Quadratic K.	
	Accuracy	Std	Accuracy	Std	Accuracy	Std	Accuracy	Std
Ahmetağa	99.9695	0.0017	99.6444	0.0494	99.9632	0.0022	99.6204	0.0654
Aldane	99.9693	0.0017	99.6334	0.0500	99.9635	0.0025	99.6064	0.0653
Alparslan	99.9694	0.0015	99.6368	0.0552	99.9639	0.0027	99.6147	0.0627
Alpu01	99.9696	0.0019	99.6369	0.0535	99.9633	0.0024	99.6190	0.0669
Altay2000	99.9695	0.0016	99.6401	0.0519	99.9637	0.0024	99.6133	0.0665
Ayyıldız	99.9694	0.0017	99.6322	0.0536	99.9637	0.0024	99.6201	0.0685
Bayraktar2000	99.9695	0.0019	99.6447	0.0578	99.9636	0.0023	99.6175	0.0679
Bezostaya	99.9696	0.0020	99.6333	0.0501	99.9636	0.0027	99.6212	0.0698
Bozkır	99.9694	0.0019	99.6286	0.0546	99.9639	0.0024	99.6187	0.0733
Cesit1252	99.9697	0.0017	99.6251	0.0530	99.9637	0.0027	99.6193	0.0762
Cetinel	99.9696	0.0019	99.6255	0.0501	99.9642	0.0023	99.6045	0.0653
Dağhan	99.9698	0.0016	99.6230	0.0494	99.9635	0.0029	99.6114	0.0722
Doğu88	99.9693	0.0017	99.6391	0.0478	99.9638	0.0025	99.6261	0.0711
Ekiz	99.9697	0.0016	99.6342	0.0578	99.9641	0.0024	99.6253	0.0711
Energo	99.9690	0.0018	99.6421	0.0510	99.9636	0.0025	99.6284	0.0710
Enola	99.9699	0.0020	99.6387	0.0484	99.9637	0.0021	99.6202	0.0758
Es10K20	99.9697	0.0017	99.6388	0.0502	99.9636	0.0022	99.6337	0.0627
Es26	99.9696	0.0017	99.6351	0.0491	99.9635	0.0021	99.6158	0.0779
Esperia	99.9697	0.0019	99.6258	0.0510	99.9641	0.0024	99.6132	0.0772
Galateya	99.9696	0.0017	99.6317	0.0507	99.9639	0.0025	99.6149	0.0746
Gökhan	99.9696	0.0017	99.6275	0.0510	99.9637	0.0025	99.6322	0.0673
Harmankaya99	99.9694	0.0017	99.6333	0.0495	99.9633	0.0022	99.6153	0.0759
Hendrix	99.9695	0.0017	99.6309	0.0491	99.9640	0.0025	99.6269	0.0674
Karahan99	99.9695	0.0016	99.6336	0.0490	99.9639	0.0025	99.6199	0.0586
Karasu90	99.9691	0.0019	99.6434	0.0511	99.9636	0.0022	99.6120	0.0674
Karatoprak	99.9695	0.0017	99.6355	0.0560	99.9641	0.0024	99.6171	0.0744
Kate_a1	99.9696	0.0018	99.6387	0.0537	99.9639	0.0023	99.6246	0.0666
Kenanbey	99.9695	0.0019	99.6327	0.0514	99.9636	0.0023	99.6186	0.0629
Kinac97	99.9697	0.0018	99.6377	0.0563	99.9634	0.0024	99.6288	0.0681
Kirik	99.9694	0.0018	99.6317	0.0537	99.9642	0.0025	99.6171	0.0673
Konya2002	99.9691	0.0019	99.6309	0.0449	99.9635	0.0024	99.6324	0.0616

Krasunideska	99.9696	0.0016	99.6375	0.0532	99.9635	0.0025	99.6211	0.0617
Lancer	99.9696	0.0020	99.6264	0.0474	99.9641	0.0021	99.6264	0.0666
Meram2002	99.9695	0.0019	99.6272	0.0579	99.9643	0.0022	99.6288	0.0626
Meram	99.9695	0.0018	99.6270	0.0523	99.9639	0.0026	99.6179	0.0707
Mesut	99.9697	0.0017	99.6249	0.0493	99.9634	0.0023	99.6234	0.0721
Midas	99.9696	0.0016	99.6288	0.0567	99.9632	0.0026	99.6129	0.0657
Nacibey	99.9693	0.0018	99.6321	0.0463	99.9635	0.0026	99.6307	0.0791
NeneHatun	99.9694	0.0017	99.6283	0.0497	99.9635	0.0024	99.6159	0.0699
Palandoken	99.9697	0.0018	99.6291	0.0609	99.9635	0.0025	99.6281	0.0652
Renan	99.9692	0.0018	99.6291	0.0529	99.9638	0.0022	99.6119	0.0744
Selcuklu97	99.9687	0.0019	99.6362	0.0417	99.9640	0.0025	99.6264	0.0738
Seri2003	99.9693	0.0018	99.6287	0.0554	99.9636	0.0024	99.6328	0.0745
Seri82	99.9696	0.0018	99.6379	0.0588	99.9637	0.0027	99.6258	0.0714
Seval	99.9692	0.0015	99.6309	0.0530	99.9636	0.0023	99.6254	0.0800
Sham-I	99.9696	0.0017	99.6292	0.0512	99.9636	0.0025	99.6079	0.0652
Sonmez2001	99.9695	0.0018	99.6298	0.0545	99.9635	0.0024	99.6234	0.0761
Tosunbey	99.9694	0.0019	99.6345	0.0568	99.9632	0.0026	99.6294	0.0719
Yildirim	99.9694	0.0020	99.6362	0.0542	99.9637	0.0024	99.6207	0.0735
Yunus	99.9696	0.0019	99.6369	0.0486	99.9639	0.0022	99.6217	0.0713
Ortalama	99.9695	0.0018	99.6331	0.0520	99.9637	0.0024	99.6208	0.0697

4.5. Yöntem 1 Değerlendirme

Derin öğrenme yöntemleri tarafından sağlanan yüksek doğruluk oranları, genel olarak, her bir katmandaki girdiler ve özellikler arasında aşamalı olarak bağlantı kuran basamaklı evrişim katmanları sayesinde elde edilir. Bu kısımda da CNN özellikleri kullanılarak sınıflandırma yapılmaya çalışılmıştır. FC6 ve FC7 özelliklerinden faydalanılmıştır. FC6 ile elde edilen sonuçlar FC7 ile elde edilen sonuçlara göre biraz daha iyidir. Buna ek olarak SVM polinom ise SVM' e göre daha iyi sonuç vermiştir. Bu farklılıklara rağmen çizelge 4.1'e bakıldığında tüm sonuçların oldukça iyi olduğu gözlemlenmektedir.

Kontrollü ve tarafsız bir ortamda yakalanan VNIR hiperspektral görüntülemenin buğday çeşidi sınıflandırmasında iyi bir performans gösterdiğine sonucuna ulaşılmıştır. Veri setindeki 50 buğday çeşidinden elde edilen toplamda 11000 görüntü kullanılarak başarılı bir sınıflandırma yapılmıştır.



5. YAPILAN ÇALIŞMALAR YÖNTEM 2

Gelişen teknoloji ile birlikte daha objektif kalite yöntemleri denenmeye başlanmış ve buğday çeşitlerinin yeni teknolojilerle belirlenme ihtiyacı daha da artmıştır. Bu bölümdeki çalışmalarda da bu doğrultuda, hem görünür ışık (RGB, dalga boyu: 400-800 nm), hem görünür yakın kızıl ötesi (VNIR, dalga boyu: 400 – 1100 nm) hem de kısa dalga kızıl ötesi (SWIR, dalga boyu: 900-1700 nm) görüntüleme teknikleri kullanılmıştır. Bunlardan gelen bilgilerin birleşimi ile buğday çeşitlerinin sınıflandırılmaya çalışılmıştır. Üç farklı görüntüleme tekniği ile 40 çeşit buğday sınıfından her bir sınıftan 200 resim olacak şekilde toplamda 8000 resim elde edilmiştir. Görüntü işleme teknikleri ile birlikte, özellik çıkarma ve sınıflandırıcı yöntemler ile bu çeşitler sınıflandırmaya çalışılmıştır. Geliştirilecek sistem ile birlikte fiyat tespiti, buğday çeşidinin tanımı ve kalitesinin kararı için insan faktörü ortadan kaldırılacak ve daha objektif karar verme sağlanabileceği düşünülmektedir.

5. 1. Konsensus Kuralına Dayalı Olarak Buğday Çeşitlerinin Sınıflandırılması

Günlük hayatta tüketilen ekmek, bisküvi ve makarna gibi ürünlerin kalitesi, teknik açıdan bakıldığında üretilmiş olan buğday çeşidine dayanmaktadır. Ayrıca, buğdayın kalitesi tanelerine, yetiştirilme, hasat ve depolama koşullarına doğrudan bağlıdır. Bununla birlikte, mikroorganizmaların ve böcek zararlılarının neden olduğu hasarlar, buğday çeşidinin kalitesini olumsuz yönde etkilemektedir. Tarım bakanlığında buğday çeşitlerinin tanınması, genellikle, uzman bir kişinin deneyim, bilgi ve becerilerine bağlı olarak gerçekleştirilir fakat bu yaklaşım insana bağımlı olduğu için yanlış etiketleme ile sonuçlanabilir. Dahası, çeşitlerin kalite problemini küçük ölçekli veri setlerine dayalı olarak ele aldıklarını belirten bazı çalışmalarda, farklı bölgelerden toplanan çeşitlerin sayısı artmadığı sürece tüm sisteme genelleştirilemezler.

