

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**SEZGİSEL BULANIK KÜME TABANLI DERİN ÖĞRENME
MODELLERİYLE HAPLOİD VE DİPLOİD MISIRLARIN
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN : İbrahim AYAZ
DANIŞMAN : Dr. Öğr. Üyesi Fatih KUTLU
II. DANIŞMAN : Doç. Dr. Zafer CÖMERT

VAN-2022

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**SEZGİSEL BULANIK KÜME TABANLI DERİN ÖĞRENME
MODELLERİYLE HAPLOİD VE DİPLOİD MISIRLARIN
SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: İbrahim AYAZ

Bu çalışma TÜBİTAK tarafından 2210-C öncelikli alanlara yönelik yurt içi yüksek lisans burs programı (Başvuru no:1649B022100495) kapsamında desteklenmiştir.

VAN-2022

KABUL VE ONAY SAYFASI

Yapay Zeka ve Robotik Anabilim Dalı'nda Dr. Öğr. Üyesi Fatih KUTLU ve Doç. Dr. Zafer CÖMERT danışmanlığında, İbrahim AYAZ tarafından sunulan “Sezgisel Bulanık Küme Tabanlı Derin Öğrenme Modelleriyle Haploid ve Diploid Mısır Tohumlarının Sınıflandırılması” isimli bu çalışma Lisansüstü Eğitim-Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 25/05/2022 tarihinde aşağıdaki jüri tarafından **oy birliği** ile başarılı bulunmuş ve **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Başkan	: Dr. Öğr. Üyesi Vedat TÜMEN	İmza:
Üye	: Dr. Öğr. Üyesi Fatih KUTLU	İmza:
Üye	: Dr. Öğr. Üyesi Murat CANAYAZ	İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/...../2022 tarih ve sayılı kararı ile onaylanmıştır.

...../...../2022

Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

2022

İbrahim AYAZ

İmza



ÖZET

SEZGİSEL BULANIK KÜME TABANLI DERİN ÖĞRENME MODELLERİYLE HAPLOİD VE DİPLOİD MISIRLARIN SINIFLANDIRILMASI

AYAZ, İbrahim

Yüksek Lisans Tezi, Yapay Zeka ve Robotik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Fatih KUTLU

II. Danışman: Doç. Dr. Zafer CÖMERT

Haziran 2022, 67 Sayfa

Mısır, tüm dünyada yetiştirilen buğdaygiller familyası içerisinde yer alan önemli bir tahıl bitkisidir. İnsan nüfusunun ve çevresel faktörlerin artmasıyla birlikte mısır bitkisine olan ihtiyaç her geçen gün artmaktadır. Mısır üretimini artırmanın etkili yöntemlerinden biri de mısır ıslahıdır. Mısır ıslahında en etkili ve hızlı yöntem katlanmış haploid tekniğidir. Bu teknik, mısır yetiştirme süresini kısaltır ve verimliliği artırır. Mısır ıslah sürecinde haploid mısır tohumlarının seçilmesi için farklı seçim yöntemleri bulunmaktadır. Bu seçim yöntemleri arasında en yaygın ve en başarılı seçim yöntemi R1-Navajo (R1-nj) işaretçisinin görsel olarak kontrol edilmesidir. Mısır tohumlarının elle ayrılması, zaman alan ve hataya açık bir işlemdir. Emek yoğun ve oldukça yorucudur, bu nedenle haploid ve diploid mısır tohumlarını birbirinden ayıştıracak hızlı ve yüksek doğruluklu akıllı bir sistemin geliştirilmesi elzemdir.

Bu tezde, haploid ve diploid mısır imgeleri, sezgisel bir bulanık c-ortalama algoritması kullanılarak R1-nj renklendirmesine göre bölümlere ayrılmıştır. Mısır tohumlarının sınıflandırılması için yeni bir hibrit derin öğrenme modeli önerilmiştir. Önerilen hibrit model, CBAM, hiper sütun, 2B üst örnekleme ve artık blok gibi bazı yeni teknikler kullanılmıştır. Veri seti 3000 mısır imgesinden oluşmaktadır. Mısır imgeleri sezgisel bulanık kümeleme algoritmasıyla bölütlenmiştir. Önerilen yöntemlerin performans ölçümleri için 5 katlı çapraz doğrulama tekniği kullanılmıştır. IFCM+CNN modeliyle kabul edilebilir başarımlar elde edilmiştir. CNN modeliyle 94.13% doğruluk, 94.91% F1-Skoru ve 97.27% hassasiyet ile yüksek başarımlı bir sonuç elde edilmiştir.

Anahtar kelimeler: Akıllı tarım, Bölütleme, Derin öğrenme, Sezgisel bulanık kümeler, Yapay zeka.



