

**ÜÇ FARKLI GÖRÜNTÜLEME TEKNİĞİNDEN ELDE EDİLEN
BİLGİLERİN BİRLEŞİMİ İLE BUĞDAY ÇEŞİTLERİNİN
SINIFLANDIRILMASI VE HASTALIKLI BUĞDAYLARIN
TESPİTİ**

Program Kodu: 1001

Proje No: 116O576

Proje Yürütücüsü:
Doç. Dr. Kemal ÖZKAN

Araştırmacılar:

Prof. Dr. Murat OLGUN
Doç. Dr. Onur KOYUNCU
Dr. Öğr. Üyesi Erol SEKE
Yük. Müh. Turgay ŞANAL
Araş. Gör. Dr. Şahin IŞIK

Bursiyerler:

Yük. Müh. Zeynep Duygu DEMİREZ
Büşra Topsakal YAVUZ

Mart 2019
ESKİŞEHİR



ÖNSÖZ

Kaliteli ve güvenli gıda ürün beklentilerinin artmasıyla birlikte, bu özelliklerin doğru, hızlı ve objektif kalite tespitine olan ihtiyaç gün geçtikçe artmaya devam etmektedir. Kalite güvencesi, herhangi bir endüstrinin en önemli hedeflerinden biridir. Sürekli olarak yüksek kaliteli ürünler üretme yeteneği, rekabet gücü yüksek gıda endüstrisindeki başarının temelidir. Buğday üretiminde en önemli faktörlerden birisi buğday bitkisinin kalite düzeyidir. Kaliteli bir üretim için sadece bitkinin sahip olduğu kalite düzeyi sorunu çözmekle; aynı zamanda tohumluk değerine olumsuz etki yapan aynı veya başka çeşit tohumların karışması, süne ve kımıl zararı, yabancı madde, kötü temizleme ve tasnif ve uygunsuz depolama şartları gibi faktörler tohumluk kalitesini düşürmektedir. 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. 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 tohumluluk 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. Bilgisayarla görü ve makine öğrenimi 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 bilgisayarla görü ve makine öğrenimi yoluyla objeleri sınıflandırmayı yüksek bir doğruluk oranıyla yapılabilir hale getirmiştir.

Çalışma, TARIM, ORMANCILIK ve VETERİNERLİLİK ARAŞTIRMA DESTEK GURUBU–TOVAG tarafından 1001 – BİLİMSEL VE TEKNOLOJİK ARAŞTIRMA PROJELERİNİ DESTEKLEME PROGRAMI kapsamında 116O576 proje numarası ile desteklenmiştir.

İÇİNDEKİLER

1. ÖZSÖZ	2
2. İÇİNDEKİLER	3
3. ÖZET	6
4. ABSTRACT	7
5. GİRİŞ	8
6. BUĞDAY VERİ SETİNİN OLUŞTURULMASI.....	10
7. HİPERSPEKTRAL GÖRÜNTÜLEME	15
8. KISA DALGA KIZILÖTESİ IŞIK (SHORT WAVE INFRARED)	15
9. YAKIN GÖRÜNÜR KIZILÖTESİ IŞIK DALGASI (VISIBLE INFRARED LIGHT WAVE)	16
10. GÖRÜLEBİLİR IŞIK DALGALARI	16
11. FARKLI DALGA BOYLU GÖRÜNTÜLERLE BUĞDAY SINIFLANDIRILMASI	18
12. FOURIER TEMELLİ ŞEKİL TABANLI BETİMLEYİCİ	19
13. DENEYSEL ÇALIŞMALARDA KULLANILAN ÖLÇÜM YÖNTEMLERİ	21
14. SWIR, VNIR VE RGB GÖRÜNTÜLERİNİN FÜZYONU	22
15. ORTAK VEKTÖR YAKLAŞIMI İLE İMGE FÜZYONU	23
16. THE BROVEY TRANSFORM (BT) TABANLI FÜZYON	25
17. INTENSITY-HUE-SATURATION (IHS) TABANLI FÜZYON	25
18. DISCRETE COSINE TRANSFORMATION (DCT) TABANLI FÜZYON	25
19. GELENEKSEL ÖZNİTELİK ÇIKARIMI VE KELİMELE ÇANTASI YÖNTEMİ İLE ELDE EDİLEN DENEYSEL SONUÇLAR	25
20. DERİN ÖĞRENME TABANLI YÖNTEMLER	26
21. ALEXNET MODELİ	26
22. ÖZNİTELİK (FEATURE) FÜZYONU YÖNTEMLERİ	28
23. GÖRÜNTÜ TABANLI FÜZYONUN DENEYSEL SONUÇLARI	30
24. SÜNE BÖCEĞİ ETKİSİNE KALMIŞ TASNİF DIŞI BUĞDAY ÇALIŞMALARI	30
25. KAYNAKLAR	33

Şekiller Listesi

1. Çalışmada kullanılmış olan SWIR Kamera	16
2. Çalışmada kullanılmış olan VNIR Kamera	16
3. Çalışmada kullanılmış olan Halojen Ampuller	16
4. Her üç kanaldan elde edilen örnek görüntüler	17
5. Görüntü yakalama düzeni	17
6. Füzyon deneylerinde kullanılmak için oluşturulan görüntü kayıt ortamı	18
7. Buğday çeşidinin tanımlanması için önerilen sistemin genel süreci	20
8. RGB, SWIR ve VNIR kanalları üzerinden füzyon işleminin görselleştirmesi	23
9. RGB, SWIR, VNIR ve FUSION veri kümesine ilişkin bazı örnekler	24
10. Kırmızı, Yeşil, Mavi, VNIR ve SWIR dahil beş kanalın füzyonu için görselleştirme	25
11. AlexNet yapısının genel akışı	27
12. Test aşaması	27
13. CNN Mimarilerine Dayanan İkinci Yöntemin Gösterimi	28
14. Süne zararlısına uğramış ve kaliteli buğday	30

Tablolar Listesi

1. Gıda üzerine yapılan farklı dalga boylarındaki çalışmalar	8
2. Anadolu Beyaz Sert (1260) Buğdaylar	10
3. Anadolu Kırmızı Sert (1270) Buğdaylar	11
4. Diğer Beyaz Buğdaylar	11
5. Diğer Kırmızı Buğdaylar	12
6. Makarnalık Buğdaylar	13
7. Süne Emgisinin Buğday kalitesine etkisi	14
8. İki sınıflı bir örnekte karışıklık matrisi	21
9. Geleneksel yöntemlerimin başarımlar oranı	26
10. FC6 ve FC7 özellikleri üzerindeki Linear ve Quadratic Kernel SVM skorları	27
11. FUSION, RGB, SWIR, VNIR üzerindeki CNN özelliklerinin doğruluğu (%)	28
12. Öznitelik uzayında yapılan füzyonun genel performans	29
13. Görüntü alanı üzerinde yapılan füzyon için genel performansı	30
14. MPEG 7 veri seti sonuçları	31
15. Hayvan veri seti sonuçları	31
16. Yaprak veri seti sonuçları	31
17. Caltech 101 veri seti sonuçları	31
18. Süne zararlısına uğramış buğday veri seti sonuçları	31

ÜÇ FARKLI GÖRÜNTÜLEME TEKNİĞİNDEN ELDE EDİLEN BİLGİLERİN BİRLEŞİMİ İLE BUĞDAY ÇEŞİTLERİNİN SINIFLANDIRILMASI VE HASTALIKLI BUĞDAYLARIN TESPİTİ

ÖZET

Tarım endüstrisinde makine öğrenme ve derin öğrenme sistemlerinin kullanımı oldukça büyük bir artış göstermiştir. Tarımsal ürünlerin çeşitlerinin tanınması sınıflandırılması üretim kalitesini ve verimliliğini olumlu yönde etkilemektedir. Tarım ürünleri arasında buğday ülkemizde ve dünyada insanların ihtiyaçlarını karşılaması açısından gıda ve sanayi sektöründe oldukça büyük bir paya sahiptir. Dolayısıyla üretiminin sağlanması ve devamlılığı ülkemiz ve dünya ekonomisi adına da oldukça önemlidir. Buğdayın çeşitlerinin tanınması ve sınıflandırılması da üretim kalitesini doğrudan etkilemektedir. Doğru sınıflandırma ve tanıma yapılabilmesi için yeni teknolojik sistemler geliştirilmektedir. Bu sayede insan gücü en aza indirilerek zamandan ve emekten tasarruf sağlanır. Bu proje kapsamında üç farklı görüntüleme tekniğinden (RGB, VNIR, SWIR) elde edilmiş buğday görüntüsünden oluşturulan veri seti üzerinde tanıma ve sınıflandırma çalışmaları yapılmıştır. Bu kapsamda geleneksel betimleyiciler ve kelimeler çantası modelinin yanı sıra derin öğrenme yöntemleri de proje kapsamında kullanılmıştır. İlaveten oy çokluğu kuralı, CNN ve BoW çerçevelerinin öngördüğü kararlar üzerine kurulmuştur. Tanıma doğruluğunu arttırmak adına öncelikle imge (image) füzyonu ve öznelilik (feature) füzyonu olmak üzere iki farklı füzyon yöntemi uygulanmıştır. Eğitimler sonucu elde edilen sonuçlara göre derin öğrenme yöntemlerinin parametrik bağımlılara göre daha başarılı olduğu görülmüştür. Geliştirilen bu sistem etkili ve zahmetsiz tanımlama ve sınıflandırma imkânı sunarken aynı zamanda derin öğrenme teknolojisinin buğday çekirdeği türlerini yüksek performans ile ayırt edebileceğini göstermektedir. Ülke ekonomisinde büyümeye yaptığı katkının yanı sıra buğday endüstrisinde insan iş gücünü azaltarak daha fazla verimlilik ve üretkenlik sağlamak adına önemli bir adım atılmasını sağlamaktadır.

Anahtar Kelimeler : Buğday Danesi Sınıflandırma, Süne Zararlısı, Hiperspektral Görüntüleme, Füzyon



DISEASE DETECTION AND CLASSIFICATION OF WHEAT KERNEL TYPE USING FUSED INFORMATION FROM THREE IMAGING TECHNIQUE

ABSTRACT

The use of machine learning and deep learning systems in the agricultural industry is increased considerably. Recognition and classification of agricultural products positively affect production quality and productivity. Among the agricultural products, wheat has a large share in the food industry in terms of supplying the needs of people in our country and the world. Therefore, the continuity of production is crucial for our country and the world economy. Recognition and classification of wheat varieties directly affect production quality. New technological systems have been developed for accurate classification and recognition. In this way, manpower is minimized, time and labor are saved. In the research presented here, recognition and classification are performed on the data set consisting of wheat images obtained from three different imaging techniques; RGB, VNIR, SWIR. The traditional descriptors and the words bag model as well as deep learning methods (Conventional neural network, CNN) are used in the scope of this study. Additionally, a consensus rule is established on decisions predicted by CNN and BoW frameworks for wheat cultivar detection. In order to increase the accuracy of recognition, two different fusion methods were performed; image fusion and feature fusion. According to the results of obtained by simulations, deep learning methods were found to be more successful than parameter dependent ones. Developed system provides effective and effortless identification and classification, demonstrating that deep learning methods can distinguish wheat seed species with high performance. In addition to the contribution to national economy, an important step is taken to ensure greater efficiency and productivity by reducing human labor in wheat industry..