Buğday çeşitlerinin sınıflandırılmasının doğru bir şekilde üstesinden gelmek için, tanımlama sürecini iyi bir doğrulukla yerine getirme yeteneğine sahip yeni bir makine öğrenme tekniğinin, bir uzmanın görsel değerlendirmesinden kaynaklanan hatalı kararların yüzdesini azaltma yararına geliştirilmesi büyük ölçüde gereklidir. Buğday sınıflandırması

konusunda uzmanın kararına alternatif ve/veya yardımcı olarak geliştirilen çalışmalarda, dijital görüntülerin kullanılan görüntüleme cihazından bilgisayara aktarılması ve makine öğrenimi algoritmaları kullanılarak tanımlayıcı bilgilerin çıkarılması ve sonuç olarak bunların sınıflandırılması yaklaşımına dayanır. Bu çalışma aynı zamanda SWIR, VNIR ve RGB kameralarından elde edilen örnekler üzerinde etkili bir yöntem oluşturarak buğday çeşitlerinin doğru bir şekilde sınıflandırılmasını amaçlamaktadır. Popüler sınıflandırıcılar ile birlikte yaygın olarak bilinen özellik çıkarıcıların buğday çeşitlerini tanımak için kullanılması planlanmıştır.

Bu amaçla, iki sistem geliştirilmiştir:

- (i) Geleneksel BoW özelliklerinin kullanıldığı yöntem
- (ii) CNN özelliklerinin kullanıldığı yöntem.


Önceden belirlenmiş bir sınıflandırıcıya sahip özellik çıkarıcı algoritma, buğday temsili için makul bir performans vaad etmediğinden, SIFT, SURF, DSIFT, LBP ve SBFD gibi BoW özellikleri kullanılmıştır ve karar verme aşamasında SVM, ANN ve KNN sınıflandırıcılar ile birlikte bir oy çokluğu kuralı geliştirilmiştir. Buğday tanımlama temelli makine öğrenme sistemleri üzerine literatür taraması yapıldığında, tek bir sınıflandırıcının [ref1-ref2] kimlik tespiti için kullanıldığı gözlemlenebilir. Tam tersine bu çalışmada, dört sınıflandırıcıdan (SVM (lineer), SVM (polinom)), YSA ve K-NN 'den elde edilen sınıflandırma sonuçlarının birleştirilmesinden sonra istatistiksel olarak uygun doğruluk elde etmek için, oy çokluğu temelli karar vermeden oluşan bir kural önerilmiştir. İkinci yöntemde ise, VGG16, VGG19 ve GoogleNet gibi derin CNN mimarileri üzerinde deneyler yapıldıktan sonra CNN özelliklerinin etkileri analiz edilmiştir. Bu yöntemde, CNN modellerinden döndürülen özellikler üzerindeki oy çokluğu kuralının performansı da araştırılmıştır. Geliştirilen CNN özellikleri temelli bu yöntem ile fiyat tahmini, cinslerin tanımlanması ve buğday çeşitleri için kalite belirlemesi ve böylece insan faktörü müdahalesinin azalması ile birlikte tutarlı ve daha objektif kararlar alınacaktır.

5.2. BoW Yöntemi: Geleneksel Özellikler ve Sınıflandırıcılar

Kelimeler çantası modeli BoW (Bag of Word), doğal dil işleme ve bilgi erişiminde kullanılan basitleştirilmiş bir temsildir. Vektör uzay modeli olarak da bilinir. Bu modelde, bir metin (bir cümle veya bir belge gibi), dilbilgisi ve hatta kelime düzeni göz ardı edilerek ancak çokluk korunarak bu kelimelerin çantası olarak temsil edilir. Kelime çantası metin belgelerindeki özellikleri ayıklamak için bir yöntemdir. Bu özellikler, makine öğrenimi algoritmalarını eğitmek için kullanılabilir. Eğitim setindeki tüm belgelerde oluşan tüm benzersiz kelimeler bir kelime hazinesi oluşturur. Kelimeler çantası modeli bilgisayar görüşü için de kullanılmaktadır. Kelimeler çantası modeli, her bir kelimenin bir sınıflandırıcıyı eğitmek için özellik olarak kullanıldığı sınıflandırma yöntemlerinde yaygın olarak kullanılmaktadır.

İmgeden seçilen yamalar SIFT, LBP gibi betimleyiciler tarafından sabit boyutlu vektörlere dönüştürüldükten sonra yama vektörleri nicemleme işlemine tabi tutulur. Bu amaç için en çok kullanılan yöntem k -en yakın merkez toplama algoritmasıdır. Bu toplama algoritmasının döndürdüğü merkezler temsili yama vektörleri (temsili yama vektörleri BoW modelinde words-kelimelere karşılık gelmektedir) olarak kullanılırlar.

Şekil 5.1.'de gösterildiği üzere imgelerden gelen yama vektörlerinin temsili yama vektörlerine olan uzaklıklarına bakılarak atamalar yapılır ve imgeleri temsil eden histogram vektörleri belirlenir.




Şekil 5.1. Kelimeler çantası temelli imge betimleme

Şekil 5.1.' de (a) Her bir imgeden seçilen yamalar (b) betimleyiciler kullanılarak sabit boyutlu vektörlere dönüştürüldükten sonra her bir yamanın temsili yama vektörlerine olan uzaklıklarına bakılarak, yamalar temsili yamalara (şekilde w_i , $i=1,...,5$, olarak gösterilen 5 tane temsili yama vektörü vardır) atanır (c). Son olarak imge, atamaları yansıtan histogram vektörü ile temsil edilir

BoW (Bag of Word) yönteminin hedefleri arasında en önemlileri (i) buğday çeşitlerinin sınıflandırma hassasiyetini geliştirmek için RGB, VNIR ve SWIR dahil olmak üzere farklı görüntüleme sistemlerinden gelen bilgilerin birleştirilmesi ve (ii) iyi bilinen özellik çıkarıcıların ve sınıflandırıcıların bir oy çokluğu kuralıyla birlikte performansının değerlendirilmesidir.

Bu hedeflere ulaşmak için, Şekil 5.2.' de verilen sistem takip edilmiştir. Sınıflandırma sisteminin ilk adımı olarak, Eskişehir Ticaret Borsası ve Eskişehir Tarım İl Gıda Müdürlüğü gibi yerel ofislerden 40 farklı buğday çeşidi toplanarak depolanmıştır. Ardından, buğday çeşitlerinin her bir örneği üç farklı dalga boyu aralığıyla çalışan (RGB, VNIR, SWIR) kameralar ile görüntüleme yapılmıştır. Ek olarak, RGB, VNIR ve SWIR görüntülerinin bir füzyonu olarak dördüncü veri kümesi, Ortak Vektör Yaklaşımı (CVA) yöntemi ile elde edilmiştir. Füzyon prosedürü, Böl. 5.4. te ayrıntılı olarak anlatılmıştır. Böylece RGB, VNIR, SWIR ve FUSION şeklinde dört farklı veri seti, hem geleneksel bir yöntem olan BoW yönteminde hem de yeni gelişen bir yöntem olan CNN özelliklerinin kullanıldığı yöntemde buğday çeşitlerinin belirlenmesi ve oy çokluğu kuralının performansını araştırmak amacıyla elde edilmiştir.



Şekil 5.2. Buğday çeşidinin tanımlanması için önerilen sistemin genel süreci


Şekil 5.2. , buğday çeşitlerini SIFT Lowe vd. (2004), SURF Bay vd. (2008), DSIFT Vedaldi vd. (2010) ve SBFD Ojala vd. (2002) gibi iyi bilinen geleneksel özellik / tanımlayıcı çıkarma araçları yardımıyla ayırt eden ilk yöntemi kısaca özetlemektedir. SIFT, SURF, DSIFT, LBP ve SBFD özellikleri / tanımlayıcı kümeleri yukarıda belirtilen veri

kümelerinden ayıklandıktan sonra, her özellik kümesi Kelimeler Çantası (BoW) stratejisi kullanılarak kodlanmıştır. BoW modelinde Vedaldi vd. (2010) tanımlayıcı kümesi olarak adlandırılan her bir yerel histogram, k-ortalama kümeleme yöntemi ile özellik uzayından elde edilen en yakın merkezin çıkarılmasıyla görsel bir kelimeye eşlenmiştir. Çalışma süresi ile doğruluk arasındaki uyum göz önüne alınarak, bir özellik kümesinin boyutu 600 olarak belirlenmiştir, bu da BoW modelinden dönen 600 değerden oluşan bir vektördür. Dört veri kümesi ve beş özellik / tanımlayıcı çıkarma aracımız olduğu için, toplamda 20 farklı özellik kümesi vardır. Sınıflandırma aşaması durumunda, her bir test örneği için dört sınıflandırıcı (SVM (doğrusal), SVM (Polinom), YSA ve K-NN) kullanılarak 80 farklı karar tahmin edilmiştir. Bu, 20 farklı özellik kümesinin ve 4 sınıflandırıcının bulunduğunu, böylece seçilen özellik kümeleri için modellerin ayrı ayrı oluşturulmasından ve ilişkilendirilmiş sınıflandırıcıların çalıştırılmasından sonra 80 tane farklı karar alındığını göstermektedir. Çoğunluk oylama prosedürünü (“uzlaşma kuralı”) yürüttükten sonra, 80 karar arasından her buğday örneği için tek bir etiket belirlenmiştir. İlgili kullanılan özellik çıkarıcı ve sınıflandırıcıların detayları ve parametreleri Böl. 5.5’te verilmiştir.

5.3. CNN Çerçevesi: Derin Öğrenme Özellikleri

İkinci bir tanımlama yöntemi olarak, derin öğrenme stratejisine dayanan CNN mimarilerinden belirlenen güçlü özellikler kullanılmıştır. Bu yöntemi gerçekleştirmek için, VGG16, VGG19 ve GoogleNet mimarileri, konvolüsyon aşamalarında kullanılan ağırlıkların ayırt edici bilgilerini kapsayacak şekilde yapılmıştır. Buğday çeşitlerinin sınıflandırmasında kullanılan yukarıda bahsedilen CNN mimarileri, derin katmanlar ve büyük ağırlıklar ile eğitilmiştir.