ABSTRACT

CLASSIFICATION OF HAPLOID AND DIPLOID MAIZE SEEDS WITH INTUITIONISTIC FUZZY SET-BASED DEEP LEARNING MODELS

AYAZ, İbrahim

MSc. Artificial Intelligence and Robotics

Advisor: Asst. Prof. Dr. Fatih KUTLU

Co-Advisor: Assoc. Prof. Dr. Zafer CÖMERT

June 2022; 67 Pages

Maize is an important cereal plant in the family of wheatgrass cultivated all over the world. With the increase in human population and environmental factors, the need for maize plants is increasing day by day. One of the effective methods of increasing maize production is maize breeding. The most effective and fastest method in maize breeding is the doubled haploid technique. This technique shortens maize growing time and increases productivity. There are different selection methods for selecting haploid maize seeds in the maize breeding process. Among these selection methods, the most common and most successful selection method is visually checking the R1-Navajo (R1-nj) marker. Manual separation of maize seeds is a time-consuming and error-prone process. It is labor-intensive and very tiring, so the development of a fast and highly accurate intelligent system to separate haploid and diploid maize seeds is essential.

In this thesis, haploid and diploid maize images were segmented according to R1-nj coloring using an intuitionistic fuzzy c-means algorithm. A new hybrid deep learning model is proposed for the classification of maize seeds. Some new techniques such as the proposed hybrid model, CBAM, hypercolumn, 2D upsampling, and residual block are used. The dataset consists of 3000 maize images. Maize images are segmented by the intuitionistic fuzzy clustering algorithm. For the performance measurements of the proposed methods, the 5-fold cross-validation technique was used. Acceptable performance was obtained with the IFCM+CNN model. A high-performance result was achieved with the CNN model with an accuracy of 94.13%, an F1-Score of 94.91% and an accuracy of 97.27%.

Keywords: Smart agriculture, Segmentation, Deep learning, Intuitionistic fuzzy sets, Artificial intelligence,



ÖN SÖZ

Yüksek lisans süresince samimi ve insani yönleriyle aynı zamanda bilgi ve tecrübeleriyle bana destek olan, kariyerime önemli katkılar sağlayan danışman hocalarım Sayın Dr. Öğr. Üyesi Fatih KUTLU ve Doç. Dr. Zafer CÖMERT'e;

Yüksek lisans süresi boyunca öneri ve bilgileriyle desteklerini sunan Van Yüzüncü Yıl Üniversitesi Yapay Zekâ ve Robotik Anabilim Dalı bölüm hocalarıma ve Bitlis Eren Üniversitesi Bilgisayar Mühendisliği bölüm çalışanlarının tümüne;

Tez süresince öncelikli alanlara yönelik yurt içi yüksek lisans burs programı olan TÜBİTAK 2211 Yurt İçi Lisansüstü Burs Programına ve araştırma sürecinde HPC kaynaklarını kullandırdıkları için Harran Üniversitesi Yüksek Başarımlı Hesaplama Merkez'ine;

Ayrıca eğitim hayatımda her zaman yanımda olan başta babam ve annem olmak üzere ailem ve tüm dostlarıma teşekkür ederim.

2022

İbrahim AYAZ



İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	iii
ÖN SÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ	ix
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR	xiii
1. GİRİŞ.....	1
1.1. Haploid Bitkinin Üretimi.....	2
1.1.1. In vitro haploid tekniği	2
1.1.2. In vivo haploid tekniği	2
1.2. Haploid ve Diploid Mısır Tohumlarının Ayırıştırılması.....	3
2. KAYNAK BİLDİRİŞLERİ	7
3. MATERYAL VE YÖNTEM.....	13
3.1. Veri Seti.....	13
3.2. Embriyo ve R1-nj Belirtecinin Bölütlenmesi	16
3.3. Mısır İmgelerinin Sınıflandırılmasında Kullanılan Derin Öğrenme Mimarisi...	18
3.4. Kümeleme.....	19
3.4.1. K ortalamalar algoritması.....	19
3.4.2. Uzaklık metrikleri	20
3.5. Bulanık Küme Teorisi.....	21
3.5.1. Bulanık c ortalamalar algoritması (FCM)	23
3.6. Sezgisel Bulanık Küme Teorisi	25
3.6.1. Sezgisel bulanık c ortalamalar algoritması (IFCM)	26
3.7. Kümeleme Geçerlilik İndeksleri.....	29
3.8. Derin Öğrenme	30
3.8.1. Evrişimsel sinir ağı (convolutional neural networks - CNN).....	31
3.8.1.1. Giriş katmanı (input layer).....	32
3.8.1.2. Evrişim katmanı (convolution layer)	32
3.8.1.3. Havuzlama katmanı (pooling layer).....	34
3.8.1.4. Tam bağlı katman (fully connected layer)	35
3.8.1.5. Seyreletme katmanı (dropout)	35
3.8.1.6. Softmax katmanı	36