Keyword: Wheat Kernel Classification, Sunn Pest, Hyperspectral Imaging, Fusion

GİRİŞ

Kaliteli ve güvenli gıda ürün beklentilerinin artmasıyla birlikte, bu özelliklerin doğru, hızlı ve objektif kalite tespitine olan ihtiyaç gün geçtikçe artmaya devam etmektedir. Kalite güvencesi, herhangi bir endüstrinin en önemli hedeflerinden biridir. Sürekli olarak yüksek kaliteli ürünler üretme yeteneği, rekabet gücü yüksek gıda endüstrisinde başarının temelidir. Müşterilerdeki sadakati teşvik eder ve pazar payının artmasına neden olur. Gıda endüstrisinde kullanılan kalite güvence yöntemleri, geleneksel olarak insan gözle muayenesini içermektedir. Bu tür yöntemler sıkıcı, zahmetli, zaman alıcı ve tutarsızdır. Artan ürün miktarı ve kalite ölçüm yöntemleri ile birlikte, kalite güvencesi ve kalite kontrolü için otomatik yöntemler kullanmak gerekli hale gelmiştir (Gunasekaran, 1996). Ayrıca, tüketicilerin artan farkındalığı ve sofistike olması, gelişmiş kaliteli gıda ürünleri beklentisini oluşturmuştur. Tüketiciler her zaman üstün gıda ürünleri kalitesi, yani, münferit bir gıda maddesi için daha yüksek kalite, toplu halde ürünlerin tutarlılığı ve bir bütün olarak gelişmiş gıda güvenliği talep etmektedirler (Nagata vd., 2005). Genel olarak, bir kalite değerlendirmenin otomatik hale getirilmesi sadece kalite güvencesini optimize etmekle kalmaz, aynı zamanda ve daha önemlisi insanın öznelliğini ve tutarsızlığını ortadan kaldırmaya yardımcı olur. Son zamanlarda yapılan çalışmalar, görsel gözlemlerin öznelliğini ortadan kaldırmak için insan gözlemcinin kullandığı görsel ipuçlarını keşfetmek için bilgisayarla görü ve makine öğrenimini kullanımı artmıştır. (Barbedo vd.,2018; Delwiche vd., 2013; Lancelot vd., 2017).

Bilgisayarla görü ve makine öğrenimi 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 bilgisayarla görü ve makine öğrenimi yoluyla objeleri sınıflandırmayı yüksek bir doğruluk oranıyla yapılabilir hale getirmiştir. İlk yapılan çalışmalarda ağırlıklı olarak RGB görüntüleme yani görülebilir tayfı ölçerek ve bu yolla öznelite çıkarımıyla sınıflandırma çalışmaları literatürde daha yaygındır. Ancak RGB görüntülemekten elde edilebilecek bilgiler sadece görünür ışık tayfından 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.

Bilgisayar destekli kalite denetim sistemleri hakkında uluslararası alanda farklı çalışmalar yapılmıştır. Bu çalışmalardan hiperspektral kamera ile gıda üzerine yapılan çalışmaların bir özeti Tablo 1'de verilmiştir. Tablo 1'de buğday üzerine yapılan çalışmalar en altta gösterilmiştir.

Tablo 1. Gıda üzerine yapılan farklı dalga boylarındaki çalışmalar

Gıda	Analiz	Dalga Boyu (nm)	Sınıflandırıcı	Referans
Çilek	Sıklık ve çözünabilir katı içeriğinin ölçümü	650-1000, 450-650	Aşamalı Çoklu Doğrusal Regresyon	Nagata vd. (2005), Nagata vd. (2004)
Elma	Berelenmeleri Algılama	400-1000	Temel Bileşen Analizi	Xing vd. (2005)
Elma	Berelenmeleri Algılama	900-1700	Temel Bileşen Analizi ve Maksimum Gürültü Fraksiyonu	Lu (2003)

Elma	Dışkı bulaşması algılama	450-851	Temel Bileşen Analizi	Kim vd.(2002)
Elma	Dışkı bulaşması algılama	452-729 ve 465-900	Band oranı	Lefcourt vd. (2006)
Elma	Yüzey kusurları ve yabancı maddelerin tespiti	430-900	Asimetrik ikinci fark yöntemi	Mehl vs.(2004)
Elma	Acı çekirdeklerin ölçümü	900-1700	Ayırıcı kısmi en küçük kareler regresyonu	Nicolai vd.(2006)
Çilek	pH değeri algılama	400-1000	Kısmi en küçük kareler regresyonu ve çoklu lineer regrasyonu	ElMasry vd.(2007)
Şeftali	Sertlik ölçümü	500-1000	Çoklu lineer regrasyon	Lu ve Peng (2005)
Mantar	Donma hasarı	400-1000	Temel Bileşen Analizi, Linear ayırıcı analizi	Gowen vd (2009)
Salatalık	Berelenmeleri Algılama	900-1700	Temel Bileşen Analizi	Ariana vd (2006)
Salatalık	Soğutma zararların incelenmesi	450-950	Temel Bileşen Analizi, Lineer ayırıcı analizi	Cheng vd (2004)
Mısır	Nem ve yağ içeriği tahmini	750-1090	Kısmi en küçük kareler regresyonu	Cogdill vd(2004)
Mısır	Sertliğine göre mısır sınıflandırma	1000-2498	Kısmi en küçük kareler regresyonu	Williams vd (2009)
Buğday	8 farklı buğday çeşidini sınıflandırma	960-1700	Yapay sinir ağları	Mahesh vd (2008)
Buğday	13 farklı buğday çeşidini sınıflandırma	960-1700	Yapay sinir ağları	Choudhary vd.(2009)
Buğday	5 farklı buğday çeşidini sınıflandırma	960-1700	Lineer ayırıcı analizi	Mahesh vd (2011)
Buğday	Protein tahmini ile sınıflandırma	----	Kimyasal yöntemler	Koenig vd (2015)
Buğday	Mantar bozulmasına uğramış buğdayların sınıflandırılması	1000-1600	Destek vektör makineleri	Zhang vd (2007)
Buğday	Böcek hasar tespiti	1000-1600	Lineer ayırıcı analizi	Singh vd (2009ve2010a)
Buğday	Titresineği-hasarlı buğday tanelerinin tanınması	700-1100	İstatistiksel analiz	Singh vd (2010b)
Buğday	Buğday içindeki yabancı madde	1000-1600	Yapay sinir ağları, en yakın komşuluk, Bayes	Radhika ve Sardeshmukh (2014)

Bu çalışma, özellikle buğdayların kalitesi üzerinedir. Buğday insan beslenmesinde kullanılan kültür bitkileri arasında dünyada ekiliş ve üretim bakımından ilk sırada yer almaktadır. Bunun sebebi buğday bitkisinin geniş bir adaptasyon yeteneğine sahip olmasıdır. Ayrıca buğday tanesi uygun besleme değeri, saklama ve işlenmesindeki kolaylıklar nedeniyle yaklaşık olarak 50 ülkenin temel besini durumundadır. Buğday başta unlu mamuller olmak üzere birçok gıda ve sanayi sektöründe kullanılmaktadır. Ülkemizde hızla artan nüfusun beslenmesinde üretilen buğday miktarının büyük önemi vardır. Gerek dünya ve gerekse ülkemizde özellikle buğday üretiminde herhangi bir nedenle azalma olduğunda gerek ekmek fiyatları veya gerekse undan yapılan gıda maddelerinin fiyatları yükselerek doğrudan herkesi etkilemektedir. Bu nedenle her ülke için buğday üretimi açısından yeterli olmak ve stoklarında yeterince buğday ürünü bulundurmamak stratejik bir önem arz etmektedir. 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 (Gubretas.com.tr, 2019).

Kaliteli bir üretim için sadece bitkinin sahip olduğu kalite düzeyi sorunu çözmemekte; aynı zamanda tohumluk değerine olumsuz etki yapan aynı veya başka çeşit tohumların karışması, süne ve kımıl zararı, yabancı madde, kötü temizleme ve tasnif ve uygunsuz depolama şartları gibi faktörler tohumluk kalitesini düşürmektedir. 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. 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 tohumluluk 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 başlanmış 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.

BUĞDAY VERİ SETİNİN OLUŞTURULMASI

Toprak Mahsülleri Ofisi buğday alım baremi dikkate alınarak Anadolu beyaz sert (1260) ekmeklik buğday grubundan; Adana-99, Ceyhan-99 ve Tosunbey, Anadolu kırmızı sert (1270) ekmeklik buğday grubundan; Quality, Bezostaja-1, Rumeli, Esperia, Krasunkaya, Alparslan ve Sagittario, diğer beyaz (1360) ekmeklik buğday grubundan; Bayraktar-2000, Cemre, Konya-2002, Altınbaşak, Karahan-99, Kaşifbey-95, Kenanbey, Eser ve Sultan-95, Diğer kırmızı (1370) ekmeklik buğday grubundan; Ahmetağa, İkizce-96, Katea-1, Gelibolu, Köprülü, Midas, Pehlivan,

Rumeli, Saban, Şanlı, Selimiye, Sönmez-2000 ve makarnalık buğday grubundan; Kızıltan-91, Eminbey, İmren, Ank-98 ve Ç-1252 temin edilmiştir¹.

Öncelikle temin edilen çeşitler, yabancı madde yönünden mekanik olarak temizlendikten sonra, mekanik ayırma ile ayrılmayan süne emgili taneler gözle büyüteç altında sağlam tanelerden ayrılmıştır. Temizlenen buğday örneklerinin hektolitre ağırlığı, bin tane ağırlığı Zeleny sedimentasyon analizleri, makarnalık buğdaylarda ise hektolitre ağırlığı, bin tane ağırlığı SDS sedimentasyon analizleri yapılmıştır ve değerler aşağıda tablo 2, 3, 4, 5 ve 6 da verilmiştir. Süne zararının tespit edilmesi için yapılması planlanan çalışmada süne emgili örnekler ve sağlam örnekler belirlenmiştir. Süne emgili tanelerin tespitinde; un olarak Bühler değirmeninde öğütülen örneklerde Zeleny sedimentasyon analizi ile aynı örnekte 2 saat bekletilerek yapılan beklemeli sedimentasyon analizi arasındaki fark dikkate alınarak belirlenmiştir. Genel olarak süne emgisi olmayan örneklerin beklemeli Sedimentasyon değeri Zeleny sedimentasyon değerinden yüksek çıkmaktadır. Süne emgili örneklerde beklemeli sedimentasyon değerlerinde düşme görülmektedir (tablo 7). Düşme derecesi o örneğin görmüş olduğu süne zararı ile doğru orantılıdır.