Şekil 5.3. , buğday çeşitlerinin sınıflandırmasında CNN bazlı özellik çıkarma metodolojisini göstermektedir. Bu ikinci yöntemde, buğday tanımlama sisteminin performansını artırmak için VGG16, VGG19 ve GoogleNet kullanılmıştır. Amaç, objektif değerlendirme ölçütlerine dayalı olarak, derin nöral ağ özelliklerinin performansının geleneksel özellikler karşısında oy çokluğu kuralına dayandırarak karşılaştırılmasıdır.




Şekil 5.3. CNN Mimarilerine Dayanan İkinci Yöntemin Gösterimi

5.4. SWIR, VNIR ve RGB Füzyonu

Sistem performansının sadece RGB görüntülemeyi kullanma ile sınırlı olması nedeniyle, iç sınıf varyasyonuna kıyasla düşük sınıflar arası değişim olduğundan, üç görüntüleme sisteminin anlamlı bilgileri birleştirmek, buğday çeşitlerinin sınıflarını ve buna bağlı olarak kalitelerini belirlemek için doğru bir çözüm olarak ortaya çıkar. Ayrıca, 400 nm ile 1700 nm arasındaki bilgilerin füzyon işleminden sonra tek bir kanal ile temsil edileceğini vurgulayabiliriz. Başka bir deyişle, füzyon, her bir kanalda belirtilen farklı ayrıntıları birleştirdikten sonra maksimum bilgi içeriğine sahip olan eşsiz bir görüntü elde etmeyi hedefler. Yakın zamanlarda bu motivasyona paralel olarak, makine öğrenme sistemlerinin performansını geliştirmek için farklı füzyon metodolojileri ile birlikte çok sayıda algoritmalar (He vd., 2017; Lin vd., 2017; M. Gulmezoglu vd., 2001) uygulanmıştır.

Bu çalışmanın yeni noktalarından biri olarak, Ortak Vektör Yaklaşımı (CVA) yöntemi (Gulmezoglu vd., 2001) füzyon amacıyla gerçekleştirilmiştir. Ayrıca, bu konudaki benzer girişimlerde de multispektral kanalları füzyon amacıyla CVA'ı Özkan vd. (2016) çalışmalarında uygulamışlardır. CVA şimdiye kadar, sınıflandırmadan (Cevikalp vd.,

2005) görüntü işlemeye (Işık vd., 2016, Özkan vd. 2015) kadar farklı görevler için kullanılmıştır. Alt uzay tabanlı bir projeksiyon tekniği olarak, CVA yöntemi aşağıdaki gibi özetlenebilir (Ergin vd., 2011).



Şekil 5.4. RGB, SWIR, VNIR ve FUSION veri kümesine ilişkin bazı örnekler.

Herhangi bir sınıfa ait $\vec{a}_i$ ile temsil edilen bir vektör olduğunu varsayarak, $\vec{a}_i = \vec{a}_{com} + \vec{a}_{i,diff}$ formunu elde etmek mümkündür. $\vec{a}_{i,diff}$ sınıfın detaylarından ve kararsız özelliklerinden oluşan fark vektörünü ifade ederken, $\vec{a}_{i,diff}$ paylaşılan bilgiyi vektörler aracılığıyla içeren ve sınıfının karakteristik özelliklerini özetleyen ortak vektörü ifade eder. CVA yöntemi için, yeterli ve yetersiz veri durumlarına istinaden iki durum olması mümkündür. Bir sınıfın vektörlerinin sayısı bir vektörün uzunluğundan daha az ise, o zaman yetersiz veri durumu olarak kabul edilir, aksi takdirde ilgili sınıf için yeterli bir veri durumu vardır. Bu çalışmada, füzyon amaçlı olarak düşünülen beş kanalda (Kırmızı, Yeşil, Mavi, VNIR ve SWIR) yetersiz veri durumu ortaya çıkmıştır. RGB, VNIR 256x320 formundayken, SWIR da 175x200 boyutundan oluşuyordu, dolayısıyla bu çalışma için


yetersiz veri durumunun meydana geldiğini gözlemleyebiliyordu. Yetersiz veri durumunda, Gülmezoglu vd. (2001) çalışmasında vurgulandığı gibi ortonormal vektörleri belirlemek için Gram Schmidt yöntemi kullanılabilir. $\vec{a}_i = \vec{a}_{com} + \vec{a}_{i,diff}$ formülünü $\vec{a}_{com} = \vec{a}_i + \vec{a}_{i,diff}$ formülü ile değiştirirken, $\vec{a}_i$ olarak bilinen değer sayesinde, ilgili sınıfta ortak vektörü ($\vec{a}_{com}$) için fark vektörünün ($\vec{a}_{i,diff}$) elde edilmesinin yeterli olduğunu söyleyebiliriz.

$$\vec{b}_i = \vec{a}_{i+1} - \vec{a}_1 \quad (i = 1, 2, \dots, n-1) \quad (5.1)$$

Bu amaçla denklemde gösterildiği gibi (5.1) fark alanını hesaplamak için bir referans vektörü olan $\vec{a}_i$ vektörünün seçilmesi gereklidir. Bu çalışmada, $\vec{a}_1$ n tane vektörden referans olarak seçilmiştir. Böylece, Gram Schmidt ayrıştırma işleminde kullanılmak üzere bir fark alt alanı $\{\vec{b}_1, \vec{b}_2, \dots, \vec{b}_{n-1}\}$ elde edilmiştir. Dikleştirme işlemi, fark alt uzayına uygulandığında, birimdik set $\{\vec{z}_1, \vec{z}_2, \dots, \vec{z}_{n-1}\}$, (5.2) denkleminde ifade edilen birimdik vektörlere yansıtmak suretiyle hesaplanan referans vektörü $\vec{a}_{1,diff}$ elde edilmiştir.

$$\vec{a}_{1,diff} = \sum_{k=1}^{n-1} \langle \vec{a}_1, \vec{z}_k \rangle \vec{z}_k \quad (5.2)$$

Ardından ilgili sınıfın $\vec{a}_{com}$ ortak vektörü çıkarılır. Sonuç olarak, elde edilen $\vec{a}_{com}$ vektörünün paylaşılan detaylar hakkında zengin bilgiler içeren Ortak Vektör olduğunu söyleyebiliriz.



Şekil 5.5. Kırmızı, Yeşil, Mavi, VNIR ve SWIR dahil beş kanalın füzyonu için görselleştirme.

Şekil 5.5. , Kırmızı, Yeşil, Mavi, VNIR ve SWIR dahil olmak üzere beş kanalın belirli bir Tosunbey sınıfı örneği için füzyon prosedürünü sergilemektedir. RGB' de gözlemlenen buğday çekirdeklerinin yapılarının korunmuş olduğu gözlemlenebilirken, VNIR ve SWIR üzerinde belirtilen ayırt edici bilgiler füzyon görüntüsüne eklenmiştir. Ortak vektör yaklaşımıyla temsil edilen füzyon görüntüsünün, özellik çıkarım teknikleriyle birlikte buğday çeşitlerinin sınıflandırması için anlamlı detaylar içerdiği varsayılmaktadır.

5.5. Araçlar ve Parametreler

Bu bölümde, kullanılan özellik çıkarıcılar ve sınıflandırıcılar hakkında uygulama ayrıntılarını verilmiştir. Yukarıda değinildiği gibi, deneysel çalışma iki çerçeveden oluşmaktadır. Birinci yöntemde, SIFT, DSIFT, LBP, SURF ve SBFD gibi geleneksel özellik çıkarıcıların, SVM, ANN ve K-NN gibi farklı sınıflandırıcılar üzerindeki performanslarının değerlendirilmesi ele alınmıştır. Ayrıca, ikinci bir yöntem olarak, CNN özelliklerinin Softmax sınıflandırıcı ile birlikte ayırıcı gücü, VGG16, VGG19 ve GoogleNet gibi derin katmanlarda deneyler yapılarak doğrulanmıştır.

5.5.1. Özellik çıkarıcı araçlar

Adından anlaşılacağı gibi, özellik çıkarımı, karar vermeyi kolaylaştırmak için bir sınıfın gerçek temel özelliklerini çıkarmayı ifade eder. Sınıflandırma amacı için bir özellik çıkarıcı kullanılması gerektiğinde, tüm faktörleri, yani sınıflar arası değişimini arttırmanın yanı sıra özellik uzayındaki iç sınıf değişimlerini azaltma yeteneğini ölçmek gerekir. Bu çalışma, buğday çeşitlerinin sınıflandırması ile bağlantılı özellik çıkarıcıların ayırt edici kapasitesini ortaya koymaktadır. Bunu yapmak için, geleneksel özellikler söz konusu olduğunda, kelime dağarcığından önce, her bir sınıf için eğitim örneklerinin %20'sinden 6500 özellik vektörü rastgele seçilmiştir. 600 kelimeyi kabul ettiğimiz için her bir görüntü, sadece bir seviyedeki uzamsal piramit kullanarak elde edilen kelime dağarcığı özelliklerini kodladıktan sonra 600x1 boyutuna sahip bir özellik vektörü ile temsil edilmektedir.

- **SIFT:** Ölçekten Bağımsız Öznitelik Dönüşümü (SIFT) (Lowe vd., 2004), tanımlayıcıların histogramına dayanan popüler bir özellik çıkarıcı araçtır. Bir resmin ölçeklendirme, döndürme gibi ya da çevresel etkenlerden kaynaklanan aydınlatma gibi

durumlara karşı güçlü ve bölgesel özellikler tanımlayan bir algoritmadır. Kısaca algoritma resimde var olan bölgesel özellikler ile eğitim kümesinde var olan bölgesel özellikleri kıyaslar. Bunlardan en çok eşleşmenin olduğu örnekte tanıma işlemi uygulanır. Ana hatları ile ise, nesnelerin SIFT anahtar noktaları önce bir dizi referans görüntüden çıkarılır ve bir veritabanında saklanır. Nesnenin yeni bir görüntüden her bir özelliği, yeni görüntüden bu veri tabanına ayrı ayrı karşılaştırarak ve özellik vektörlerinin Öklid mesafesine göre aday eşleme özelliklerini bulmasıyla yeni bir görüntüde tanınır. Tam eşleşme kümesinden, nesne üzerinde hemfikir olan anahtar noktalarının alt kümeleri ve yeni görüntüdeki konumu, ölçeği ve yönü iyi eşleşmeleri süzmek için tanımlanır. Tutarlı kümelerin belirlenmesi, genelleştirilmiş Hough dönüşümünün etkin bir karma tablosu uygulaması kullanılarak hızlı bir şekilde gerçekleştirilir. Bir nesneye 3 veya daha fazla özellik kümesinin katılmasıyla ayrıntılı model doğrulamaya tabi tutulur ve daha sonra dışarıda kalanlar ayrılır. Son olarak, belirli bir özellik kümesinin bir nesnenin varlığını göstermesi olasılığı, uygunluk ve olası yanlış eşleşme sayısı dikkate alındığında hesaplanır. Tüm bu testleri geçen nesne eşleşmeleri, yüksek güven ile doğru olarak tanımlanabilir.