3.8.1.7. Evrişim bloklı dikkat modülü katmanı.....	36
3.8.1.8. Artık bloklar (residual blok)	38
3.8.1.9. Hiper sütun tekniğı.....	39
3.8.2. Evrişimsel sinir ağıları ile geliştirilen derin öğrenme mimarileri	39
3.8.2.1. AlexNet	39
3.8.2.2. GoogLeNet.....	40
3.8.2.3. VGG-16.....	40
3.8.2.4. ResNet.....	41
3.8.3. Aktivasyon fonksiyonu	42
3.8.3.1. Sigmoid	42
3.8.3.2. Softmax	43
3.8.3.3. ReLU	43
3.8.3.4. Hiperbolik tanjant (tanh).....	44
3.8.4. Hiper parametreler.....	44
3.8.5. Performans ölçümleri	46
3.8.5.1. Karmaşıklık matrisi.....	46
3.8.5.2. Alıcı işletim karakteristiğı.....	48
3.8.5.3. K-katlı çapraz doğrulama.....	49
4. BULGULAR.....	51
5. TARTIŞMA ve SONUÇ.....	57
KAYNAKLAR.....	61
ÖZ GEÇMİŞ.....	67

ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. 107 kaynak donör genotip listesi (Altuntaş, 2018).	14
Çizelge 3.2. FCM algoritmasının sözde kodu (Baykasoğlu ve ark., 2019).....	25
Çizelge 3.3. Küme geçerlilik indeksleri.	30
Çizelge 4.1. Küme geçerlilik indekslerinin sonuçları.....	51
Çizelge 4.2. IFCM+CNN ve CNN modellerinde kullanılan hiper parametreler.....	52
Çizelge 4.3. IFCM+CNN modelinin her kattaki karmaşıklık matrisleri.	55
Çizelge 4.4. CNN modelinin her kattaki karmaşıklık matrisleri.	55
Çizelge 4.5. Her iki modelin performans ölçüm sonuçları.....	56
Çizelge 5.1. Aynı veri setini kullanan çalışmalar ve performans metrikleri.	57
Çizelge 5.2. Haploid ve Diploid mısırların sınıflandırılmasıyla alakalı çalışmalar.	57

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 1.1. Geleneksel mısır ıslahı süreci ve KH tekniğiyle mısır ıslah süreci.	3
Şekil 1.2. Haploid (a) ve diploid (b) mısır tohumları üzerindeki R1-nj renk markörü. ...	4
Şekil 3.1. (a) haploid, (b) diploid mısır imgeleri.	16
Şekil 3.2. Diploid imgeye ait segmentasyon sonucu.	17
Şekil 3.3. Diploid imgeye (d (101).jpg) ait kayıp eğrisi.	17
Şekil 3.4. Haploid imgeye ait segmentasyon sonucu.	17
Şekil 3.5. Haploid imgeye (h (149).jpg) ait kayıp eğrisi.	18
Şekil 3.6. Derin öğrenme modelinin mimarisi.	19
Şekil 3.7. Yapay zekanın çalışma alanları.	31
Şekil 3.8. ESA mimarisinde bulunan katmanlar (Albelwi ve Mahmood, 2017).	32
Şekil 3.9. Evrişim aşamaları.	33
Şekil 3.10. Havuzlama katmanı işlem aşamaları (Tümen, 2019).	34
Şekil 3.11. (a) Standart YSA, (b) seyreltme sonrası YSA (Srivastava ve ark., 2014). ...	35
Şekil 3.12. Kanal dikkat modülü yapısı (Woo ve ark., 2018).	37
Şekil 3.13. Uzamsal dikkat modülü yapısı (Woo ve ark., 2018).	38
Şekil 3.14. CBAM katmanının genel yapısı (Woo ve ark., 2018).	38
Şekil 3.15. Artık öğrenmenin yapısı.	39
Şekil 3.16. AlexNet mimarisi (Hemmer ve ark., 2018).	40
Şekil 3.17. VGG-16 mimarisi (Blauch ve ark., 2021).	41
Şekil 3.18. ResNet mimarisi (Sarwinda ve ark., 2021).	42
Şekil 3.19. Sigmoid aktivasyon fonksiyonu (Başaran, 2020).	43
Şekil 3.20. Rectified linear unit grafiği.	44

Şekil	Sayfa
Şekil 3.21. Tanh aktivasyon fonksiyonu.	44
Şekil 3.22. (a)Momentum kullanılarak SDG, (b)momentum kullanılmadan SDG.	46
Şekil 3.23. Karmaşıklık matrisi.	47
Şekil 3.24. Alıcı işletim karakteristiği grafiği (Cömert, 2017).	49
Şekil 3.25. 5-Katlı çapraz doğrulama tekniği.	50
Şekil 4.1. Orijinal ve bölütlenmiş mısır imgeleri	52
Şekil 4.2. IFCM+CNN modelinin döneme bağlı kayıp ve doğruluk grafikleri.	53
Şekil 4.3. CNN modelinin döneme bağlı kayıp ve doğruluk grafikleri.	54
Şekil 4.4. (a) IFCM+CNN modelinin ROC eğrisi (b) CNN modelinin ROC eğrisi.	56