Tablo2. Anadolu Beyaz Sert (1260) Buğdaylar

Çeşit	Hektolitre Ağırlığı (kg/hl)	Bin Tane Ağırlığı (g)	Tane Proteini (%)	Rutubet (%)
Tosunbey	81,316	34,677	12,477	8,972
Tosunbey	80,975	34,409	11,872	9,504
Adana99	81,550	31,704	11,200	11,500
Adana99	81,424	38,282	12,500	11,376
Ceyhan-99	80,652	40,062	11,242	6,855
Ceyhan-99	80,294	39,686	10,512	6,937
Ortalama	80,446	36,470	11,634	9,191
En Büyük	81,424	40,062	12,500	11,500
En Küçük	78,015	31,704	10,512	6,855
Standart Sapma	1,153	3,074	0,721	1,861

Anadolu beyaz sert grubunda ortalama; hektolitre ağırlığı 80,44 kg/hlt, Bin tane ağırlığı 36,47 g, protein oranı %11,634 ve rutubet %9,191 olmuştur. En yüksek hektolitre ağırlığı, bin tane ağırlığı, protein oranı ve rutubet oranına sırası ile 81,487 kg/hlt ile Adana -99, 39,874 g ile Ceyhan-99, %11,85 ile Adana-99 ve %11,438 ile Adana-99 çeşitleri sahip olmuştur.

Tablo 3. Anadolu Kırmızı Sert (1270) Buğdaylar

Çeşit	Hektolitre Ağırlığı (kg/hl)	Bin Tane Ağırlığı (g)	Protein (%)	Rutubet (%)
Qulity	78,105	36,044	11,706	8,629

¹ Bu farklı sınıftaki / çeşitteki buğdaylar ve hastalık (özellikle süne böceğinin sebep olduğu) / yabancı madde içeren buğdaylar Eskişehir Ticaret Borsası ve Eskişehir Toprak Mahsulleri Ofisi, Eskişehir Osmangazi Üniversitesi Ziraat Fakültesi'nden temin edilmiştir. Buğday temininde, projeyi destekleyen Eskişehir Ticaret Borsası ve Eskişehir Toprak Mahsulleri Ofisi'ne katkılarından dolayı teşekkür ederiz

Qulity	77,261	34,899	11,799	8,739
Krasunkaya	78,966	32,776	11,700	9,047
Krasunkaya	77,800	33,100	11,500	9,080
Esperia	80,383	34,424	11,516	8,777
Esperia	80,545	36,042	11,680	9,355
Rumeli	81,478	34,935	11,560	8,820
Rumeli	80,980	35,300	11,400	8,600
Bezostaja-1	79,827	36,931	14,192	9,705
Bezostaja-1	79,600	36,400	14,200	9,600
Sagittario	78,535	38,837	13,200	11,064
Sagittario	77,172	38,124	13,000	10,980
Aldane	78,435	38,224	13,200	10,985
Aldane	78,635	38,024	12,800	10,975
Alparslan	78,335	38,074	13,100	10,960
Alparslan	78,735	38,174	13,300	11,00
Ortalama	79,221	35,651	12,288	9,366
En Büyük	81,478	38,837	14,200	11,064
En Küçük	77,172	32,776	11,400	8,600
Standart Sapma	1,404	1,738	1,018	0,817

Anadolu kırmızı sert grubunda ortalama; hektolitre ağırlığı 79,221 kg/hlt , Bin tane ağırlığı 35,651 g, protein oranı %12,288 ve rutubet %9,366 olmuştur. En yüksek hektolitre ağırlığı, bin tane ağırlığı, protein oranı ve rutubet oranına sırası ile 81,229 kg/hlt ile Bezostaja-1, 38,4805 g ile Sagitatio, %14,196 ile Bezostaja-1 ve %11,022 ile Sagitario çeşitleri sahip olmuştur

Tablo 4. Diğer Beyaz Buğdaylar

Çeşit	Hektolitre Ağırlığı (kg/hl)	Bin Tane Ağırlığı (g)	Proteini (%)	Rutubet (%)
Bayraktar-2000	80,168	35,273	12,600	9,702
Bayraktar-2000	80,401	35,985	12,900	9,497
Karahan-99	78,553	31,214	11,900	9,010
Karahan-99	78,392	30,831	11,600	9,054
Kenanbey	76,795	34,820	11,700	9,171
Kenanbey	76,420	34,600	11,400	9,000
Eser	77,997	33,725	9,310	8,944
Eser	77,423	34,320	10,549	8,709
Sultan-95	79,271	33,006	9,303	8,903
Sultan-95	79,109	34,571	9,681	8,905
Altınbaşak	80,599	31,222	12,000	6,021

Altınbaşak	79,300	30,900	12,810	6,040
Cemre	79,737	36,852	12,900	6,580
Cemre	79,594	36,715	12,600	6,192
Kaşifbey	76,759	30,460	12,300	10,294
Kaşifbey	76,600	30,800	12,000	10,000
Konya-2002	81,944	33,701	10,714	9,006
Konya-2002	80,886	33,500	10,645	9,028
Alpu-2001	80,286	33,500	10,345	9,028
Alpu-2001	81,486	33,350	10,745	9,128
Altay-2000	76,700	33,650	12,100	9,128
Altay-2000	76,500	30,800	11,900	9,228
Ayyıldız	79,837	31,000	11,850	8,928
Ayyıldız	79,637	30,600	12,150	9,142
Ortalama	78,886	33,472	11,495	8,559
En Büyük	81,944	36,852	12,900	10,294
En Küçük	76,420	30,460	9,303	6,021
Standart Sapma	1,587	2,066	1,169	1,321

Diğer beyaz buğday grubunda ortalama; hektolitre ağırlığı 78,886 kg/hlt, Bin tane ağırlığı 33,472 g, protein oranı %11,495 ve rutubet %8,559 olmuştur. En yüksek hektolitre ağırlığı, bin tane ağırlığı, protein oranı ve rutubet oranına sırası ile 81,415kg/hlt ile Konya-2002, 36,783 g ile Cemre, %12,75 ile Cemre ve %10,147 ile Kenanbey çeşitleri sahip olmuştur.

Tablo 5. Diğer Kırmızı Buğdaylar

Çeşit	Hektolitre Ağırlığı (kg/hl)	Bin Tane Ağırlığı (g)	Tane Protein (%)	Rutubet (%)
Ahmetağa	80,132	37,564	10,771	8,908
Ahmetağa	80,450	37,200	10,600	8,800
Gelibolu	71,609	33,378	12,600	10,546
Gelibolu	70,500	34,000	12,800	10,612
İkizce-95	79,271	36,250	13,000	8,828
İkizce-95	79,000	36,400	12,800	8,800
Katea-1	79,702	30,020	13,600	9,189
Katea-1	79,600	30,120	12,800	9,000
Köprülü	77,566	38,399	9,652	8,995
Köprülü	77,400	36,000	9,400	8,600
Midas	70,600	29,000	12,500	10,812
Midas	71,197	28,925	12,486	8,451
Pehlivan	79,684	44,875	15,200	6,885

Pehlivan	78,589	45,131	13,400	7,030
Rumeli	71,968	29,041	14,752	10,553
Rumeli	71,968	29,041	14,752	10,553
Saban	80,294	41,793	12,001	9,309
Saban	80,240	42,342	12,012	8,966
Selimiye	81,908	32,000	11,311	9,204
Selimiye	80,200	31,574	11,600	9,224
Sönmez	78,822	30,484	11,800	9,614
Sönmez	78,600	30,700	11,200	9,500
Şanlı	81,334	40,500	12,110	9,235
Şanlı	81,119	41,000	12,039	9,114
Ortalama	77,817	35,509	12,193	9,138
En Büyük	81,908	45,131	15,200	10,812
En Küçük	70,500	28,925	9,400	6,885
Standart Sapma	3,662	5,143	1,356	0,935

Diğer kırmızı buğdaylar grubunda ortalama; hektolitre ağırlığı 77,817 kg/hlt, Bin tane ağırlığı 45,131 g, protein oranı %15,02 ve rutubet %9,138 olmuştur. En yüksek hektolitre ağırlığı, bin tane ağırlığı, protein oranı ve rutubet oranına sırası ile 81,0745kg/hlt ile Saban, 45,003 g ile Pehlivan, %14,3 ile Pehlivan ve %10,579 ile Gelibolu çeşitleri sahip olmuştur.

Tablo 6. Makarnalık Buğdaylar

Çeşit	Hektolitre Ağırlığı (kg/hl)	Bin Tane Ağırlığı (g)	Proteini (%)	Rutubet (%)
Ank-98	76,219	41,061	15,800	9,870
Ank-98	75,950	41,960	15,600	9,786
Ç-1252	79,543	43,228	15,030	9,653
Ç-1252	79,865	42,850	14,600	9,560
Eminbey	76,168	40,691	15,864	9,666
Eminbey	76,800	41,200	15,200	9,500
İmren	78,367	37,575	14,510	9,633
İmren	77,960	36,890	14,230	9,450
Kızıltan-91	76,321	40,629	14,200	9,195
Kızıltan-91	76,120	39,780	13,900	9,000
Ortalama	77,331	40,586	14,893	9,531
En Büyük	79,865	43,228	15,864	9,870
En Küçük	75,950	36,890	13,900	9,000
Standart Sapma	1,416	1,949	0,672	0,250

Makarnalık buğdaylar grubunda ortalama; hektolitre ağırlığı 77,331 kg/hlt, Bin tane ağırlığı 40,586 g, protein oranı %14,893 ve rutubet %9,531 olmuştur. En yüksek hektolitre ağırlığı, bin tane ağırlığı, protein oranı ve rutubet oranına sırası ile 79,904 kg/hlt ile Ç-1252, 43,945 g ile Ç-1252, %14,532 ile Eminbey ve %9,828 ile Ank-98 çeşileri sahip olmuştur.