- **DSIFT:** Yoğun Ölçekten Bağımsız Öznitelik Dönüşümü (DSIFT) (Vedaldi vd., 2010) SIFT' in bir başka sürümüdür. DSIFT, önemli bir kilit nokta tabanlı yaklaşım olan SIFT algoritmasından türemiştir. Her kilit nokta, konumunun, yerel ölçeğinin ve yönünün bilgilerini içerir. Bir görüntü verildiğinde, SIFT görüntüdeki tüm ana noktaları, her bir pikselin gradyan özelliğine göre bulur. Daha sonra, her bir kilit noktaya dayalı olarak, SIFT, anahtar noktanın çevresindeki yerel bölgede gradyan özelliğini gösteren bir lokal görüntü tanımlayıcıyı hesaplar. Tüm yerel tanımlayıcılar birleştirilerek, görüntüden tüm özellikleri alınır. SIFT algoritmasına dayalı olarak, yoğun SIFT bazı yeni varsayımlar yapar: (a) her bir kilit noktasının konumu pikselin gradyan özelliğinden değil, önceden tasarlanmış bir yerden; (b) her bir kilit noktanın ölçeği, aynı zamanda önceden tasarlanmış olanla aynıdır; (c) her bir kilit noktasının yönü her zaman sıfırdır (Ahonen, 2006). Bu varsayımlar ile DSIFT, SIFT' in yaptığından daha kısa sürede daha fazla özellik kazanabilir. SIFT' de gerçekleştirilen önemli noktaları seçmek yerine sabit ölçekte gridleri kaydırarak özellikleri çıkarır. Parametre ayarlarında, bin boyutu 8 olarak belirlenmiştir.

- **LBP:** Yerel İkili Desen (LBP) Ojala vd. (2002), doku odaklı özellik çıkarma aracıdır. Her pikselin komşuluğunu eşleştirerek bir görüntünün piksellerini etiketleyen ve sonucu

bir ikili sayı olarak gören basit ama çok verimli bir doku operatörüdür. Görüntülerin mikro yapıları için güçlü bir yerel tanımlayıcı olarak tanıtılmıştır. Ayırt edici gücü ve hesaplama kolaylığı nedeniyle, LBP doku operatörü çeşitli uygulamalarda popüler bir yaklaşım haline gelmiştir. Doku analizinin geleneksel olarak birbirinden farklı istatistiksel ve yapısal modellerine birleştirici bir yaklaşım olarak görülebilir. Pietikäinen vd. (2010) LBP operatörünün gerçek dünyadaki uygulamalarındaki belki de en önemli özelliği,örneğin, aydınlatma varyasyonlarının neden olduğu monoton gri ton değişikliklerine olan sağlamlığıdır. Diğer bir önemli özellik ise, zorlu gerçek zamanlı ayarlarda görüntülerin analiz edilmesini mümkün kılan hesaplama sadeliğidir. LBP operatörü bir görüntünün piksellerini, her pikselin 3×3 komşuluğunu merkez değeriyle eşleyerek ve sonucu bir ikili dizi veya bir ondalık sayı olarak bularak etiketler. Yapılan denemelerde, her bir görüntü 8 hücreye bölünmüş ve 3×3 'lük komşulardan tanımlayıcılar çıkarılmıştır.


- **SURF:** Hızlandırılmış Gürbüz Öznitelikler (SURF) (Bay vd., 2008) ayırt edici blob özelliklerini tespit eder ve yaygın olarak SIFT' in daha hızlı versiyonu olarak bilinir. Benzer özelliklere dayanmaktadır ve karmaşıklığı daha da azaltılmıştır. İlgili noktalarını saptamak için, SURF önceden hesaplanmış integral bir görüntü kullanarak 3 tamsayı işlemi ile hesaplanabilen Hessian blob detektörünün determinantının tamsayı yaklaşımını kullanır. Özellik tanımlayıcısı, ilgi alanı etrafındaki Haar dalgacık yanıtının toplamına dayanır. Bunlar ayrıca entegre görüntünün yardımıyla da hesaplanabilir. SURF tanımlayıcısının amacı, ilgili noktaların çevresindeki piksellerin yoğunluk dağılımını tanımlayarak bir görüntü özelliğinin benzersiz ve sağlam bir tanımını sağlamaktır. Çoğu tanımlayıcı böylece yerel bir şekilde hesaplanır, dolayısıyla daha önce tanımlanan her bir nokta için bir tanım elde edilir. Tanımlayıcının boyutsallığı, hem hesaplama karmaşıklığı hem de nokta eşleşmesi sağlamlığı / doğruluğu üzerinde doğrudan etkiye sahiptir. Kısa bir tanımlayıcı, görünüm değişikliklerine karşı daha sağlam olabilir, ancak yeterli ayrımcılığı sunmayabilir ve bu nedenle çok fazla yanlış pozitif sonuç verebilir. İlk adım, ilgi noktasının etrafında dairesel bir bölgeden gelen bilgilere dayanan tekrarlanabilir bir oryantasyonu sabitlemektir. Daha sonra, seçilen yöne hizalanmış bir kare bölge oluşturulur ve SURF tanımlayıcı buradan çıkarılır. Noktanın etrafındaki bölgeyi tanımlamak için, bir kare bölge çıkarılır, ilgi noktasının üzerinde ortalınır ve seçilen oryantasyon boyunca yönlendirilir. Bu pencerenin boyutu 20'dir. İlgili bölgesi daha küçük 4×4 karesi alt bölgelere ayrılır ve her biri için Haar dalgacık tepkileri 5×5 düzenli aralıklı örnek noktalarında

çıkarılır. tepkiler Gaussian ile ağırlıklandırılmıştır. En güçlü özellikleri seçerken threshold 10'a ayarlanmıştır. (En.wikipedia.org., 2018)

- **SBFD:** Şekil-Tabanlı Fourier Tanımlayıcısı (SBFD), buğday çeşitlerinin sınıflandırmasında yeni bir özellik çıkarıcı uygulanması açısından bu çalışmanın yeniliğini arttırmaktadır. SBFD, nesne sınıflandırması için kullanılan geliştirilmiş bir versiyon olan Fourier Tanımlayıcılarıdır (Çevikalp vd., 2013). X. Wang vd. (2014)' in çalışmasına benzer şekilde, kontur parçaları üzerinden Fourier Tanımlayıcılar çıkarılmıştır.

Şekil tabanlı bir betimleyici çıkarma adımları Şekil 5.6. 'da gösterilmiş olup kısaca şöyledir;

- İlk adımda betimleyicisi çıkartılacak olan objenin konturları çıkartılır (Şekil 5.6a)
- Konturlar üzerinde anlamlı noktalar işaretlenir (Şekil 5.6b). Anlamlı noktalarla şeklin parça konturlara ayrılmasının gösterilmesi Şekil 5.6c'de mavi renkle resmedilmiştir.
- Her bir anlamlı nokta için parça konturlara uygulanan anlamsal ve şekilsel betimleyicilerin çıkarılması Şekil 5.6d'de verilmiştir.
- Şekil 5.6e'de ise her bir anlamsal ve şekilsel betimleyiciden oluşturulan kodlar gösterilmiştir.
- Betimleyicinin hem yerel hem de global olarak şekli temsil edebilmesi için 1x1, 2x2 ve 4x4 boyutlarında uzamsal piramit yapısı kullanılmış ve Şekil 5.6f'de bu kullanım gösterilmiştir.
- Şekli temsil eden histogramlar Şekil 5.6g'de görülmektedir.



Şekil 5.6. Şekil tabanlı bir betimleyici çıkarmanın adımları

- **VGG16:** Görsel Geometri Grubu (VGG) (Simonyan vd., 2014), özelliklerinin performansını, 3x3 gibi sabit boyutlu küçük filtreler kullanarak geliştirerek yeni bir standartlaştırılmış CNN mimarisi geliştirmiştir. VGG-16 modeli 144 milyon parametreyi barındırır. 3x3 boyutunda çok küçük alıcı alanlara sahip 16 adet evrişim katmanı, 5 adet uzamsal havuzu gerçekleştirmek için gereken 2x2 boyutunda maksimum havuzlama katmanları ve son tabakası softmax tabakası olan üç tam bağlantılı katman içerir. Doğrusal olmayan (ReLU) aktivasyonu tüm gizli katmanlara uygulanır. Model ayrıca, tam bağlı katmanlarda eksiltme (dropout) düzenini de kullanır. CNN mimarilerinde filtrelerin boyutunu küçültme girişimleri, uzun derin katmanlarda büyük veri kümelerini eğitirken hata oranlarını minimuma indirmek için yapılmıştır. VGG16 ile deneyler yaparken, çevrim (epoch) boyutu ve toplu iş (batch) boyutu sırasıyla 20 ve 16'ya sabitlenmiştir. İstatistiksel Eğitim Azalması (Stochastic Gradient Descent) olarak özelleştirilen optimizasyon fonksiyonu Momentum ve Başlangıç Öğrenme oranı ile birlikte 0.0001'dir

- **VGG19:** VGG19 (Simonyan vd., 2014), kullanılan yapı açısından VGG16'ya oldukça benzemektedir, fakat sadece VGG19'da ağırlık katmanları artırılmıştır. 3x3 filtreler kullanılmaktadır. Temel olarak model, konvolüsyon ve havuz katmanlarından oluşur ve hiç ayrılmamıştır. VGG16' da kullanılan aynı parametreler ile VGG19'da da aynı deneyler gerçekleştirilmiştir.