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	Açıklama
FS	Bulanık (fuzzy) kümeler
FS^X	X kümesinde tanımlı bulanık kümelerin ailesi
IFS	Sezgisel bulanık (intuitionistic fuzzy) kümeler
IFS^X	X kümesinde tanımlı sezgisel bulanık kümelerin ailesi
u	Üyelik matrisi (bölüm matrisi)
v	Küme merkezleri
J_m	Amaç fonksiyonu
ε	Durdurma kriteri (epsilon)
m	Bulanıklaştırıcı değeri
$d(X, Y)$	X ve Y noktaları arasındaki uzaklık değeri
μ	Üyelik derecesi
η	Üye olmama derecesi
π	Belirsizlik (tereddüt) derecesi
μ_A	A bulanık kümesine üye olma derecesi
η_A	A bulanık kümesine üye olmama derecesi
π_A	A bulanık kümesinin belirsizlik derecesi
u_{ik}	i . kümedeki k 'inci verinin x_k üye olma değeri
u_{ik}^*	i . sınıftaki k 'inci verinin sezgisel bulanık kümeye üyeliğini gösterir
v_i^*	i . kümenin sezgisel bulanık kümedeki merkez
π_i^*	i . kümenin belirsizlik derecesi
J_2	Sezgisel bulanık entropi
y_r	Softmax katmanının çıkış değeri

Kısaltmalar	Açıklama
TÜİK	Türkiye İstatistik Kurumu
TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
KH	Katlanmış Haploid
IGC	Uluslararası Hububat Konseyi
FAO	Gıda ve Tarım Örgütü
R1-nj	R1-Navajo (Mısır embriyosundaki renklenme belirteci)
FCM	Bulanık C Ortalamalar (Fuzzy C Means)
IFCM	Sezgisel Bulanık C Ortalamalar (Intuitionistic Fuzzy C Means)
IFE	Sezgisel Bulanık Entropi (Intuitionistic Fuzzy Entropy)
IVIFSs	Aralık Değerli Sezgisel Bulanık Küme (Interval-Valued Intuitionistic Fuzzy Sets)
MIFCM	Değiştirilmiş Sezgisel Bulanık C Ortalamaları (Modified Intuitionistic Fuzzy C Means)
SGD	Stokastik Gradyan İniş (Stochastic Gradient Descent)
DNA	Deoksiribo Nükleik Asit
AI	Yapay Zeka (Artificial Intelligence)
ESA	Evrışimli Sinir Ağı (Convolutional Neural Networks)
YSA	Yapay sinir ağı
AİK	Alıcı işletim karakteristiği (Receiver Operating Characteristic)
ReLU	Rectified Linear Unit
TanH	Hiperbolik Tanjant
DP	Doğru Pozitif (True Positive)
DN	Doğru Negatif (True Negative)
YP	Yanlış Pozitif (False Positive)
YN	Yanlış Negatif (False Negative)
RGB	Kırmızı Yeşil Mavi (Red Green Blue)

1. GİRİŞ

Dünyada en çok üretilen ikinci mahsul olan Mısır (*Zea mays L.*) temel gıda olarak insan beslenmesinde, yem olarak hayvan beslenmesinde, ham madde olarak endüstride ve biyoyakıt olarak makinelerde kullanılan buğdaygiller familyası içerisinde yer alan önemli bir tahıl bitkisidir (Fuente, 2015). Afrika, Asya ve Amerika'nın yoksul bölgelerinde yaşayan halkın temel gıda kaynağıdır (Prigge, 2012). Uluslararası Hububat Konseyi (IGC) verilerine göre 2020-2021 yıllarında 1.126 milyar ton mısır üretimi ve 1.148 milyar ton mısır tüketimi yapıldığı tahmin edilmektedir. 2021-2022 yıllarında mısır üretiminin 1.210 milyar ton ve 1.201 milyar ton mısır tüketiminin olacağı ön görülmektedir (International Grains Council, 2021). Gıda ve Tarım Örgütü tahminlerine göre dünya stok-tüketim oranı 2021-2022'de %21'e düşecektir. Bu oran 2012-2013 yılından bu yana en düşük seviyeyi göstermektedir (FAO, 2020). Türkiye İstatistik Kurumu Ekim ayı verilerine göre 2021 yılında Türkiye'de mısır üretimi bir önceki yıla göre değişmeyerek 6.5 milyon ton olacağı ön görülmüştür (TÜİK, 2021).