Tablo 7. Süne Emgisinin Buğday kalitesine etkisi

Örnek	Zeleny Sedimentasyon (ml)	Beklemeli Zeleny Sedim. (ml)	Sedimentasyon Fark	Alveograf W (1004 Joule)	Farinograf Yumuşama Derecesi (BU)
1	49	63	14	409	0
1*	43	11	32	42	235
2	48	62	14	279	121
2*	47	19	28	32	345
3	43	49	6	179	0
3*	39	12	27	29	197
4	47	61	14	317	41
4*	47	16	31	51	253
5	37	55	18	283	100
5*	40	13	27	187	202
6	33	57	24	231	124
6*	36	16	20	98	246
7	35	48	13	245	53
7*	50	12	38	99	148
8	42	58	16	319	0
8*	39	11	28	18	249
9	56	63	7	290	63
9*	50	23	27	8	282
12	46	58	12	309	0
12*	35	11	24	44	303
13	45	63	18	353	66
13*	41	15	26	128	216
14	33	57	24	279	114
14*	54	17	37	69	266
16	45	62	17	274	26
16*	63	14	49	95	237
17	37	57	20	285	62
17*	41	16	25	105	200
18	58	67	9	377	0
18*	65	12	53	52	280
19	36	59	23	199	76
19*	56	24	32	104	0
20	35	57	22	208	0
20*	49	14	35	82	232
21	40	63	23	286	0
21*	51	15	36	82	202

*Süne zararına maruz kalmış örnekler

Zeleny/SDS sedimantasyon test glutenin koloidal olarak şişmesi ile ekmek yapma kalitesi arasındaki ilişki ilk olarak 1916 yılında Upson ve Calvin tarafından tanımlanmıştır. Günümüzde; glutenin şişme kapasitesini tanımlayan standart metotlar mevcuttur (ICC Standard No. 116/1, AACC Methods 56-60 – 56-70). Sedimentasyon hacmi veya Zeleny-indeks değeri, buğday unlarının değerlendirmesi veya sınıflandırmasında oldukça basit fakat önemli parametrelerdir. Alveograf enerji değeri de buğday kalitesinin belirlenmesinde tüm dünyada yaygın olarak kullanılan bir parametredir ve en az 300 g un gerektirmektedir. Zeleny sedimantasyon ve enerji değeri ekmek hacmi ve ekmekliğin tekstürel (ekmek içi yumuşaklığı, gözenek yapısı, hacmi, şekli vb.) özellikleri ile pozitif yönde doğrusal bir ilişki vermektedir. Buğday/un ticaretinde protein miktar ve kalitesinin belirlendiği en temel analizlerden biridir. Süne yoğunluğunun fazla olduğu dönemlerde beslenme amacı ile buğday özünü (protein) emmektedir. Buğdayın süt olum döneminde bu işlem rahatça yapılabilirken, geç dönemde yapıyı yumuşatması için proteaz enzimini salgılamakta ve yumuşayan tanede emme yapmaktadır. Sünenin buğdaya bırakmış olduğu proteaz enzimi unun su ile yoğrulması ve fermentasyona bırakılması aşamasında enzim (proteaz) aktivite göstermekte (su ve 35 C sıcaklık), bu aktivite büyük molekül ağırlığına sahip glutenleri daha küçük hidrokarbonlara parçalamakta ve bu parçalanma gluten ağ yapısının zayıflamasına neden olmakta, sonuçta hamurun gaz tutma kapasitesini azaltmaktadır. Projede sağlam buğday taneleri süne emgili tanelerle ve diğer buğdaylarla karıştırılarak (Anadolu beyaz sert buğdaylara Anadolu kırmızı sert veya diğer beyaz buğdaylar) oluşturulacak sistem ile bunların ayrıla bilirliliği test edilemiştir. Aynı çeşit /hatların yer aldığı demene Kızıltepe ve Adıyaman lokasyonlarında yürütülmüş, kızıltepede süne zararı görülmemiş fakat Adıyaman lokasyonunda yoğun süne zararı oluşmuştur. Aynı çeşit/hattın Adıyaman ve Kızıltepe de yetiştirilen örneklerde Zeleny sedimantasyon ve beklemeli Zeleny sedimantasyon analizleri yapılmış, aynı örneklerde alveograf enerji değeri ve farinograf yumuşama derecesi değeri analizleri yapılmış sonuçlar tablo 7 de verilmiştir. Süne emgisinin buğday kalitesine vermiş olduğu zararı tespit etmek amacı ile yapılan Zeleny sedimantasyon ve beklemeli Zeleny sedimantasyon değerleri incelendiğinde; en yüksek kaliteye sahip 18 nolu çeşit 65 ml ile en yüksek Zeleny sedimantasyon değeri ve 12 ml beklemeli Zeleny sedimantasyon değeri, 377 joule enerji değeri ve 280 BU farinograf yumuşama değeri vermiştir. En düşük kaliteye sahip 6 ve 14 nolu örnek 33 ml Zeleny sedimantasyon ve sırası ile 16 v 17 ml beklemeli Zeleny sedimantasyon değerleri vermiştir.

Her bir amaç için bir önceki iş kolunda sınıflara ayrılmış buğday çeşitlerinin (hem test, hem eğitim için) hem görünür ışık (RGB, dalga boyu: 400-800 nm), hem yakın kızıl ötesi (NIR, dalga boyu: 800 – 1100 nm) hem de kısa dalga kızıl ötesi (SWIR, dalga boyu: 900-1700 nm) görüntülemeleri gerçekleştirilmiştir. 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 aktararak görüntü işleme teknikleri yardımıyla tanımlayıcı bilgilerin elde edilmesi ve bu bilgilerin sınıflandırılması prensibine dayanmaktadır. Bu çalışmada hiperspektral görüntüleme için 3 farklı kamera kullanılmıştır. Bunlar SWIR, VNIR ve RGB kameralardır.

HİPERSPEKTRAL 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 görüntülemelerde, 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.

KISA DALGA KIZILÖTESİ IŞIK (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 algılayıcılar yaklaşık 1.0 μ m'lik bir üst sınırı 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 görüntülemelerde kullanılan birincil algılayıcılarıdır. Bu çalışmada, Mikro Tasarım' a ait MT-CL-MicroCAM-SW6415 (MikroTasarım, 2018) SWIR Kamera kullanılmıştır (Şekil 1). Özellikleri Şunlardır:

- MT6415CA ROIC üzerinde Hibrit SWIR Görüntüleme Algılayıcısı
- 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 1. Çalışmada kullanılmış olan SWIR Kamera

YAKIN GÖRÜNÜR KIZILÖTESİ IŞIK DALGASI (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 2. Çalışmada kullanılmış olan VNIR Kamera

GÖRÜLEBİLİR IŞIK DALGALARI

Görülebilir ışık dalgaları, görebildiğimiz tek elektromanyetik dalgalardır. Bu dalgaları gökkuşağının renkleri olarak görülmektedir. 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 yansımasını 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. Çalışmada kullanılmış olan Halojen Ampuller



Şekil 4 Her üç kanaldan elde edilen örnek görüntüler


Deneysel çalışmalarda öncelikli olarak Eskişehir ve bölgesinde yaygın olarak yetiştirilen buğday tanelerinin ayrı ayrı RGB, WNIR ve SWIR kameralarla kontrollü ortam fotoğraflarından üretilmiştir. Şekil 4 farklı sınıflardaki buğdaylardan elde edilen fotoğraflarını ve etiketlerinden örnek göstermektedir. Her sınıf için, 640x512 boyutundaki görüntü yakalanıp, her biri 227x227'lik 4 görüntüye ayrılarak görüntü sayısı 220'ye yükseltilmiştir. Kontrollü bir ortamın WNIR kamera örneği Şekil 5.'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 5 Görüntü yakalama düzeni. (a)Çizim düzeni, (b)Gerçek düzen.

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. Bu amaçla Şekil 6'da sanallaştırılmış modeli verilen yöntemle aynı anda her üç kamera ile görüntüler elde edilmiştir.



Şekil 6. Füzyon deneylerinde kullanılmak için oluşturulan görüntü kayıt ortamı.

Yukarıdaki şekilden de görülebileceği gibi, spesifik kameralar, SWIR, VNIR, RGB için mesafelerin 50, 30 ve 20 cm olduğu buğday numunelerinin tepesine uygun şekilde yerleştirmiştir. SWIR, VNIR ve RGB için odaklama alanı sırasıyla 21x29 cm², 9x7 cm² ve 9x7 cm² olarak işaretlenmiştir. Ortamdaki ani ışık değişimlerini engellemek için, iki adet 100 W halojen ışık kaynağı, SWIR'ın sol tarafında ve RGB'nin sağ tarafında konumlanarak, bu da düzgün bir ışık dağılımı sağlayarak kullanılır.

FARKLI DALGA BOYLU GÖRÜNTÜLERLE BUĞDAY SINIFLANDIRILMASI

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. 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. 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 tohumluluk 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. Buna bağlı olarak, gelişen teknolojiyle daha objektif

kalite yöntemleri denenmeye başlamış ve bu yeni teknolojilere göre buğday çeşitlerinin belirlenmesinin gerekliliği ortaya çıkmıştır.

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 geliştirilmiştir²:

- (i) Geleneksel kelimeler çantası (bag of Word, BoW) özelliklerinin kullanıldığı yöntemler
- (ii) Evrimsel sinir ağları (Conventional Neural Network, CNN) özelliklerinin kullanıldığı yöntemler.

Önceden belirlenmiş bir sınıflandırıcıya sahip özellik çıkarıcı algoritma, buğday temsili için makul bir performans vaad etmediğinden, SIFT (Lowe , 2004), SURF (Bay vd., 2006), DSIFT (Vedaldi vd., 2010) ve LBP (Ojala vd. ,2002) gibi öznelik çıkarma yöntemleri BoW (Csurka vd., 2004) yapısı ile birlikte kullanılmıştır ve karar verme aşamasında destek vektör makineleri (support vector machine, SVM), yapay sinir ağları (artificial neural network, ANN) ve k-en yakın komşuluk (k-nearest neighbor, KNN) sınıflandırıcılar ile birlikte bir oy çokluğu kuralı geliştirilmiştir. Buğday tanımlama temelli makine öğrenme sistemleri üzerine literatür taraması yapıldığında, tek bir sınıflandırıcının 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 (Simonyan ve Andrew, 2014), VGG19 (Simonyan ve Andrew, 2014) ve GoogleNet (Szegedy, 2015) 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.

Bu hedeflere ulaşmak için, Şekil 7' de verilen sistem takip edilmiştir. RGB, VNIR ve SWIR görüntülerinin bir füzyonu olarak dördüncü veri kümesi, Ortak Vektör Yaklaşımı (common vector approach, CVA, Cevikalp vd 2005) yöntemi ile elde edilmiştir. 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. Geleneksel yöntemlere ilaveten şekil tabanlı yeni bir öznelik çıkarma yöntemi de proje çalışmaları esnasında türetilmiştir.

² Ayrıntılı bilgi için proje kapsamında Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü yönetmeliği uyarınca Elektrik Elektronik Mühendisliği Anabilim Dalı Telekomünikasyon Sinyal İşleme Bilim Dalında Duygu Zeynep Demirez Örs (2018) tarafından hazırlanan yüksek lisans tezine bakılabilir.



Şekil 7. Buğday çeşidinin tanımlanması için önerilen sistemin genel süreci

FOURIER TEMELLİ ŞEKİL TABANLI BETİMLEYİCİ

Betimleyici (öznitelik) çıkartılması işlemi, isminden de anlaşılacağı üzere sadece bir kategoriye (sınıfa) özgü olan ve diğer kategorilerde bulunmayan karakteristik bilgilerin tespit edilmesi işlemidir. Kategorileri birbirlerinden ayıran doğru betimleyicilerin tespit edilmesi, sınıflama performansının artması üzerinde olumlu bir etki oluşturacaktır. Seçilen her konu için doğru betimleyicilerin bulunmasına yönelik matematiksel bir yöntem yoktur ve çoğu durumda betimleyici tasarımcının sezgisine bağlı olarak tespit edilir. Süne böceği veya başka hastalıklardan dolayı buğdayın şeklinde bozulmalar olmaktadır. Bu sebepten dolayı süne ve başka hastalıklardan etkilenmiş olan buğdayların tespiti için şekil tabanlı bir betimleyicinin kullanılması başarıyı artıracak aşikardır. Bununla beraber, aynı betimleyici yabancı madde tespitinde başarılı olması kaçınılmazdır. Çünkü yabancı maddelerde şekil bakımından buğdaylardan farklıdır.