- **GoogleNet:** GoogleNet'in arkasındaki temel motivasyonda (Szegedy vd., 2015) hızlı bir ağ yapısı geliştirmenin yanı sıra AlexNet (Krizhevsky vd., 2012), VGG16 ve VGG19 gibi bilinen CNN mimarilerinin iç parametrelerini azaltarak, yüksek doğruluk puanları verecek

etkili ve verimli bir derin öğrenme aracı üretme amacı yatmaktadır. GoogleNet, ağdaki eğitilebilir parametrelerin büyük bir kısmını büyük ölçüde geride bırakan başlangıç modülünü tanıtan ilk mimariler arasında yer almaktadır. (Pawara, 2017) Başlangıç modülü, bir havuzlama katmanı ile birlikte 1×1 , 3×3 ve 5×5 konvolüsyonlarının paralel bir kombinasyonunu kullanır. Ek olarak, boyutsal indirgeme için 3×3 ve 5×5 evrişimlerinden önce ağa 1×1 evrişim filtre eklenir. Buna “ağdaki ağ” mimarisi denir. GoogleNet mimarisi, en fazla dört katmanlama katmanı ile birlikte bir ortalama havuz katmanını içeren 22 katman ve 9 başlangıç modülden yararlanır. ReLU, başlangıç modülleri içindekiler de dahil olmak üzere tüm evrişim katmanlarında kullanılır. Şebekedeki yok edici eğim problemini ele almak için, eğitim sürecinde iki yardımcı sınıfın katmanlarına eklenmiştir. Softmax sınıfına 0,4'lük bir bırakma oranı uygulanmıştır. Yine, sonuçların elde edilmesi aşamasında, GoogleNet’ de VGG16’ da kullanılan aynı çevrim boyutu, toplu iş büyüklüğü, ilk öğrenme oranı ve optimizasyon fonksiyonu ile deneyler yapılmıştır.

5.5.2.Sınıflandırıcılar


Sınıflandırıcılar, eğitim setinin özelliklerini modellemek ve test setinin performansını değerlendirmek için gerçekleştirilecektir. Bu çalışmada, dört farklı sınıflandırıcıyı

- (i) Geleneksel Vektörler için Destek Vektör Makinesi (SVM),
- (ii) Yapay Sinir Ağı (YSA)
- (iii) K-En Yakın Komşu (KNN)
- (iv) Softmax

sınıflandırıcı olarak kullanılmıştır.

• **DVM:** DVM, nesne algılamadan metin sınıflamasına kadar değişen desen tanıma görevlerini zorlamak için kullanılan yaygın bir sınıflandırıcıdır. Altta yatan fikir, aralarındaki kenar boşluğunu en üst düzeye çıkararak iki farklı sayısal veriyi ayıran doğrusal veya doğrusal olmayan karar düzleminin çıkarılmasıdır. Destek Vektör Makineleri karar sınırlarını tanımlayan karar düzlemleri kavramına dayanmaktadır. Bir karar düzlemi, farklı sınıf üyeliklerine sahip nesneler kümesi arasında ayrım yapan bir düzlemdir. Aşağıdaki resimde şematik bir örnek gösterilmiştir. Bu örnekte, nesneler ya

kırmızı ya da mavi sınıfına aittir. Ayırma çizgisi, tüm nesnelerin mavi olduğu ve solundaki tüm nesnelerin kırmızı olduğu sağ tarafta bir sınır tanımlar. Sağa düşen herhangi bir mavi olarak sınıflandırılır (veya kırmızı olarak sınıflandırılırsa, ayırma çizgisinin soluna düşmelidir). DVM 'nin iki farklı türü, lineer ve polinom olarak adlandırılmıştır.




Şekil 5.7. Destek Vektör Makineleri şematik gösterim

- **YSA:** Yapay sinir ağı (YSA), biyolojik sinir ağlarının yapı ve işlevlerine dayanan bir hesaplama modelidir. Bir YSA, yapay nöronlar (bir hayvan beynindeki biyolojik nöronların basitleştirilmiş bir versiyonu) olarak adlandırılan bağlı ünitelerin veya düğümlerin koleksiyonuna dayanır. Yapay nöronlar arasındaki bağlantılar (sinapsın basitleştirilmiş bir versiyonu) bir sinyali diğerine iletebilir. Sinyali alan yapay nöron onu işleyebilir ve ona bağlı yapay nöronları işaret edebilir. Ağ boyunca akan bilgi, bir sinir ağının değiştiği veya bir anlamda, bu giriş ve çıkışa bağlı olduğu için YSA' nın yapısını etkiler. YSA' lar, girdiler ve çıktılar arasındaki karmaşık ilişkilerin modellendiği veya kalıpların bulunduğu doğrusal olmayan istatistiksel veri modelleme araçları olarak kabul edilir.


YSA ayrıca bir sinir ağı olarak bilinir. YSA sınıflandırıcı, giriş, gizli ve çıkış katmanları dahil olmak üzere birbirine bağlı üç katmandan oluşur. Giriş katmanı, ayırt edilecek ağ yapısına yönlendirilen sınıfların özelliklerini içerir ve giriş nöronlarından oluşur. Bu nöronlar, veriyi ikinci katmana gönderirler ve bu da çıkış nöronlarını üçüncü katmana gönderir. Gizli katmanlar, sigmoid gibi bir aktivasyon fonksiyonu ile birlikte ağırlıklar ve bias parametreleri olan üç bileşeni içerir.

Yapay bir sinir ağı eğitimi, ilişkili birkaç algoritmanın bulunduğu izin verilen modellerden seçim yapmayı içerir. Diğer taraftan, ANN'nin son başı bir test numunesinin sınıf etiketini tahmin etmek için softmax gibi bir aktivasyon fonksiyonuna ev sahipliği yapar. 10 gizli katmanla deneyler yapılmıştır.



Şekil 5.8. ANN yapısının şematik gösterimi

- **K-NN:** Basit ve hızlı bir sınıflandırıcı olarak, K-NN test ve sınıf örnekleri arasındaki mesafelerin sıralanmasıyla belirlenen ilk k en benzer çıktıları gözlemleyerek test numunesinin sınıf etiketini tahmin eder. Şekil 5.9. 'da K-NN yapısının şematik gösterimi verilmiştir.



Şekil 5.9. K-NN yapısının şematik gösterimi.


Örüntü tanıma, k-NN sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir. Girdi, özellik alanındaki k en yakın eğitim örneklerinden oluşur. Çıktı, k-NN' nin sınıflandırma veya regresyon için kullanılmasına bağlıdır. k-NN sınıflandırmasında çıktı, bir sınıf üyeliğidir. Bir nesne, komşularının çoğunluk oyu ile sınıflandırılır; nesne, en yakın komşuları arasında en yaygın olan sınıfa atanır (k, genellikle küçük bir pozitif tamsayıdır). Eğer $k = 1$ ise, o zaman nesne sadece o en yakın komşunun sınıfına atanır. k-NN algoritması, tüm makine öğrenimi algoritmalarının en basitlerinden biridir. Eğitim örnekleri, her biri bir sınıf etiketine sahip çok boyutlu bir özellik alanındaki vektörlerdir. Algoritmanın eğitim aşaması, sadece eğitim örneklerinin özellik vektörlerini ve sınıf etiketlerini içerir. Sınıflandırma aşamasında k, kullanıcı tarafından tanımlanan bir sabittir ve etiketlenmemiş bir vektör (sorgu veya test noktası), bu sorgu noktasına en yakın k eğitim örnekleri arasında en sık kullanılan etiketle atanmasıyla sınıflandırılır. Bu çalışmada, k değeri, 11 olarak sezgisel olarak seçilmiş ve mesafeleri hesaplamak için Standart Euclidean mesafesi belirlenmiştir.

- **Softmax:** Softmax sınıflandırıcı, sonuç sayısı üzerinden olasılık dağılımını tahmin eder. Tembel bir sınıflandırıcı olarak, Softmax esas olarak, üstel işlevle dönüştürülen değerleri normalleştirerek olasılıkları hesaplar.

5.6. Deneysel Çalışma

5.6.1. Veri seti

Her bir sınıftan 200 görüntü olmak üzere 40 buğday sınıfından 640 x 512 boyutlarında toplam 8000 adet görüntü elde edilmiştir ve bu görüntülerin %20'si test için ayrılmıştır. Görüntüler görünür ışıktan (RGB, dalga boyu: 400 nm ila 800 nm) Görünür Yakın Kızılötesi (VNIR, dalga boyu: 400 nm ila 1100 nm) ve Kısa Dalga Kızılötesi (SWIR, dalga boyu: 900 nm ila 1700 nm) kameralar ile kontrollü bir çevrede elde edilmiştir. Çizelge 5.1. , 40 buğday sınıfının listesini göstermektedir ve Şekil 5.10 veri kümesine ilişkin bazı örnekleri göstermektedir.




Şekil 5.10. Çalışmada kullanılan buğday imge örnekleri

Şekil 5.11. SWIR, NIR, RGB kameralarının, örneklere sırasıyla yaklaşık 50, 30 ve 20 cm üzerinde konumlandığını gösterir. Kameraların gördükleri alan sırasıyla SWIR, VNIR ve RGB için örnek düzlemde yaklaşık 21x29 cm², 9x7 cm² ve 9x7 cm² bölgelerdir. Ana eksenin her iki tarafına iki adet 100 W halojen ışık kaynağı yerleştirilmiştir.

Çizelge 5.1. 40 Farklı Sınıfa Ait Veri Seti

Ahmetağa	Altay2000	Atay85	Aytın	Bayraktar2000
Bezostaja	Cesit1252	Çetiner	Dağdaş	Ekiz
Energo	Es26	Esperia	Flamura85	Gelibolu
Gerek79	Harmankaya	İzgi	KateA1	Kıraç
Kırgız	Kunduru	Mesut	Michelangelo	Midas
Müfitbey	Nacibey	Pehlivan	Porsuk	Reis
Renan	Selimiye	Sönmez	Soyer	Sultan95
Süzen	Tosunbey	Yelken	Yıldız	Yunus



Şekil 5.11. Görüntü yakalama sistemi.