Dünya çapında azalan tarım arazileri ve çevresel faktörlerin etkisiyle beraber artan dünya nüfusunu beslemek, verimli mahsullere ulaşmak, tarımsal üretimde yenilik ve verimlilik artışları bitki ıslah programlarının gelişmesini zorunlu hale getirmiştir. Bu sebeple mısır ıslah programları, kendi içinde melezlenmiş iki farklı hattı geçerek daha verimli ve daha öngörülebilir hibrit tohum çeşitleri üretir. Geleneksel mısır ıslah çalışmalarıyla saf hatların gelişimi uzun bir zaman alarak 6-7 yıl sürmektedir. Bu sürenin sonunda genomlar ancak %99 homozigot düzeyine ulaşılabilir (Veeramani ve ark., 2018). Bu sürenin kısaltılması haploid bitki elde etme teknikleri ile mümkündür (Altuntaş, 2018). Katlanmış haploid (KH) tekniği ile mısır ıslah süreci kısaltılarak 2-3 yıl içinde verimli bir şekilde homozigot hatların oluşmasını sağlar (Veeramani ve ark., 2018). KH tekniği ile 100% homozigot ve homojen hatların hızlı gelişimi sağlanmaktadır (De La Fuente ve ark., 2017).

İlk haploid mısır bitkisi Stadler ve Randolph tarafından 1929 - 1932 yılları arasında keşfedilmiştir. Daha sonraki yıllarda Chase (1947), Amerika'nın çeşitli mısır kuşağı materyallerinde düşük frekansta haploid mısırlar bulmuştur. Tüm bu gelişmeler mısır ıslahında kromozom katlama maddesi olan kolhisinin keşfedilmesine, in vitro anter

ile laboratuvar ortamında mikrospor kültür tekniklerinin başarılı bir şekilde uygulanmasına ve in vivo haploid tekniği için uygun genotiplerin tespitine imkân sağlamıştır (Geiger, 2009).

1.1. Haploid Bitkinin Üretimi

Haploid bitkiler “in vitro” ve “in vivo” olmak üzere iki indirgeme (indüklenme) tekniği ile elde edilir (Cerit ve ark., 2016). Bölüm 1.1.1 ve Bölüm 1.1.2’de bu tekniklerden bahsedilmiştir.

1.1.1. In vitro haploid tekniği

Haploid bitkilerin üretimi için in vitro kültür tekniklerinin başarılı bir şekilde uygulanması araştırmacıları cesaretlendirerek bu tekniğin mısırdaki uygulanmasına teşvik etmiştir. Uygulama sonucunda mısır bitkisi, tatmin edici in vitro embriyogenez sergileyen çok az sayıda genotip ile son derece inatçı bir bitki türü olduğu saptanmıştır (Geiger, 2009). In vitro haploid tekniği laboratuvar ortamında anter veya mikro spor kültürü, polenleri farklı sıcaklıklarda bekletilmesi ve polenlerin ışınlaması gibi çeşitli teknikler uygulanarak haploid bitkilerin elde edilmesi mümkündür. In vitro tekniklerinin genotip etkisi sebebiyle yeterli düzeyde sonuç alınamamıştır (Cerit ve ark., 2016).


1.1.2. In vivo haploid tekniği

In vivo haploid bitki elde etme tekniğinde son yıllarda indükleyici adı verilen tozlayıcı olarak kullanılan hatlar kullanılmaktadır. Bu hatlar rastgele bir biçimde toz verdiği bitkinin koçanlarında haploidlerin oluşmasına imkân sağlamaktadır. Koçanlardaki haploid tohumlar, seleksiyon ve çimlendirme işleminden sonra kromozom katlama maddesi olan kolhisin ile kendilenerek 100% homozigot fertil (verimli) KH hatlar elde edilir. (Cerit ve ark., 2016).

In vivo haploid tekniği ile KH hatların elde edilmesi paternal (androgetik) ve maternal (gynogenetik) haploidler olmak üzere iki yöntem ile gerçekleştirilir (Cengiz, 2016). Paternal Haploid Yöntemi, indükleyici hattın toz alıcı (ana ebeveyn) olarak

kullanılmasıdır. Maternal Haploid Yöntemi, indükleyici hattın polinatör (baba ebeveyn) olarak kullanılmasıdır. Paternal haploid yöntemi ile elde edilen haploid miktarı maternal haploid yöntemine göre çok daha düşüktür (Cerit ve ark., 2016). Yüksek miktarda haploid bitki elde etme nedeniyle maternal haploid tekniği daha çok tercih edilmektedir (Altuntaş, 2018). In vivo haploid tekniği ile geliştirilen KH hatların çoğu ticari amaçlı geliştirilmiştir. KH hatların gelişiminde diğer tekniklerin etkisi daha azdır (Cerit ve ark., 2016).