Wang vd (2014) anlamsal ve şekilsel betimleyici çıkartabilmek için anlamlı noktalar üzerine daireler yerleştirilmiş, her bir daire içine düşen şeklin konturları üzerindeki noktaların sayısı kullanılmıştır. Nokta sayıları yerine Fourier tabanlı bir yöntemin şeklin konturlarını daha iyi temsil edebileceğini ve bu sayede daha başarılı olacağını düşünülmüştür. Fourier dönüşümü 1800 yıllardan beri hemen hemen bütün mühendislik uygulamalarında kullanılmaktadır. Fourier dönüşümü alındığı zaman dönüşüm sonrasında hem büyüklük hem de faz açısı bilgileri elde edilebilmektedir (Cevikalp vd, 2013). Faz açısı bilgisi, şekli temsil etmek için daha fazla bilgi içermektedir. Bundan dolayı her bir daire içine düşen şeklin konturları üzerindeki noktaların sayısı yerine Fourier dönüşümünün faz bilgisini içeren yöntemin algoritması aşağıda verilmiştir.

1. Girdi imgesindeki nesnenin kenar bölütünü bul.
2. Çizgi bölütlerini hesapla.
3. Çizgileri doğrula.
4. Çizgi üzerindeki anlamlı noktaları tespit et
5. Kontur parçacıkları kümesi oluştur.
6. Öznitelik vektörlerini hesapla.
7. Kod kitabı oluştur.
8. Havuzlamaya tabi tut.

Önerilen algoritmanın adımları aşağıda açıklanmıştır.

Kenar Bölütü : Kenar dedektörünü bulmak için eğer girdi imgesi renkli ise Color Edge Drawing (Akinlar ve Topal, 2017), girdi imgesi gri tonlu bir imge ise Edge Drawing (ED, Topal ve Akınlar, 2012) algoritması uygulanarak, kenar bölütü adı verilen temiz ve birleştirilmiş bir piksel zinciri oluşturulur.

Çizgi Bölütleri : En küçük kareler çizgi birleştirilmesi yöntemi (Burns vd, 1986) ve bir doğruluk (düzgünlük) kriteri kullanılarak, üretilen piksel zincirlerinden çizgi bölütleri ortaya çıkartılır.

Çizgi Doğrulama : Hatalı olarak tespit edilen çizgi bölütlerini elimine etmek için Helmholtz prensibine (Desolneux vd 2000) dayanan çizgi doğrulama adımı kullanılır.

Anlamlı nokta tespiti: Zhang ve Lu (2004) un yaptıkları gibi imgenin kontur gradyanlarından hesaplanan dönüş açısı eğriliğine dayalı bir yöntemle bir önceki aşamada elde edilen çizgiler üzerindeki anlamlı noktalar elde edilir.

Kontur parçacıklar kümesi : Çok ölçekli bilgiyi elde edebilmek için tüm anlamlı noktalar arasındaki kontur parçaları Wang vd. (2014) önerdikleri gibi elde edilerek kontur parçacıkları kümesi elde edilir. Bu sayede hem lokal hem de global özellikleri çıkarmak mümkün hale gelmiştir.

Fourier tabanlı öznitelik vektör oluşturma : Kontur parçacıklarının lokasyon bilgilerinin Fourier dönüşümüne tabi tutularak mutlak değerleri (büyüklük) öznitelik vektörü olarak alınmıştır. Bu çalışmada ise büyüklük değerinden daha fazla bilgi içeren açı bilgisi öznitelik vektörü olarak kullanılmıştır. Bu kapsamda kontur üzerindeki piksellerin x ve y koordinat değerleri j karmaşık sayıyı göstermek üzere $x + jy$ şeklinde bir boyutlu karmaşık sayılardan oluşan vektör haline getirilerek Fourier dönüşümüne tabi tutulmuştur. Elde edilen Fourier katsayılarının açı bilgisi öznitelik vektörü olarak kullanılmıştır. x ve y koordinat değerleri kendi ortalamalarından çıkartılarak normalize edilmiştir.

DENEYSEL ÇALIŞMALARDA KULLANILAN ÖLÇÜM YÖNTEMLERİ

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 sınıfları ifade etmektedir. Sütunlar ise modelin tahminlemesini göstermektedir. İki sınıflı bir örnekte karışıklık matrisi aşağıdaki gibi olmaktadır.

Tablo 8 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.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FN + FP} \quad (1)$$

$$\text{Hata Oranı} = \frac{FP + FN}{TP + FP + FN + TN} \quad (2)$$


Kesinlik, sınıfı A olarak tahminlenmiş Gerçek Pozitif sayısının, sınıfı A olarak tahminlenmiş tüm örnek sayısına oranı, $TP / (TP + FN)$, duyarlılık ise doğru sınıflandırılmış pozitif örnek sayısının toplam pozitif örnek sayısına oranı, $TP / (TP + FN)$, olmak üzere f ölçütü aşağıdaki gibi tanımlanır.

$$F \text{ ölçütü} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3)$$

SWIR, VNIR VE RGB GÖRÜNTÜLERİNİN FÜZYONU

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. Şekil 8, farklı görüntü kanallarının füzyonu ile ilgili gösterimi ifade etmektedir. Görüntü füzyonu ile uzaysal çözünürlüğü artırmak, belirsizliği azaltmak, sınıflandırma hassasiyetini geliştirmek ve görüntü kalitesi iyileştirmek gibi hedeflere ulaşılabilir. Çalışma kapsamında 5 farklı imge füzyon yöntemleri uygulanmış olup sonuçları karşılaştırılmıştır.



Şekil 8. RGB, SWIR ve VNIR kanalları üzerinden füzyon işleminin görselleştirilmesi.

ORTAK VEKTÖR YAKLAŞIMI İLE İMGE FÜZYONU

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. (2015, 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 9. 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, $\vec{a}_{com}$ 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 durumunu meydana gelmektedir. Yetersiz veri durumunda, Gülmezoglu vd. (2001) çalışmasında vurgulandığı gibi ortonormal vektörleri belirlemek için Gram Schmidt yöntemi kullanılabilir. $\vec{a}_i$ sınıf içinde referans olarak seçilen herhangi bir vektör olmak üzere fark vektörleri aşağıdaki gibi elde edilebilir.

$$\vec{b}_i = \vec{a}_{i+1} - \vec{a}_1 \quad (i = 1, 2, \dots, n-1) \quad (4)$$

Bu taban vektörleri kullanılarak Gram-Schmidt dikleştirme metoduyla, aşağıdaki denklemde $\vec{z}_i$ ile gösterilen birimdik vektör kümesi elde edilir. Referans olarak seçilen vektör bu birim dik vektörlere izdüşümü ile fark vektörü elde edilir.

Tosunbey sınıfının # 000012 örneği için füzyon prosedürü



Şekil 10 Kırmızı, Yeşil, Mavi, VNIR ve SWIR dahil beş kanalın füzyonu için görselleştirme.

$$\bar{a}_{i,diff} = \sum_{k=1}^{n-1} < \bar{a}_i, \bar{z}_k > \bar{z}_k \quad (5)$$

Fark vektörü referans vektörden çıkarılmasıyla ortak vektör elde edilmiş olur. Elde edilen ortak görüntü örnekleri şekil 9'da görülebilir.

Şekil 10. , 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.

THE BROVEY TRANSFORM (BT) TABANLI FÜZYON

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

$$RN = \frac{R}{R+G+B}V, \quad GN = \frac{G}{R+G+B}V, \quad BN = \frac{B}{R+G+B}V \quad (6)$$

İNTENSİTY-HUE-SATURATION (IHS) TABANLI FÜZYON

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

$$V1 = \frac{R+G-2B}{\sqrt{6}}, \quad V2 = \frac{R-G}{\sqrt{2}}, \quad RN = V + \frac{V1}{\sqrt{6}} + \frac{V2}{\sqrt{2}}, \quad GN = V + \frac{V1}{\sqrt{6}} - \frac{V2}{\sqrt{2}}, \quad BN = V - 2\frac{V1}{\sqrt{6}} \quad (7)$$

DİSCRETE COSİNE TRANSFORMATION (DCT) TABANLI FÜZYON

Elimizde RGB imgeden elde edilmiş Grey (G) ve VNIR(V) imgeleri olduğunu varsayalım. DCT tabanlı füzyon işleminde imgelerden elde edilen parçalar öncelikle DCT transformasyondan geçirilmektedir. Daha sonra DCT uzayında parçaların varyans bilgileri dikkate alınarak füzyon işlemi yapılmakta ve tekrardan DCT transformasyonun tersi alınarak füzyon işlemi tamamlanmaktadır. Elimizde G ve V imgelerinden alınmış, 8x8 'lik ve P1 ve P2 parçaları olsun ve füzyon edilmiş parça P olduğunu varsayalım. Bu durumda öncelikle DCT transformasyon uygulanarak P1 ve

P2 oluşturulmaktadır. En son işlem olarak P parçası üzerinden DCT transformasyonun tersi alınıp füzyon sonlandırılmaktadır.

GELENEKSEL ÖZNİTELİK ÇIKARIMI VE KELİMELER ÇANTASI YÖNTEMİ İLE ELDE EDİLEN DENEYSEL SONUÇLAR

Önerilen yöntemin performansı ile ilgili genel bir fikir vermek için, elde edilen sonuçları F ölçütü ve karışıklı matrisinden hesaplanan objektif ölçümler açısından değerlendirilmiştir. Doğruluk, tahmin edilen sonuçların gerçek değerlere (ground truths) yakınlığını ifade eder. F ölçütü, 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. 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. Karşılaştırma için, her bir geleneksel yöntemin doğruluk sonucu Tablo 2'de elde edilmiş ve sergilenmiştir. 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 9'dan, VNIR veri kümesinin diğerlerine karşı en iyi performansı elde ettiği görülmektedir. 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 (Özkan vd., 2019 a).

Tablo 9. Geleneksel yöntemlerimin başarımları

		DSIFT	SBFT	LBP	SIFT	SURF
RGB Ortalama 22.23	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
VNIR Ortalama 22.68	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
SWIR Ortalama 12.90	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
FUSION Ortalama 16.33	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

DERİN ÖĞRENME TABANLI YÖNTEMLER


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. 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 geleneksel betimleyiciler kullanılmaktadır. Büyük veri setleri için makine öğrenme sistemlerinin performansını artırma çabalarında, derin evrimsel sinir ağları

(Conventional Neural Network, CNN) 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 stratejileri dönemi hemen hemen sona ermektedir ve makine öğrenimini değiştirmiştir.

ALEXNET MODELİ


AlexNet, imagenet yarışmasında yıldızı parlayan ve CNN öznetelikleri tabanlı modelleme olarak bilinmektedir. Daha önce önerilen LeNet yapısının sadece büyük imgelere göre ayarlanması olarak düşünebilir. LeNet modeli ilk olarak digit sınıflandırma için önerilmiş ve gelecek vaadeden başarımlar gösterdiği izlenmiştir. CNN yapılarının en büyük avantajı anlamlı öznetelikleri kademeli bir şekilde oluşturmalarıdır. AlexNet modelinde konvolüsyon katmanları aslında sinir ağlarının modelindeki ağırlıklandırma katsayıları ile girdi verisini çarpmaya benzetmektedir. 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 fonksiyonunun türevi kullanılmaktadır.