5.6.2. Deneyler hakkında ayrıntılar

Önerilen yöntemin performansı ile ilgili genel bir fikir vermek için, elde edilen sonuçları Fscore ve confusion matrisinden hesaplanan objektif ölçümler açısından

değerlendirilmiştir. Doğruluk, tahmin edilen sonuçların gerçek değerlere (ground truths) yakınlığını ifade eder. Ayrıca, BoW ve CNN çerçeveleri için fikir birliği kurallarının Fscore'u da görselleştirilmiştir. Fscore, Gerçek Pozitif (TP), Yanlış Pozitif (FP) ve Yanlış Negatif (FN) oranlarına göre hesaplanır.

Eğitim aşamasında, her bir sınıfa ait örneklerin %80'i dikkate alınırken, geri kalan kısımlar test amaçlı kullanılmıştır. Bu da, eğitim aşamasında 6400 tane örneğin kullanıldığı anlamına gelir. Fikir birliği kuralını gerçekleştirmek için, her bir eğitim ve test numunesi ile ilişkili endeks, deney aşamalarından önce kaydedilmiştir ve bu kaydedilen örnekler her deneyde dikkate alınmıştır. Her bir yöntemin başarımı 1600 test örneğinde araştırılmıştır.

5.6.3. BoW çerçevesinin değerlendirmesi

BoW ve CNN çerçevelerinin başarımını değerlendirmek için, doğruluk puanlarına dayanan bazı nicel sonuçlar gösterilmiştir. Karşılaştırma için, her bir geleneksel yöntemin doğruluk sonucu Tablo 2'de elde edilmiş ve sergilenmiştir. Tablo 1'de gösterildiği gibi, farklı veri kümeleri için elde edilen ortalama doğruluk oranları SWIR %12.90, FUSION %16.33, RGB %22.33 ve VNIR %22.68 olarak sıralanmıştır. Tablo 2'den, VNIR veri kümesinin diğerlerine karşı en iyi performansı vereceğine karar verebiliriz. Yine, sonuçlar DSIFT' in en etkili geleneksel özellik çıkarma aracı olduğunu göstermektedir. SBFT metodu şekil odaklı olduğundan ve yerel Fourier Transform (FT) ile ilgili faz açıları histogramları olan bir buğday örneğinin altta yer alan gradyanlarının yerini alacak şekilde geliştirildiğinden, performansı diğerlerine göre oldukça düşüktür. Geleneksel tanımlayıcı çıkarma araçlarının, benzer buğday çekirdeği gibi doku modellerine uygun olmadığı anlamına gelir. Sınıflandırıcıların performansını inceledikten sonra, polinom çekirdekli SVM diğerlerinden daha iyi bir performans elde etmiştir.

Çizelge 5.2. BoW Özelliklerinin Fusion Üzerinde Doğruluğu

BoW özelliklerinin doğruluğu (%)					
FUSION					
	DSIFT	FFT	LBP	SIFT	SURF
SVM (Linear)	36.19	3.19	20.94	13.25	15.06
KNN	25.00	2.94	18.38	6.06	13.94
SVM(Polynomial)	39.00	2.88	22.31	14.44	16.06
ANN	28.06	3.31	20.31	11.13	14.13
Average	16.33				

Çizelge 5.3. BoW Özelliklerinin RGB Üzerinde Doğruluğu

RGB					
	DSIFT	FFT	LBP	SIFT	SURF
SVM (Linear)	36.94	4.13	30.63	19.63	30.00
KNN	23.44	2.69	23.56	7.94	22.13
SVM(Polynomial)	41.81	4.63	33.50	20.88	32.00
ANN	34.81	3.88	32.00	17.56	22.56
Average	22.23				

Çizelge 5.4. BoW Özelliklerinin SWIR Üzerinde Doğruluğu

SWIR					
	DSIFT	FFT	LBP	SIFT	SURF
SVM (Linear)	17.31	4.19	23.75	10.75	11.81
KNN	16.63	2.50	21.25	5.31	7.81
SVM(Polynomial)	19.69	4.44	26.06	10.63	12.69
ANN	16.63	5.38	23.00	7.94	10.31
Average	12.90				

Çizelge 5.5. BoW Özelliklerinin VNIR Üzerinde Doğruluğu

VNIR					
	DSIFT	FFT	LBP	SIFT	SURF
SVM (Linear)	37.69	4.63	28.88	23.13	31.06
KNN	25.63	2.50	22.38	10.13	15.56
SVM(Polynomial)	42.06	4.50	30.38	24.50	32.13
ANN	43.13	4.44	29.00	19.25	22.63
Average	22.68				

Dahası, oybirliği kuralının etkinliği incelenmiştir ve BoW çerçevesini değerlendirmek için yorumda bulunulmuştur. Geleneksel özellik çıkarma araçlarından elde edilen tahmin etiketleri üzerine fikir birliği kuralı uygulandığında, en iyi doğruluk %68.94 olarak elde edilmiştir, bu da buğday çeşitlerinin tanımlanması açısından tatmin edici doğruluk oranıdır.

Konsensüs kuralı 1600x80'lik kararlarla gerçekleştirilmiştir, yani bu da demek oluyor ki her bir örnek için 1600 test örneği ve 80 karar vardır. Bir buğday örneğinin sınıf etiketinin ataması durumunda, bu 80 kararda çoğunluk oyu kuralı dikkate alınmıştır.

5.6.4. CNN çerçevesinin değerlendirilmesi

Bu bölümde, FUSION, RGB, SWIR ve VNIR veri kümelerin CNN özelliklerinin sağlamlığı arttırılmıştır. Her bir veri setini GoogleNet, VGG16 ve VGG19 gibi iyi bilinen derin yapılara yönlendirerek üç kontrollü deney gerçekleştirilmiştir.

FUSION, RGB, SWIR ve VNIR veri kümeleri ile ilişkili ortalama doğruluk sonuçlarına bakarak doğruluk oranları belirlenmiştir. Bu elde edilen doğruluk oranları aşağıdaki gibidir;

- I. FUSION %92.17,
- II. RGB %98.58,
- III. SWIR %85.73,
- IV. VNIR %97.35.

Çizelge 5.5' te sunulan genel sonuçlara göre diğerleri ile kıyaslandığında en iyi puanlar RGB veri setinden elde edilmiştir. Ayrıca, derin ağ modelleri arasında, VGG19 hemen hemen her durumda baskın sonuçlar vermektedir. Uygun doğruluklar, sadece evrimsel modeller üzerinde deney yürütülmesi durumunda softmax sınıflandırıcı ile elde edilmiştir.

Çizelge 5.6. CNN özelliklerinin FUSION, RGB, SWIR, VNIR üzerindeki doğruluğu.



CNN özelliklerinin doğruluğu (%)					
	FUSION	RGB	SWIR	VNIR	Average
GoogleNet	86.44	98.13	87.94	94.88	91.84
VGG16	95.50	98.13	84.44	98.38	94.11
VGG19	94.56	99.50	84.81	98.81	94.42
Average	92.17	98.58	85.73	97.35	

Aynı şekilde BoW çerçevesinde olduğu gibi, CNN modelleri ile tahmin edilen kararlar üzerinde de fikir birliği kuralı uygulanmış ve başarımlar %99.94 doğruluk oranı ile rapor edilmiştir. Bu üstün performans, her bir test numunesi için 12 farklı tahmin etiketini içeren 1600x12 karar matrisinde oyçokluğu kuralının yerine getirilmesi durumunda sadece bir örneğin yanlış sınıflandırıldığını göstermektedir.

Deneyisel sonuçlar, daha derin ağ yapısının, en iyi performansın elde edilmesi açısından daha iyi olması anlamına gelir, yani VGG19, VGG16'dan daha sağlamdır.

5.6.5. CNN ve BoW çerçevelerinin karşılaştırılması

Bu aşamada, CNN ve BoW çerçevesi arasındaki avantajları ve avantajları ile avantajları karşılaştırılmıştır. Bu amaçla, her iki çerçeveye ilgili oyçokluğu kuralıyla tahmin edilen tek performans, Şekil 5.12. (a) ve Şekil 5.12. (b) ile görselleştirilmiştir. Performansı tüm yönleriyle değerlendirmek için, 40 sınıf için elde edilen doğruluk ve F-ölçüm skorları, adil bir karşılaştırma için Şekil 5.12. (a) ve Şekil 5.12. (b) ile özetlenmiştir.



Şekil 5.12. CNN ve BoW yöntemleri için Fscore ve doğruluk oranları.

Şekil 5.12. (a), CNN ve BoW çerçeveleri ile elde edilen her bir sınıfın doğruluğunu gösterir. Görüldüğü gibi, CNN modellerinde 40 sınıf için kararlı ve başarılı sonuçlar elde edilmiştir. Diğer taraftan, BoW yöntemi CNN yöntemine ayak uyduramamakta ve değişken ve düşük puanlar sunmaktadır. Yine, F-ölçüm skoruna baktığımızda, CNN çerçevesinin neredeyse her zaman 1'e yakın olan en yüksek puana ulaştığı açıktır.

Bu objektif iyi puanlar, düşük performansın sınırlandırılması için, buğday çeşitleri tanımlama sistemi geliştirmeye geldiğinde CNN modellerini göz önünde bulundurmalıdır. Ek olarak, genel değerlendirmeden, buğday sınıflandırma için daha derin ağ modellerinin daha doğru sonuçlar verdiğini gözlemleyebiliriz. Ne yazık ki, buğday tanımlama için geleneksel özelliklerin etkinliği, CNN özellik çıkarma araçları ile karşılaştırıldığında zayıf başarılı olarak bulunmuştur. BoW özellikleri şekil odaklı olduğundan, buğday gibi benzer tekrarlanan doku desenlerine uygulandığında çökmektedir.