KH hatları, kromozom katlama maddesi olan kolhisinin haploidlere uygulanmasıyla elde edilir. Bu uygulama pahalı ve zehirli kimyasal içerir. Bu nedenle kromozom katlanması uygulanmadan önce haploidlerin etkin bir şekilde seçilmesi, kimyasal maddelerin kullanımı, mısır ekim alanı, iş gücü ve ekim alanındaki diploid tohumların yönetimi açısından kaynak tasarrufu sağlar (Chaikam ve ark., 2016). Şekil 1.1'de görüldüğü üzere katlanmış haploid tekniğinin geleneksel mısır ıslahı yöntemine göre çok daha erken ve verimli bir mahsul elde edildiği görülmektedir.




Şekil 1.1. Geleneksel mısır ıslahı süreci ve KH tekniğiyle mısır ıslah süreci.

1.2. Haploid ve Diploid Mısır Tohumlarının Ayrıştırılması

KH tekniğindeki en zahmetli ve en önemli aşama, haploid mısır tohumlarının diploid mısır tohumlarından ayrıştırılması işlemidir (Melchinger ve ark., 2014). Kromozomlara katlanmış haploid tekniğini uygulamadan önce indüklenen tohumlar arasından sayıca az olan haploidlerin, diploidlerden ayrıştırılması gerekir çünkü KH tekniğinde sadece haploidler kullanılır. Bu durum haploid tohumların hızlı ve duyarlı bir

şekilde seçilmesi için önemlidir (Geiger ve ark., 2013). Haploid tohumları seçmek için farklı seçim yöntemleri vardır. Bu seçim yöntemlerinden en yaygın olarak kullanılan ve en başarılı seçilebilir belirteç R1-Navajo (R1-nj)'dur (Chase ve Nanda, 1969). R1-nj belirtecinin haricinde embriyo ağırlıkları (Smelser ve ark., 2015), yağ içeriği seviyeleri (Melchinger ve ark., 2014) ve redroot (Chaikam ve ark., 2016) arasındaki farklar gibi alternatif seçilebilir belirteçler de mevcuttur. Baskın R1-nj markörü, indükleyici genotipler üzerinde antosiyanin pigmentasyonuna bağlı olarak aleurone ve scutellum'un mor renklenmesine neden olur (Melchinger ve ark., 2014). Şekil 1.2'de görüldüğü üzere R1-nj renk markörü, embriyo ve endosperm üzerindeki renklenme haploid ve diploid mısır tohumunun ayrımını kolaylaştırır, görsel olarak sınıflandırmasına izin verir (Altuntaş ve ark., 2019).



Şekil 1.2. Haploid (a) ve diploid (b) mısır tohumları üzerindeki R1-nj renk markörü.

Embriyo ve endosperm üzerindeki kırmızı-mor renkli tohumlara diploid denir. Diploid tohumlarda kaynak genotip ve indükleyici hattın kromozomunu içerdiğinden, $2n$ kromozomu vardır. Tohumların endospermelerinde R1-nj renklenmesi olsa da embriyolarının renksiz olması bu tohumların haploid olduğunu gösterir. Haploid tohumlar sadece donör bitkinin kromozomlarını taşıdığından dolayı n kromozoma sahiptir (Altuntaş ve ark., 2019). Geleneksel olarak elle yapılan emek-yoğun ve hataya açık olan bu ayrıştırma sürecinin minimum hatayla hızlı bir biçimde otomatik olarak gerçekleştirilmesini sağlayacak yapay zeka tabanlı bir sistemin geliştirilmesi elzemdir.

Bu tez çalışmasında, haploid ve diploid mısır tohumlarını yüksek başarımlı bir biçimde ayrıştıracak bir yapay zeka uygulaması geliştirilmesi amaçlanmıştır. Çalışmada açık erişimli bir veri seti olan 1230 haploid ve 1770 diploid olmak üzere toplamda 3000 mısır tohumu imgesinden faydalanılmıştır. Veri setindeki mısır tohumu imgeleri sezgisel bulanık kümeleme algoritmalarından biri olan ve Chaira (2011) tarafından tanımlanan sezgisel bulanık c ortalamalar (intuitionistic fuzzy c means (IFCM)) ile bölütlenerek özgün evrimsel sinir ağına verilmek üzere hazır hale getirilmiştir. Sınıflandırma işlemlerinde kullanılan derin öğrenme modelinde artık blok, dikkat modülü, iki boyutlu örnekleme bloğu ve hiper sütun teknikleri kullanılmıştır.

Literatürde haploid ve diploid mısır tohumlarını otomatik ayrıştırmayı amaçlayan ve çalışmamızda kullandığımız yöntemleri uygulayan çalışmalara Bölüm 2’de yer verilmiştir. Bölüm 3’de tez çalışmasında kullanılan materyal ve yöntemlerden bahsedilmiştir. Bölüm 4’de elde edilen bulgulara/deneysel sonuçlara yer verilmiştir. Bölüm 5’de deneysel sonuçlar tartışılmış ve sonuçlar paylaşılmıştır.