Örüntüleri ayırmak için genel olarak AlexNet modelinin tam bağlı katmanlar (full connected layers) adını verdiğimiz ve Şekil 11 'de en sağ kısımda gösterilen FC7 veya FC6 katmanları öznetelik çıkarmak için kullanılmaktadır. 227x227x3 boyutlu bir girdi imgesi ileri yönde tüm katmanlardan geçirilerek 4096x1 boyutlu bir öznetelik vektörü ile temsil edilmektedir. Birçok çalışmada 4096x1 vektörü sınıflandırma ve benzeri amaçlar için kullanılmaktadır. Bu çalışmada FC7 ve FC6 katmanlarından dönen 4096x1'lik vektörler buğday sınıfı tahmin etmek için kullanılmıştır.



Şekil 11. AlexNet yapısının genel akışı

Önceden eğitilmiş AlexNet, bu tür görüntüler üzerinde çalışacak şekilde tasarlandığından, resimler her biri 227x227 boyutlarındaki dört alt görüntüye göre kırılır. Her bir test görüntüsü için test akışı Şekil 12'de özetlenmiştir.




Şekil 12. 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 kullanılmamıştır. Bu işlem 100 kez farklı eğitim ve test seti tekrarlanmıştır ve doğruluk ortalamaları ve standart sapmalar kaydedilmiştir. Açıkçası, doğrusal olarak sınıflandırılmış FC6 özelliklerinin FC7'den biraz daha iyi olan %99,9695 toplam doğruluk sonucu verdiğini gözlemlenmiştir. 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.

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 tüm sonuçların oldukça iyi olduğu gözlemlenmektedir (Ozkan vd., 2019b).

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 13, 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 13. CNN Mimarilerine Dayanan İkinci Yöntemin Gösterimi

Şekil 13 de verilen yöntemle FUSION, RGB, SWIR ve VNIR veri kümelerinin CNN özelliklerinin sağlamlığı artırılmıştır. 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.

Tablo 11'de 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.

Tablo 11. FUSION, RGB, SWIR, VNIR üzerindeki CNN özelliklerinin doğruluğu (%)

	FUSION	RGB	SWIR	VNIR	Ortalama
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
Ortalama	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 (Özkan vd. ,2019c).

ÖZNİTELİK (FEATURE) FÜZYONU YÖNTEMLERİ

Heuristic (Sezgisel): Özelliklerin birleştirilmesi için kullanıcı tarafından önceden tanımlanmış bazı olasılık oranlarının kullanıldığı bir yöntemdir. Olasılık katsayıları, her bir görüntüleme sisteminin performansının ayrı ayrı analiz edilmesiyle belirlenmiştir. Verimlilik ne kadar iyi olursa, katsayısı da o kadar yüksek olur. Tablo 12'deki doğruluk puanlarını referans olarak alarak, füzyon katsayılarını RGB, SWIR ve VNIR için sırasıyla 0,2, 0,4 ve 0,4 olarak belirlenmiştir.

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

VLAD: VLAD yöntemi, kodlama yoluyla özellik boyut küçültme için kullanılan FISHER'a benzemektedir. Benzer şekilde, 1500x4096 özellikli matrisini rastgele oluşturulmuştur. Daha sonra KD-ağaç modeli, her bir özellik setinin indekslenmesi açısından elde edilen kümelenmeye dayanarak inşa edilmiştir. Sonunda, VLAD 4096x1'lik birleşmiş bir özellik vektörü verir.

VNIR + VLAD: VNIR özelliğini, kodlanmış VLAD özellikleri ile birlikte birleştirmek anlamına gelmektedir. Bu nedenle, bir test örneği, 8192x1 boyutunda bir özellik vektörüyle temsil edilmiştir.

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

Genişletilmiş özellik vektörünün performansını analiz etmek için,

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

RGB + SWIR: RGB ve SWIR özelliklerinin birleştirilmesi anlamına gelmektedir. Test özelliği vektörü 8192x1 şeklindedir.

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

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

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

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

Tablo 12. Öznitelik uzayında yapılan füzyonun genel performansı

Features/Fusion	Accuracy (%)
VNIR	99.87
RGB	94.59
SWIR	99.29
CVA	97.53
Heuristic	99.47
RGB+SWIR	97.45
RGB+VNIR	98.30
SWIR+VNIR	99.95
RGB+SWIR+VNIR	98.96
FISHER	98.81
VLAD	98.55
VNIR+VLAD	99.12
VNIR+FISHER	98.99
VNIR+VLAD+FISHER	98.93

Deney sonuçlarına bakıldığında, imge uzayında RGB-VNIR kanalları ve öznitelik alanında SWIR-VNIR özellikleri birleştirildiğinde umut verici sonuçlar gözlenmiştir. Deneysel sonuçlar, önerilen füzyon yöntemlerinin, sırasıyla, imge ve öznitelik uzayında üzerinden 1600 test örneğinin üzerinde tahminler yapılması durumunda, % 99,74 ve% 99,95'ini şeklinde iyi performanslar sağladığını göstermektedir. Sonuç olarak, buğday çeşidi tespiti zorlu bir süreçtir ve insanların algılama sürecini daha da zorlaştıran sınıflar arası yüksek benzerlik ve renk özelliklerinin zayıflığı gibi faktörler nedeniyle çok fazla çaba gerektirmektedir. Önceki yıllarda yapılan buğday tanımlama yaklaşımları genellikle farklı sınıflar arasında bir karar sınırı oluşturularak önceden belirlenmiş bir sınıflandırıcı ile birlikte manuel özelliklere

dayanır. Fakat derin öğrenme yöntemleri, performans karşılaştırmasını temel olarak değerlendirdiğinde, eski yöntemlerle yapılan nesne sınıflandırma metodolojilerinden çok daha umut vadeden sonuçlar sunmaktadır. Elde edilen iyi sonuçlar açık bir şekilde önerilen füzyon yöntemlerinin tarım endüstrisindeki buğday türlerinin doğru tahmin edilmesinde uygun olduğunu göstermektedir (Ozkan vd., 2019d).

GÖRÜNTÜ TABANLI FÜZYONUN DENEYSEL SONUÇLARI

Görüntü üzerinde yapılan füzyon işleminde, RGB, VNIR ve SWIR kanallarında belirtilen anlamlı yerel bilgiler önceden tahmin edilen olasılık oranları ile birleştirilmek üzere işlenmektedir. Temel amaç, buğday taneleri sınıflandırmak için ayırt edici bir görüntü oluşturmaktır. Çalışmada, bu görüntü füzyon metodolojilerinin buğday çekirdeklerinin sınıflandırılması üzerindeki performansları incelenmiştir. Elde edilen doğruluk skorları Tablo 13’de sunulmaktadır. Burada sayısal sonuçlar ortalama doğruluk yüzdesini göstermektedir. Bu denemeden elde edilen değerleri karşılaştırırken, en iyi doğruluk oranı (%99,74) BT metodu ile RGB-VNIR üzerinden elde edilmiştir. Genel değerlendirmede, RGB-VNIR görüntüleme sistemlerinin kullanılması, görüntü alanı üzerinden füzyon yapılırken daha uygun olduğunu göstermektedir.

Tablo 13. Görüntü alanı üzerinde yapılan füzyon için genel performansı

Method	RGB-SWIR (%)	RGB-VNIR (%)	SWIR-VNIR (%)
BT	99.24	99.74	-
IHS	98.77	99.59	-
DCT	98.29	99.06	95.54
CNN	98.91	99.20	98.59
CVA	99.33	99.42	98.49

SÜNE BÖCEĞİ ETKİSİNE KALMIŞ TASNİF DIŞI BUĞDAY ÇALIŞMALARI

Bu çalışma, özellikle buğdaylar üzerindeki süne böceğinin (sunn pest) etkisi üzerinedir. Buğdayın yetiştirilmesini sınırlayan etkenlerden en önemlisi süne zararlısı (sunn pest) olarak karşımıza çıkmaktadır (Davari ve Parker, 2018) Zira hasat öncesinde buğday danesine verdikleri zarar buğdaydan elde edilecek gıdalarda önemli kalite düşüşlerine sebep olmaktadır. Süne, buğdayın daha çok süt olum aşamasında buğday danesine zarar vermektedir. Bu zarar buğdayda glüten proteinlerinin hidrolizasyonuna sebep olarak buğdaydan elde edilecek ürünlerde önemli kalite kayıplarına dolayısıyla da verim düşmelerine sebep olmaktadır (Turhal ve Turhal, 2014). Bu sebeple buğdayın işlenmeden önce süne zararlısının etkisine maruz kalıp kalmadığının tespiti ve zarara uğramış danelerin işlem öncesinde ayrıştırılması önem kazanmaktadır Süne zararlısına uğramış buğday ile kaliteli buğday arasındaki en belirgin özellik şekilsel farklılıklardır. Tasnif dışı buğday (süne zararlısına uğramış) hastalık, yetersiz büyüme gibi nedenlerden biçimsel-bozulmuş, tüketime sunulamayan, kaliteyi düşüren buğday biçimidir (Şekil 14).



Şekil 14. Üst satır: Süne zararlısına uğramış, Alt Satır: Kaliteli buğday danesi

Bu sebepten dolayı süne ve başka hastalıklardan etkilenmiş olan buğdayların tespiti için şekil tabanlı bir betimleyicinin kullanılması başarıyı artıracak aşırıdır. Wang vd (2014) anlamsal ve şekilsel betimleyici çıkartabilmek için anlamlı noktalar üzerine daireler yerleştirilmiş, her bir daire içine düşen şeklin konturları üzerindeki noktaların

sayısı kullanılmıştır. Nokta sayıları yerine Fourier tabanlı bir yöntemin şeklin konturlarını daha iyi temsil edebileceğini ve bu sayede daha başarılı olacağını düşünülmüştür. Fourier dönüşümü alındığı zaman dönüşüm sonrasında hem büyüklük hem de faz açısı bilgileri elde edilebilmektedir (Cevikalp vd, 2013). Faz açısı bilgisi, şekli temsil etmek için daha fazla bilgi içermektedir. Bundan dolayı her bir daire içine düşen şeklin konturları üzerindeki noktaların sayısı yerine Fourier dönüşümünün faz bilgisini içeren yöntemin algoritması aşağıda verilmiştir. Önerilen betimleyicinin performans karşılaştırılması literatürde kabul görmüş standart veri tabanları ile karşılaştırılmıştır. Deneysel çalışmalarda da görüldüğü üzere hem standart veri setlerinde hem de çalışma kapsamında elde edilen veri setinde önerilen yöntem başarılıdır.