6. BULGULAR VE TARTIŞMA

Bu çalışmamızla, buğday alımı-satımı sırasında fiyat tespitin daha objektif olarak yapılması ve buğday kalitesinin belirlenmesinde insan faktörüne bağımlılığını kaldırılması sonucu hem teknik hem ekonomik kazançlar elde edilmesi hedeflenmiştir. Projenin hedeflerine ulaşması ile ülkemizde gıda sanayi için kronik bir sorun haline gelen kaliteli buğday üretimi sorununa çözüm bulmaya çalışılmıştır.

Derin öğrenme özellikleri son yıllarda bilgisayar görüşünde yeni kavramlar önermiş ve kendi gerçeğini inşa etmiştir. Derin öğrenme yöntemleri tarafından sağlanan yüksek doğruluk oranları, genel olarak, her bir katmandaki girdiler ve özellikler arasında aşamalı olarak bağlantı kuran basamaklı konvolüsyon katmanları sayesinde elde edilir. Görüntü işleme alanındaki yeni fikir ve imkanlar ile, buğday çeşitlerinin hiperspektral görüntüleri tarafından elde edilen bazı CNN özellikleriyle sınıflandırma yapılmış ve yüksek doğruluk oranlarına ulaşılmıştır. İlk yöntemde VNIR kamera ve Alexnet kullanılarak sonuçlara ulaşıp değerlendirmeler yapılmıştır.

Bunun yanında diğer yöntemde buğday çeşitleri VNIR kamera ile birlikte, hem görünür ışık, hem de SWIR görüntüleme tekniklerinden elde edilecek bilgileri birleştirerek daha hassas bir şekilde belirlenmesi amaçlanmıştır. Ayrıca, betimleyiciler olarak, görüntü işleme, örüntü tanıma, bilgisayarla görü ve robotik uygulamalarda sıklıkla kullanılan SIFT, SURF, DSIFT, LBP ve SBFD gibi BoW özellikleri kullanılmıştır ve karar verme aşamasında SVM, ANN ve KNN sınıflandırıcılar ile birlikte bir oy çokluğu kuralı geliştirilmiştir.

Çalışma süresince uygun olmayan ortam koşulları, kamera problemleri, buğday yetersizliği, aydınlatmadan kaynaklı problemler olmuştur. Kullanılan aydınlatma yöntemleriyle bu problem en aza indirgenmeye çalışılmıştır. Sonrasında eldeki buğdaylara farklı yerlerden temin ettiğimiz buğdayları ekleyerek veritabanının büyütülmesi yoluna gidilmiştir. Kamera ve ortamdaki kaynaklanan problemler en aza indirgenerek çalışma tamamlanmaya çalışılmıştır. Farklı dalga boylarının buğdayın farklı içeriğini yansıtmaları mümkündür. Bu nedenle gelecek çalışmalarda, çoklu alt bantlar için ayrı görüntüler üreten

multispektral bir kamera kullanılması planlanmaktadır. Kararlı dalga boylarına yoğunlaşmanın başarı oranını daha da artıracğını düşünüyoruz.

Sonuç olarak, nüfusu hızla artan ülkemizde buğday üretimindeki artış, yüksek verimli ve kaliteli bir üretim yapmakla mümkündür. Bunu sağlayabilmek için de insan faktöründen bağımsız yöntemler gerekmektedir. Bu doğrultuda çalışmamızda makine öğrenmesine dayalı yöntemler geliştirilmeye çalışılmıştır.



7. SONUÇ VE ÖNERİLER

Görüntü işleme alanındaki yeni fikir ve imkanlar ile, buğday çeşitlerinin hiperspektral görüntüleri tarafından elde edilen bazı CNN özellikleriyle sınıflandırma yapılmış ve yüksek doğruluk oranlarına ulaşılmıştır. İlk önerilen yöntem 1400-1100 nm spektral bandı kapsayan VNIR görüntülemeye dayanmaktadır. Bu yöntemdeki sonuçları incelerken, FC6 kullanarak elde edilen sonuçların FC7'den biraz daha iyi olduğunu gözlemleyebiliriz. Buna ek olarak, yine sınıflandırma bakımından doğrusal DVM' nin polinom DVM' e göre biraz daha iyi sonuç verdiğini gözlemlenmiştir. Bu küçük farklılıkların yanı sıra, tüm sonuçların oldukça iyi olduğu açıktır. Görüntüleri elde etme, kırpma ve deneylerin nasıl yapıldığını kontrol etme, özellikleri birer birer analiz etme / karşılaştırma yapma, yanlılık ve şüpheyi neden olabilecek olası tüm unsurları ortadan kaldırma ile gibi aşamalarla aşağıdaki sonuçlara varılmıştır;

- CNN'nin FC6 ve FC7 verileri sınıflandırma için oldukça tanımlayıcı olmuştur.
- Kontrollü ve tarafsız bir ortamda yakalanan VNIR görüntülerinin katkısı fazladır.
- SVM, doğru özelliklerle beslendiğinde, sınıflandırmada oldukça başarılıdır.

Yöntem 2'de ise, RGB, VNIR, SWIR dahil olmak üzere farklı görüntüleme tekniklerinin kullanılmasının, buğday çeşitlerinin tanımlanması amacıyla geleneksel ve modern özellikli çıkarma araçları ile birlikte etkinliğini araştırmaktadır. Bu amaçla, buğday çeşitlerinin her birinden 200 örnek, toplam 8000 örnek olmak üzere 40 farklı buğday çeşidinde deneyler yapılmıştır. Deneysel aşamalar boyunca, buğday çeşitliliği tespiti üzerine uygulandığında BoW özelliklerinin sağlam olmadığını ve çöktüğünü gözlemledik. BoW çerçevesinin performans düşüşü çoğunlukla SIFT, SBFD, LBP, SURF ve DIFT gibi el yapımı özelliklerin sadece yerel varyasyonlara odaklanmış olmasından kaynaklanmaktadır. Bununla birlikte, yerel değişkenler, görüntü alanı boyunca sınıf değişkenliği ve benzer dokular içinde / arasında iken birbirine benzeyebilir. BoW özelliklerinden farklı olarak, derin öğrenme yapıları olarak adlandırılan entegre bir CNN

yapısı, mekansal bilgileri birleştirebilir ve buğday çeşitlerinde belirtilen ayırt edici ayrıntıları bilerek kullanabilir. Deneysel çalışmalar, CNN yönteminin, geleneksel özellik çıkarma araçlarıyla karşılaştırıldığında, %99,94 ve %68,04 oranında tutarlılık kuralıyla karşılaştırıldığında, daha sağlam bir performans sağladığına işaret etmektedir. CNN özellikleri ve VNIR kamerasına dayanan bir sistem, buğday endüstrisinde pahalı ekipman kullanmadan daha objektif ve doğru kararlar almak için yeterli olacaktır.



KAYNAKLAR DİZİNİ

- A. Krizhevsky, I. S. (2012). A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, Advances in neural information processing systems2012, pp. 1097-1105.
- A. Krizhevsky, I. S. (2012). A. Krizhevsky, I. Sutskever, G.E. Hinton, Imagenet classification with deep convolutional neural networks, Advances in neural information processing systems2012, pp. 1097-1105.
- A. Pourreza, H. P.-H.-F. (2012). A. Pourreza, H. Pourreza, M.-H. Abbaspour-Fard, H. Sadrnia, Identification of nine Iranian wheat seed varieties by textural analysis with image processing, Computers and electronics in agriculture, 83 (2012) 102-108.
- A. Vedaldi, B. F. (2010). A. Vedaldi, B. Fulkerson, VLFeat: An open and portable library of computer vision algorithms, Proceedings of the 18th ACM international conference on Multimedia, ACM2010, pp. 1469-1472.
- A.C. Mutlu, I. B.-A. (2011). A.C. Mutlu, I.H. Boyaci, H.E. Genis, R. Ozturk, N. Basaran-Akgul, T. Sanal, A.K. Evlice, Prediction of wheat quality parameters using near-infrared spectroscopy and artificial neural networks, European food research and technology, 233 (2011) 267-274.
- Ahonen, T. H. (2006). Ahonen, T., Hadid, A. and Pietikainen, M. (2006). Face Description with Local Binary Patterns: Application to Face Recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, 28(12), pp.2037-2041.
- B. Jaillais, P. R.-G. (2015). B. Jaillais, P. Roumet, L. Pinson-Gadais, D. Bertrand, Detection of Fusarium head blight contamination in wheat kernels by multivariate imaging, Food Control, 54 (2015) 250-258.
- Botsalı, F. M. (2010). Fatih M. Botsalı (2010). Yapay Sinir Ağı Ve Görüntü İşleme Teknikleri Kullanarak Durum Buğdayının Camsılığının Belirlenmesi.
- C. He, J. S. (2017). C. He, J. Shao, X. Xu, D. Ouyang, L. Gao, Exploiting score distribution for heterogenous feature fusion in image classification, Neurocomputing, 253 (2017) 70-76.
- C. Singh, D. J. (2009). C. Singh, D. Jayas, J. Paliwal, N. White, Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging, Journal of stored products research, 45 (2009) 151-158.