2. KAYNAK BİLDİRİŞLERİ

Haploid ve diploid tohumların doğru ve otomatik bir biçimde ayrıştırılması emek-zaman açısından önemlidir. Bu kapsamda literatürde farklı teknikler uygulanmıştır. Çalışmamızda haploid ve diploid tohumların seçimi için akıllı sistemlerin geliştirilmesine yönelik araştırma yapan ve kullandığımız teknikleri kendi çalışmalarında kullanan benzer çalışmaların en önemli olanlarına yer verilmiştir.

Bezdek ve ark. (1984), bulanık c ortalamalar (fuzzy c means (FCM)) algoritmasını FORTRAN-IV ile kodlayarak algoritma programını birçok istatistiksel veri analiz problemlerinde kullanmışlardır. Ayrıca bu algoritma herhangi bir sayısal veri seti için bulanık bölümler ve prototipler oluşturduğu ifade edilmiştir. Bu bölümler bilinen alt yapıların doğruluğunu ölçmek ve henüz çalışılmamış verilerde alt yapı önermek için kullanışlı olduğuna değinmişlerdir. FCM algoritmasının amaç fonksiyonunda genelleştirilmiş en küçük kareler yöntemi kullanılır. FCM üç temel uzaklık metriği (Öklid, Köşegen ve Mahalonobis), esas alarak gürültüye karşı hassasiyeti kontrol eden ayarlanabilir ağırlık faktörü, değişken sayıda kümenin kabulü ve küme geçerliliğini içeren çeşitli ölçütleri içerir (Bezdek ve ark., 1984).

Xu ve Wu (2010), sezgisel bulanık kümelerin (intuitionistic fuzzy sets (IFS)) karmaşık ve belirsizliğe yatkın öznitelikleri bulunana verileri ele almak için kullanılan faydalı bir yöntem olduğundan bahsetmiştir. Bu çalışma da IFS'leri kümelemek için sezgisel bulanık c ortalamalar (intuitionistic fuzzy c means (IFCM)) algoritması geliştirilmiştir. Tanımlanan bu algoritmanın her aşamasında kaynak matrisler değiştirilir ve IFS için kümelerin her birine bir üyelik dereceleri hesaplanır. Algoritma sonunda verilen tüm IFS'lerin tahmini üyelik derecelerine göre kümelenmesi sağlanır. Ayrıca aralık-değerli sezgisel bulanık kümeler (interval-valued intuitionistic fuzzy sets (IVIFSs)) için de IFCM kullanılabilir. Bu çalışmada tanımlanan kümeleme algoritması gerçek ve simüle edilmiş verilerle test edilerek etkinliği kanıtlanmıştır (Xu ve Wu, 2010).

Chaira (2011), sezgisel bulanık küme teorisini kullanan sezgisel bulanık c ortalamalar (intuitionistic fuzzy c means (IFCM)) ile isimlendirilen kümeleme yöntemini Xu ve Wu çalışmasından farklı olarak yeniden ele almıştır. Bu yöntemde, üyelik fonksiyonları tanımlanırken ortaya çıkan tereddüt derecesi diğer bir deyişle belirsizlik

parametresini dikkate alınır. Bu nedenle FCM algoritması kullanılarak küme merkezlerinin istenilen konumuna yakınsama yapabileceği anlaşılır. Ayrıca sezgisel bulanık entropi (intuitionistic fuzzy entropy (IFE)) olan yeni bir amaç fonksiyonu algoritmaya dâhil edilmiştir. Bu eklenti kümedeki iyi noktaları maksimize etmek için kullanılır ve bu noktalar beyin görüntülerindeki anormallikleri tespit etmek için kullanılmıştır. Deneysel sonuçlar önerilen yöntemin geleneksel FCM algoritmalarının ve tip II bulanık algoritmalarına nazaran daha iyi bir yöntem olduğunu göstermektedir (Chaira, 2011).

Majumdar ve ark. (2014), buğday yaprağındaki hastalığın olup olmadığını görüntüsünden tespit eden yeni ve etkili bir yol sunmaktadır. Veri setindeki buğday görüntüsünün belirlenen özelliklerinden oluşan veri noktalarına FCM algoritması uygulanır. İlk aşama da veri kümesini hastalıklı ve hastaliksız olarak bölmek için küme sayısı (c) 2 seçilerek gruplandırılır. Daha sonra bilinen dört hastalık tipine karşın hastalıklı veri setini dört kümeye ayırmak için küme sayısı dört olarak seçilerek FCM ile sınıflandırılmıştır. Sınıflar arası ve sınıf içi varyansa dayalı özellik kümelerinin seçimi için etkili bir yöntem geliştirdikleri önerilmiştir. Bu çalışma sadece buğday yaprağında uygulanmış olsa da diğer bitkilerin yaprak görüntülerinde de aynı yöntemin uygulanabilirliğinden bahsedilmiştir (Majumdar ve ark., 2014).