MPEG-7 veri seti, bilgisayarlı görü alanında şekil analizi için yaygın olarak kullanılmaktadır. Çok fazla şekil değişkenliği olan veri setinde 70 sınıfa ayrılmış 1400 siluet imgesi vardır (<http://www.dabi.temple.edu/~shape/MPEG7/dataset.html>). Her sınıfın 20 farklı şekli vardır. Bu çalışmada iki farklı strateji kullanarak önerilen yöntemin performansı değerlendirilmiştir. (1) eğitim kümesi için her bir sınıftan rastgele 10 imge seçilir, bu işlem 10 kere tekrar edilir. (2) Her denemeden her sınıftan bir imge test verisi olarak kullanılır. Ortalama sınıflandırma doğruluğu ve sınıflandırma doğruluklarının standart sapması aşağıdaki tabloda verilmiştir.

Tablo 14. MPEG 7 veri seti sonuçları

Yöntem	Doğruluk % Strateji 1	Doğruluk % Strateji 2
Wang vd (2014)	97.16 $\pm$ 0.79	98.93
Önerilen	97.86 $\pm$ 0.742	99.03

Hayvan veri kümesi at, tavşan, maymun vb. dahil olmak üzere 20 çeşit hayvanı tanımlayan 2000 şekil içermektedir (Bai vd. 2009).. Her kategori 100 hayvan görüntüsüne sahiptir. Sınıf başına rastgele seçilen 50 imge eğitim ve diğer imgeler ise test kümesi ayrılarak deneysel çalışmalar gerçekleştirilmiştir. Bu işlem 10 kere tekrarlanarak elde edilen sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 15. Hayvan veri seti sonuçları

Yöntem	Doğruluk %
Wang vd (2014)	83.40 $\pm$ 1.30
Önerilen	84.03 $\pm$ 0.92

İsveç yaprak veri seti, Linköping Üniversitesi ve İsveç Doğa Tarihi Müzesi'ndeki yaprak sınıflandırma projesi kapsamında İsveç'te yetişen ağaç türlerinden her bir sınıfta 75 yaprak olmak üzere 15 farklı seçilmiş yaprak imgeleri içermektedir (Söderkvist ,2001). Her bir tür için, eğitim için 25 imge rastgele seçilir ve imgelerin geri kalanı test için kullanılarak deneysel çalışmalar yapılmıştır. Elde edilen sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 16. Yaprak veri seti sonuçları

Yöntem	Doğruluk %
Wang vd (2014)	96.56 $\pm$ 0.67
Önerilen	97.34 $\pm$ 0.71

Caltech101 veri kümesi, hayvanlar, araçlar, çiçekler vb. dahil olmak üzere 101 obje sınıfında farklı şekil, renk, desen ve arka planda önemli farklılıklara sahip 9144 görüntü içerir. Veri setinde kategori başına görüntü sayısı 31 ile 800 arasında değişmektedir. Bu çalışmada sınıf başına rastgele seçilen 30 imge eğitim kümesi diğer imgeler test kümesi olarak ele alınmış, deneysel çalışmalar 10 kere tekrar edilmiştir.

Tablo 17. Caltech 101 veri seti sonuçları

Yöntem	Doğruluk %
Wang vd (2014)	77.87 ± 1.0
Önerilen	77.97 ± 0.7

Süne zararlısına uğramış buğday danesi veri seti 400x800 boyutlarında aynı ışık şiddeti ve aynı uzaklık mesafesinden çekilmiştir. Veri setinde kaliteli ve tasnif dışı sınıflarında 150 adet imge bulunmaktadır (Ozkan ve Kartal, 2019 e).

Tablo 18. Süne zararlısına uğramış buğday veri seti sonuçları

Yöntem	Doğruluk %
Wang vd (2014)	79.87 ± 1.1
Önerilen	80.25 ± 0.57

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. Önerilen yöntemlerden bir tanesi 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 SVM' nin polinom SVM' 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 şüpheyne 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.

Diğer yöntemde 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. Deneysel aşamalar boyunca, buğday çeşitliliği tespiti üzerine uygulandığında BoW özelliklerinin şekil ve desen tabanlı olduğundan ve buğday çeşitlerinin arasında bu özelliklerin farklı olmamasından dolayı buğday sınıflarını ayırmada etkili olmadığı gözlemlenmiştir. 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, daha sağlam bir performans sağladığına işaret etmektedir. Hem görüntü bölgesinde hem de betimleyiciler bölgesinde füzyon işlemi başarıyı artırdığı da bu çalışmanın sonuçlarından biridir.

Kaliteli buğday elde edebilmek için yetiştirme koşulları kadar, hasat öncesindeki hastalık ve hububat zararlılarının da etkisi çok büyüktür. Hasat öncesi buğdayın verimini ve kalitesini olumsuz etkileyen hububat zararlılarını başında süne gelmektedir. Bu tür kayıpları önleyebilmek amacı ile buğdayın un üretim sürecine girmeden önce uzun, nesnel ve yorucu olan uzman kişiler tarafından süneli olup olmadığının belirlenmesi gerekmektedir. Bu çalışmada buğday danesinde süne etkisinin olup olmadığını tespit etmek amacıyla Fourier dönüşümün açığı bilgisine dayanan şekil tabanlı bir yöntem önerilmiştir. Deneysel çalışmalarda da görüldüğü üzere hem standart veri setlerinde hem de çalışma kapsamında elde edilen veri setinde önerilen yöntem başarılıdır. CNN özellikleri ve VNIR kamerasına dayanan bir sistem, buğday endüstrisinde pahalı ekipman kullanmadan daha objektif ve doğru kararlar almak için yeterli olacaktır.

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.

Bu çalışma ile birlikte, benzeri sorunları ortadan kaldırmak için ;

- buğday çeşitlerinin, hem görünür ışık (RGB, dalga boyu: 400-800 nm), hem yakın kızıl ötesi (NIR, dalga boyu: 800 – 1100 nm) hem de kısa dalga kızıl ötesi (SWIR, dalga boyu: 900-1700 nm) görüntüleme tekniklerinden elde edilecek bilgileri birleştirerek daha hassas bir şekilde belirlenmesi,
- buğday kalitesine olumsuz etkisi olan süne, kımıl zararı ve yabancı maddelerin, farklı görüntüleme tekniklerinden gelen bilgiler birleştirilerek daha hassas belirlenmesi için bir yöntem sunulmuştur.

Sonuç olarak, nüfusu hızla artan ülkemizde buğday üretimindeki artış, yüksek verimli ve kaliteli bir üretim yapmakla mümkündür. Önerilen bu projeyle, buğday alımı-satımı sırasında fiyat tespitinin daha objektif olarak yapılması ve buğday kalitesinin belirlenmesinde insan faktörüne bağımlılığını kaldırılması sonucu hem teknik hem ekonomik kazançlar elde edilmesinin mümkün olduğu belirlenmiştir.

KAYNAKLAR

- Akinlar C., Topal C., 2017, "ColorED: Color edge and segment detection by Edge Drawing (ED)", J. Vis. Commun. Image R. ,44, 82–94,
- Ariana, D.P., Lu, R., Guyer, D.E., 2006. "Near-infrared hyperspectral reflectance imaging for detection of bruises on pickling cucumbers", Comput. Electron. Agric. Sayı: 53,Sf 60-70
- Bai X., Liu W., Tu Z., 2009, "Integrating contour and skeleton for shape classification", International Conference on Computer Vision Workshops (ICCV Workshops), 360–367
- Barbedo J. G.A., Guarienti E.M., Tibola C. S., 2018, "Detection of sprout damage in wheat kernels using NIR hyperspectral imaging", Biosystems Engineering, 175, 124-132.
- Bay H., Tuytelaars T., ve Gool L.V. 2006, "SURF: Speeded up robust features". In ECCV (1), pages 404-417
- Burns, J.B., Hanson, A.R. and Riseman, E.M., 1986, "Extracting Straight Lines", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 8, no. 4, pp. 425-455.
- Cevikalp H., Neamtu M., Wilkes M., Barkana A., 2005, Discriminative common vectors for face recognition, IEEE Transactions on pattern analysis and machine intelligence, 27, 4-13
- Çevikalp H., Kurt Z., Onarcan A.O., 2013, Return of the king: The Fourier transform based descriptor for visual object classification, Signal Processing and Communications Applications Conference (SIU),21st, IEEE2013, pp. 1-4.
- Cheng, X., Chen, Y.R., Tao, Y., Wang, C.Y., Kim, M.S., Lefcourt, A.M., 2004. "A novel integrated PCA and FLD method on hyperspectral image feature extraction for cucumber chilling damage inspection",. Trans. ASAE Sayı:47 (4), Sf 1313-1320
- Choudhary R., Mahesh S., Paliwal J., Jayas D.S., (2009), Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples, biosystems engineering, Sayı: 102, Sf 115–127
- Cogdill, R.P., Hurburgh Jr., C.R., Rippke, G.R., 2004. "Single-kernel maize analysis by near-infrared hyperspectral imaging. Trans". ASAE Sayı:47 (1), Sf 311-320.
- Csurka G., Dance C. R., Dan L., Willamowski J., and Bray C.,2004, . Visual categorization with bags of keypoints. In Proc. ECCV Workshop on Stat. Learn. in Comp. Vision.
- Davari A., Parker B.L., "A review of research on Sunn Pest {Eurygaster integriceps Puton (Hemiptera: Scutelleridae)} management published 2004–2016", Journal of Asia-Pacific Entomology 21, 352–360, 2018.
- Delwiche, S. R., Yang, I.-C., & Graybosch, R. A. , 2013, "Multiple view image analysis of free falling U.S. wheat grains for damage assessment", Computers and Electronics in Agriculture, 98, 62-73.
- Desolneux, A., Moisan, L. and Morel, J.M.,2000, "Meaningful Alignments", International Journal of Computer Vision, vol. 40, no. 1, pp. 7-23.
- ElMasry, G., Wang, N., ElSayed, A., Ngadi, M., 2007. "Hyperspectral imaging for nondestructive determination of some quality attributes for strawberry", J. Food Eng. Sayı:81, Sf 98-107
- Ergin S., Çakir S., Gerek Ö.N., Gülmezoğlu M.B.,2011, A new implementation of common matrix approach using third-order tensors for face recognition, Expert Systems with Applications, 38 , , 3246-3251.
- Gowen, A.A., Taghizadeh, M., O'Donnell, C.P., 2009. "Identification of mushrooms subjected to freeze damage using hyperspectral imaging", J. Food Eng. Sayı:93, Sf 7-12
- gubretas.com.tr, 2019,Gübretaş : Buğday Yetiştirme Tekniği. [online] Available at: <http://www.gubretas.com.tr/tr/icerik/11/1850/bugday-yetistirme-teknigi.aspx> [Accessed 05 Feb. 2019
- Gillespie A.R., Kahle A.B., Walker R.E., 1987, Color enhancement of highly correlated images. II. Channel ratio and "chromaticity" transformation techniques, Remote Sensing of Environment, 22 , 343-365

Gulmezoglu M., Dzhaferov V., Barkana A., 2001, The common vector approach and its relation to principal component analysis, IEEE Transactions on Speech and Audio Processing, 9, 655-662.

Gunasekaran, S. , 1996, "Computer vision technology for food quality assurance", Trends in Food Science & Technology, 7(8), 245-256.