KAYNAKLAR DİZİNİ (devam)

- C. Szegedy, W. L. (2015). C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich, Going deeper with convolutions, Cvpr2015.
- C.B. Singh, D. J. (2012). C.B. Singh, D.S. Jayas, J. Paliwal, N.D. White, Fungal damage detection in wheat using short-wave near-infrared hyperspectral and digital colour imaging, International Journal of Food Properties, 15 (2012) 11-24.
- Choudhary, R. (2009). R. Choudhary, S. Mahesh, J. Paliwal, D. Jayas, Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples, Biosystems Engineering, 102 (2009) 115-127.
- En.wikipedia.org. (2018). *En.wikipedia.org. (2018). Speeded up robust features. [online] Available at: https://en.wikipedia.org/wiki/Speeded_up_robust_features [Accessed 1 Jun. 2018]. 2018 tarihinde https://en.wikipedia.org/wiki/Speeded_up_robust_features adresinden alındı*
- F. Guevara-Hernandez, J. G.-G. (2011). F. Guevara-Hernandez, J. Gomez-Gil, A machine vision system for classification of wheat and barley grain kernels, Spanish Journal of Agricultural Research, 9 (2011) 672-680.
- G. Lin, C. F. (2017). G. Lin, C. Fan, H. Zhu, Y. Miu, X. Kang, Visual feature coding based on heterogeneous structure fusion for image classification, Information Fusion, 36 (2017) 275-283.
- Gardezi, S. (2017). Gardezi, S. (2017). Mammogram classification using Deep learning features. In: IEEE International Conference on Signal and Image Processing Applications.
- Ghosh, S. M. (2016). Ghosh, S., Mishra, P., Mohamad, S., de Santos, R., Iglesias, B. and Elorza, P. (2016). Discrimination of peanuts from bulk cereals and nuts by near infrared reflectance spectroscopy. Biosystems Engineering, 151, pp.178-186.
- gubretas.com.tr, Gübretaş : Buğday Yetiştirme Tekniği. [online] Available at: <http://www.gubretas.com.tr/tr/icerik/11/1850/bugday-yetistirme-teknigi.aspx> [Accessed 27 Sep. 2017]. (2017). eylül 2017 tarihinde alındı*
- H. Bay, A. E. (2008). H. Bay, A. Ess, T. Tuytelaars, L. Van Gool, Speeded-up robust features (SURF), Computer vision and image understanding, 110 (2008) 346-359.

KAYNAKLAR DİZİNİ (devam)

- H. Cevikalp, M. N. (2005). H. Cevikalp, M. Neamtu, M. Wilkes, A. Barkana, Discriminative common vectors for face recognition, IEEE Transactions on pattern analysis and machine intelligence, 27 (2005) 4-13.
- H. Çevikalp, Z. K. (2013). H. Çevikalp, Z. Kurt, A.O. Onarcan, Return of the king: The Fourier transform based descriptor for visual object classification, Signal Processing and Communications Applications Conference (SIU), 2013 21st, IEEE2013, pp. 1-4.
- J. Xing, P. V. (tarih yok). J. Xing, P. Van Hung, S. Symons, M. Shahin, D. Hatcher, Using a short wavelength infrared (SWIR) hyperspectral imaging system to predict alpha amylase activity in individual Canadian western wheat kernels, Sensing and Instrumentation for Food Quality and .
- J. Xing, S. S. (2010). J. Xing, S. Symons, M. Shahin, D. Hatcher, Detection of sprout damage in Canada Western Red Spring wheat with multiple wavebands using visible/near-infrared hyperspectral imaging, Biosystems Engineering, 106 (2010) 188-194.
- J.G. Barbedo, C. T. (2015). J.G. Barbedo, C.S. Tibola, J.M. Fernandes, Detecting Fusarium head blight in wheat kernels using hyperspectral imaging, Biosystems Engineering, 131 (2015) 65-76.
- J.U. Ziegler, M. L. (2016). J.U. Ziegler, M. Leitenberger, C.F.H. Longin, T. Würschum, R. Carle, R.M. Schweiggert, Near-infrared reflectance spectroscopy for the rapid discrimination of kernels and flours of different wheat species, Journal of Food Composition and Analysis, 51 (2016)
- K. Özkan, Ş. I. (2015). K. Özkan, Ş. Işık, A novel multi-scale and multi-expert edge detector based on common vector approach, AEU-International Journal of Electronics and Communications, 69 (2015) 1272-1281.
- K. Özkan, Ş. I. (2016). K. Özkan, Ş. Işık, G.G. Dordinejad, Multispectral image fusion based on the common vector approach, INnovations in Intelligent SysTems and Applications (INISTA), 2016 International Symposium on, IEEE2016, pp. 1-6.
- K. Simonyan, A. Z. (2014). K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556, (2014).

KAYNAKLAR DİZİNİ (devam)

- Krizhevsky, A. S. (2012). Krizhevsky, A., Sutskever, I. and Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6), pp.84-90.
- L.M. Kandpal, S. L.-K. (2015). L.M. Kandpal, S. Lee, M.S. Kim, H. Bae, B.-K. Cho, Short wave infrared (SWIR) hyperspectral imaging technique for examination of aflatoxin B1 (AFB1) on corn kernels, Food Control, 51 (2015) 171-176.
- Lowe, D. (2004). D.G. Lowe, Distinctive image features from scale-invariant keypoints, International journal of computer vision, 60 (2004) 91-110.
- M. Gulmezoglu, V. D. (2001). M. Gulmezoglu, V. Dzharov, A. Barkana, The common vector approach and its relation to principal component analysis, IEEE Transactions on Speech and Audio Processing, 9 (2001) 655-662.
- M. Soto-Cámara, A. G.-J. (2012). M. Soto-Cámara, A. Gaitán-Jurado, J. Domínguez, Application of near infrared spectroscopy technology for the detection of fungicide treatment on durum wheat samples, Talanta, 97 (2012) 298-302.
- M.A. Shahin, S. S. (2011). M.A. Shahin, S.J. Symons, Detection of Fusarium damaged kernels in Canada Western Red Spring wheat using visible/near-infrared hyperspectral imaging and principal component analysis, Computers and Electronics in Agriculture, 75 (2011) 107-112.
- M.I. González-Martín, G. M.-P.-G.-M.-H. (2014). Chilean flour and wheat grain: tracing their origin using near infrared spectroscopy and chemometrics, Food chemistry, 145 (2014) 802-806.
- MikroTasarım. (2018). *mikro-tasarim*. haziran 1, 2018 tarihinde netvizyon.com.tr>, H. (2018). Mikro-Tasarım. [online] Mikro-tasarim.com.tr. Available at: <http://www.mikro-tasarim.com.tr/> [Accessed 1 Jun. 2018]. adresinden alındı
- Miralbés, C. (2008). C. Miralbés, Discrimination of European wheat varieties using near infrared reflectance spectroscopy, Food chemistry, 106 (2008) 386-389. 386-389.
- Pawara, P. &. (2017). Pawara, Pornntiwa & Okafor, Emmanuel & Surinta, Olarik & Schomaker, Lambert & Wiering, Marco. (2017). Comparing Local Descriptors and Bags of Visual Words to Deep Convolutional Neural Networks for Plant Recognition. 10.5220/0006196204790486.

KAYNAKLAR DİZİNİ (devam)

- Pietikäinen, M. (2010). Pietikäinen, M. (2010). Local Binary Patterns. [online] Available at: http://www.scholarpedia.org/article/Local_Binary_Patterns [Accessed 2 Jun. 2018]. Scholarpedia, 5(3), p.9775.
- R. Choudhary, J. P. (2008). Classification of cereal grains using wavelet, morphological, colour, and textural features of non-touching kernel images, Biosystems engineering, 99 (2008) 330-337.
- R.V. Rong, M. S. (2014). R.V. Rong, M.M. Sardeshmukh, Indian Wheat Seed Classification Based on Texture Analysis Using ANN, International Journal of Electrical, Electronics and Data Communication, 2 (2014) 2320-2084.
- Ravikanth, L. S. (2015). Ravikanth, L., Singh, C., Jayas, D. and White, N. (2015). Classification of contaminants from wheat using near-infrared hyperspectral imaging. Biosystems Engineering, 135, pp.73-86.
- S. Ergin, S. Ç. (2011). S. Ergin, S. Çakir, Ö.N. Gerek, M.B. Gülmezoğlu, A new implementation of common matrix approach using third-order tensors for face recognition, Expert Systems with Applications, 38 (2011) 3246-3251.
- S. Mahesh, A. M. (2008). S. Mahesh, A. Manickavasagan, D. Jayas, J. Paliwal, N. White, Feasibility of near-infrared hyperspectral imaging to differentiate Canadian wheat classes, Biosystems Engineering, 101 (2008) 50-57.
- S. Serranti, D. C. (2013). S. Serranti, D. Cesare, G. Bonifazi, The development of a hyperspectral imaging method for the detection of Fusarium-damaged, yellow berry and vitreous Italian durum wheat kernels, Biosystems engineering, 115 (2013) 20-30.
- Singh, C. J. (2010). Singh, C., Jayas, D., Paliwal, J. and White, N. (2010). Identification of insect-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging. Computers and Electronics in Agriculture, 73(2), pp.118-125.
- Ş. Işık, K. Ö. (2016). Ş. Işık, K. Özkan, Ö.N. Gerek, M. Doğan, A new subspace based solution to background modelling and change detection, International Journal of Intelligent Systems and Applications in Engineering, 4 (2016) 82-86.
- T. Ojala, M. P. (2002). T. Ojala, M. Pietikainen, T. Maenpää, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, IEEE Transactions on pattern analysis and machine intelligence, 24 (2002) 971-987.

KAYNAKLAR DİZİNİ (devam)

- T. Senthilkumar, D. J. (2017). T. Senthilkumar, D. Jayas, N. White, P. Fields, T. Gräfenhan, Detection of ochratoxin A contamination in stored wheat using near-infrared hyperspectral imaging, *Infrared Physics & Technology*, 81 (2017) 228-235.
- T. Senthilkumar, D. J. (2017). T. Senthilkumar, D. Jayas, N. White, P. Fields, T. Gräfenhan, Detection of ochratoxin A contamination in stored wheat using near-infrared hyperspectral imaging, *Infrared Physics & Technology*, 81 (2017) 228-235.
- Univie.ac.at. (2018). *Univie.ac.at. (2018). Visible Light Waves. [online] Available at: http://www.univie.ac.at/geographie/fachdidaktik/FD/site/external_htmls/imagers.gsfc.nasa.gov/ems/visible.html [Accessed 2 Jun. 2018].* haziran 2, 2018 tarihinde http://www.univie.ac.at/geographie/fachdidaktik/FD/site/external_htmls/imagers.gsfc.nasa.gov/ems/visible.html adresinden alındı
- X. Wang, B. F. (2014). X. Wang, B. Feng, X. Bai, W. Liu, L.J. Latecki, Bag of contour fragments for robust shape classification, *Pattern Recognition*, 47 (2014) 2116-2125.