Işık Ş., Özkan K., Gerek Ö.N., Doğan M. 2016,, A new subspace based solution to background modelling and change detection, International Journal of Intelligent Systems and Applications in Engineering, 4, 82-86.

Kim, M.S., Lefcourt, A.M., Chao, K., Chen, Y.R., Kim, I., Chan, D.E., 2002. "Multispectral detection of fecal contamination on apples based on hyperspectral imagery: Part I. application of visible and near-infrared reflectance imaging", Trans. ASAE Sayı: 45 (6), Sf 2027-2037

Koenig A., Konitzer K., Wieser H., Koehler P., (2015), Classification of spelt cultivars based on differences in storage protein compositions from wheat, Food Chemistry, Sayı: 168, Sf 176-182

Krizhevsky A., Sutskever I., Hinton G.E, 2012, Imagenet classification with deep convolutional neural networks, Advances in neural information processing systems, pp. 1097-1105

Lancelot E., Bertrand D., Hanafi M., Jaillais B. , 2017, "Near-infrared hyperspectral imaging for following imbibition of single wheat kernel sections", Vibrational Spectroscopy, 92 ,46-53.

Lefcourt, A.M., Kim, M.S., Chen, Y.R., Kang, S., 2006. "Systematic approach for using hyperspectral imaging data to develop multispectral imaging systems: detection of feces on apples", Comput. Electron. Agric. Sayı: .54, Sf 22-35

Lowe, D. (2004). D.G. Lowe, Distinctive image features from scale-invariant keypoints, International journal of computer vision, 60 (2004) 91-110.

Lu, R., 2003. "Detection of bruises on apples using near-infrared hyperspectral imaging". Trans. ASAE 46 (2), 523-530.

Lu, R., Peng, Y., 2005. "Hyperspectral scattering for assessing peach fruit firmness", Biosyst. Eng. 93 (2),

Mahesh, S., Jayas, D.S., Paliwal, J., White, N.D.G., 2011. "Identification of wheat classes at different moisture levels using near-infrared hyperspectral images of bulk samples", Sens. Instrum. Food Qual. Saf. Sayı 5 (1), Sf 1-9.

Mehl, P.M., Chen, Y.R., Kim, M.S., Chan, D.E., 2004. "Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations", J. Food Eng. Sayı:61, Sf 67-81.

Nagata, M., Tallada, J.G., Kobayashi, T., Cui, Y., Gejima, Y., 2004. "Predicting Maturity Quality Parameters of Strawberries Using Hyperspectral Imaging". Paper No.043033. ASABE, St. Joseph, MI.

Nagata, M., Tallada, J. G., Kobayashi, T., & Toyoda, H., 2005, "NIR hyperspectral imaging for measurement of internal quality in strawberries", Paper No.053131, ASAE Annual International Meeting, Tampa, Florida, USA,.

Nicolai, B.M., Lotze, E., Peirs, A., Scheerlinck, N., Theron, K.I., 2006. "Non-destructive measurement of bitter pit in apple fruit using NIR hyperspectral imaging", Postharvest Biol. Technol. Sayı:40, Sf 1-6

Ojala, T., Pietikäinen, M. and Mäenpää, T. (2002), Multiresolution Gray-scale and Rotation Invariant Texture Classification with Local Binary Patterns. IEEE Trans. Pattern Analysis and Machine Intelligence 24(7): 971-987.

Özkan K., Işık Ş., 2015, A novel multi-scale and multi-expert edge detector based on common vector approach, AEU-International Journal of Electronics and Communications, 69, , 1272-1281.

Özkan K., Işık Ş., Dordinejad G.G., 2016, Multispectral image fusion based on the common vector approach, INnovations in Intelligent SysTEms and Applications (INISTA), 2016 International Symposium on, IEEE2016, pp. 1-6.

Özkan K., Yavuz B.T., Işık Ş., 2019 a, Identification of wheat kernels by fusion of RGB, SWIR, VNIR samples over feature and image domain, hakem değeriendirilmesinde

Özkan K., Işık Ş., Onarcan A.O, Demirez D.Z, Seke E, Olgun M, 2019b, Deep Learning Based Classification of Hyperspectral Wheat Kernels , hakem değerlendirilmesinde

Özkan K., Işık Ş., Yavuz B.T., Demirez D.Z., 2019 c, Shallow and Deep Convolutional Neural Network Models for Classification of VNIR Wheat Samples, hakem değerlendirmesinde

Özkan K., Demirez D.Z., Işık Ş., Seke E., 2019 d, Evaluation of visible light, visible near-infrared and short-wave infrared imaging for wheat cultivar classification by using consensus rule, hakem değerlendirmesinde

Ozkan K., Kartal Y., 2019 e, Shape-Based Descriptor for Sunn Pest Damaged Wheat Kernel Detection, , hakem değerlendirmesinde

Radhika V.R., Sardeshmukh M., (2014), Indian Wheat Seed Classification Based On Texture Analysis Using ANN, International Journal of Electrical, Electronics and Data Communication, Sayı: 2 (7) Sf 96-99

Schetselaar E., 1998, Fusion by the IHS transform: Should we use cylindrical or spherical coordinates?, International Journal of Remote Sensing, 19, 759-765

Simonyan, K., and Andrew Z., (2014), "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556

Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2010a. "Identification of insect damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging", Comput. Electron. Agric. Sayı: 73 (2), Sf 118-125

Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2009. "Detection of insect-damaged wheat kernels using near-infrared hyperspectral imaging", J. Stored Prod. Res. 45, 151-158.

Singh, C.B., Jayas, D.S., Paliwal, J., White, N.D.G., 2010b. "Detection of midge-damaged wheat kernels using short-wave near-infrared hyperspectral and digital colour imaging". Biosyst. Eng. 105, 380-387.

Söderkvist O., 2001, "Computer vision classification of leaves from Swedish trees (Ph.D. thesis)", Linköping

Szegedy C., 2015, Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)

Topal C., Akinlar C., 2012, "Edge drawing: a combined real-time edge and segment detector", J. Visual Commun. Image Represent. 23 6, 862–872,

Turhal K., Turhal Ü.Ç., 2014, "Yapay sinir ağları ile süne zararlısının buğday üzerindeki etkilerin belirlenmesi", Trakya University Journal of Natural Sciences, 15(1):25-30, 2014

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 [Erişim 2 Haziran 2017]

Xing, J., Bravo, C., Jancsok, P.T., Ramon, H., Baerdemaeker, J.D., 2005. "Detecting bruises on 'Golden Delicious' apples using hyperspectral imaging with multiple wavebands", Biosyst. Eng. 90 (1), 27-36.

Vedaldi A., 2010,. An open implementation of the SIFT detector and descriptor. Technical Report 070012, UCLA CSD

Wang X., Feng B., Bai X., Liu W., Latecki L.J, 2014, Bag of contour fragments for robust shape classification, Pattern Recognition, 47, 2116-2125

Williams, P., Geladi, P., Fox, G., Manley, M., 2009. "Maize kernel hardness classification by near infrared (NIR) hyperspectral imaging and multivariate data analysis", Anal. Chim. Acta Sayı: 653, Sf 121-130.

Zhang D., Lu G., 2004, "Review of shape representation and description techniques", Pattern recog. , 37, 1-19.



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

TÜBİTAK
PROJE ÖZET BİLGİ FORMU

Proje Yürütücüsü:	Doç. Dr. KEMAL ÖZKAN
Proje No:	116O576
Proje Başlığı:	Üç Farklı Görüntüleme Tekniğinden Elde Edilen Bilgilerin Birleşimi ile Buğday Çeşitlerinin Sınıflandırılması ve Hastalıklı Buğdayların Tespiti
Proje Türü:	1001 - Araştırma
Proje Süresi:	24
Araştırmacılar:	EROL SEKE, ONUR KOYUNCU, TURGAY ŞANAL, MURAT OLGUN, ŞAHİN IŞIK
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	ESKİŞEHİR OSMANGAZİ Ü. MÜHENDİSLİK MİMARLIK F. BİLGİSAYAR MÜHENDİSLİĞİ B.
Projenin Başlangıç ve Bitiş Tarihleri:	01/03/2017 - 01/03/2019
Onaylanan Bütçe:	251528.0
Harcanan Bütçe:	180487.47
Öz:	Tarım endüstrisinde makine öğrenme ve derin öğrenme sistemlerinin kullanımı oldukça büyük bir artış göstermiştir. Tarımsal ürünlerin çeşitlerinin tanınması sınıflandırılması üretim kalitesini ve verimliliğini olumlu yönde etkilemektedir. Tarım ürünleri arasında buğday ülkemizde ve dünyada insanların ihtiyaçlarını karşılaması açısından gıda ve sanayi sektöründe oldukça büyük bir paya sahiptir. Dolayısıyla üretiminin sağlanması ve devamlılığı ülkemiz ve dünya ekonomisi adına da oldukça önemlidir. Buğdayın çeşitlerinin tanınması ve sınıflandırılması da üretim kalitesini doğrudan etkilemektedir. Doğru sınıflandırma ve tanıma yapılabilmesi için yeni teknolojik sistemler geliştirilmektedir. Bu sayede insan gücü en aza indirilerek zamandan ve emekten tasarruf sağlanır. Bu proje kapsamında üç farklı görüntüleme tekniğinden (RGB, VNIR, SWIR) elde edilmiş buğday görüntüsünden oluşturulan veri seti üzerinde tanıma ve sınıflandırma çalışmaları yapılmıştır. Bu kapsamda geleneksel betimleyiciler ve kelimeler çantası modelinin yanı sıra derin öğrenme yöntemleri de proje kapsamında kullanılmıştır. İlaveten oy çokluğu kuralı, CNN ve BoW çerçevelerinin öngördüğü kararlar üzerine kurulmuştur. Tanıma doğruluğunu arttırmak adına öncelikle imge (image) füzyonu ve öznitelik (feature) füzyonu olmak üzere iki farklı füzyon yöntemi uygulanmıştır. Eğitimler sonucu elde edilen sonuçlara göre derin öğrenme yöntemlerinin parametrik bağımlılara göre daha başarılı olduğu görülmüştür. Geliştirilen bu sistem etkili ve zahmetsiz tanımlama ve sınıflandırma imkânı sunarken aynı zamanda derin öğrenme teknolojisinin buğday çekirdeği türlerini yüksek performans ile ayırt edebileceğini göstermektedir. Ülke ekonomisinde büyümeye yaptığı katkının yanı sıra buğday endüstrisinde insan iş gücünü azaltarak daha fazla verimlilik ve üretkenlik sağlamak adına önemli bir adım atılmasını sağlamaktadır.
Anahtar Kelimeler:	Buğday Danesi Sınıflandırma, Süne Zararlısı, Hiperspektral Görüntüleme, Füzyon
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Hayır
Projeden Yapılan Yayınlar:	1- Unclassified Wheat Identification with Bag ofContour Fragments (Bildiri - Uluslararası Bildiri - Sözlü Sunum), 2- Shape Features Based Conic Arcs for Unclassified Wheat Identification (Bildiri - Uluslararası Bildiri - Sözlü Sunum),