Veeramani ve ark. (2018), derin evrimsel sinir ağını kullanarak haploid mısırları sıralayan DeepSort adında yeni bir derin öğrenme modeli önermiştir. Bu çalışmada 4021 adet mısır tohumu (809 haploid ve 3212 diploid) imgesi ve 5-katlı çapraz doğrulama tekniği kullanıldı. DeepSort modeli; destek vektör makinası, random forest ve lojistik regresyon sınıflandırıcılara göre %96 oran ile daha yüksek bir doğruluk elde edilmiştir (Veeramani ve ark., 2018).

Wang ve ark. (2018), çalışmalarında LSTM-CNN algoritması ve optimum dalga bandı seçimine dayalı bir yöntem önermiştir. Veri setinde 100'er haploid 100'er diploid olmak üzere iki mısır çeşidi (Zhengdan-958 ve Nongda-616) kullanılmıştır. Zhengdan-958 veri setiyle 1367.6-1526.4nm optimum dalga bandında %97 ye varan başarı elde etmişlerdir. Yine aynı optimum dalga bandında Nongda-616 veri setiyle %93'lük bir başarı elde etmişlerdir. Önerilen modelin haploid mısırların tanımlanmasında önemli bir etki yarattığı dile getirilmiştir (Wang ve ark., 2018).

Song ve ark. (2017), haploid mısır tohumlarını R1-nj renk markörünü referans olarak otomatik sınıflandıran bir sistem tasarlamıştır. Bu sistem tohum besleme birimi, görüntü alma birimi, sıralama birimi ve sistem kontrol birimini içerir. Tohum besleme ünitesi mısır tohumlarını bant üzerine dağıtır. Görüntü alma birimi, mısır tohumlarının görüntülerini çekip kaydeder ve endospermin renk özelliğine göre ayırıştırma işlemi yapar. Sistem kontrol birimi hava emişini kullanarak heterozigot çekirdeklerini ayırıştırabilen mekanik kollar ve solenoid valfler içerir. Bu sistem Çin Tarım Üniversitesi tarafından elde edilen dört mısır çeşidi tarafından test edilmiştir. Sistem % 91.39 varan başarılı boşaltma gerçekleştirmiştir. Heterozigot çekirdeklerin tanımlanmasında %95.04 varan başarı elde edilmiştir (Song ve ark., 2018).

Taylor (2019), karışık durumda olan haploid ve diploid mısır tohumlarından zaman alanlı dalga formlarını toplamak için Terahertz zaman alan spektroskopisi (THz-TDS) sistemini kullanmıştır. Veri setinde iyileştirme ve buna bağlı olarak azaltma yapmak için Watershed görüntü bölütleme tekniği kullanılmıştır. Dalga formu verileri frekans alanına dönüştürülerek eğitim verisi haline getirilmiştir. Veriler rastgele alt örnekleme tekniği kullanılarak yapay sinir ağına verildi. Sınıflandırıcı olarak makine öğrenmesi algoritmalarından biri olan olasılıksal sinir ağı (PNN) kullanıldı. Ayrıca 5 kat çapraz doğrulama tekniği ile %75'lik ortalama sınıflandırma başarısı elde edilmiştir (Taylor ve ark., 2019).

Altuntaş ve ark. (2019), evrimsel sinir ağı ve transfer öğrenme yaklaşımlarını kullanarak haploid mısır tohumlarını tanımlayan bir sistem geliştirdiler. Bu deneysel çalışmada AlexNet, VGGNet, GoogLeNet ve ResNet derin öğrenme modellerinin performans metrikleri karşılaştırılmış en iyi ve en verimli sonucun VGG-19 modeli olduğu vurgulanmıştır. Bu derin öğrenme modeli ile %94 oranında bir başarı sağlandı (Altuntaş ve ark., 2019).

Huang ve ark. (2019), mısır tohumundaki bozuklukları tespit etmek için derin öğrenme algoritma ile geleneksel makine öğrenmesi yöntemlerini karşılaştırmış, deneylerin derin öğrenme algoritması GoogLeNet'in %95 oranla daha iyi sonuç verdiğini vurgulamıştır (Huang ve ark., 2019).

Kumar ve ark. (2019), FCM'nin tıbbi görüntü segmentasyonu için kullanılan başlıca yöntemlerden biri olduğundan bahsetmişlerdir. Literatürde, gerçek verilerle ilişkili belirsizliği ele almak için sezgisel bulanık kümeler teorisine dayanan sezgisel

bulanık c ortalamalar önermişlerdir. Üyelik derecesi ile birlikte tereddüt derecesi kullanılarak amaç fonksiyonu tanımlanmıştır. Bununla birlikte, amaç fonksiyonunu analitik yöntemlerle çözmek yerine FCM kullanılarak yaklaşık çözüm elde edilmiştir. Çalışmalarında, değiştirilmiş sezgisel bulanık c ortalamalar (modified intuitionistic fuzzy c means (MIFCM)) algoritması önerilmiş ve belirsiz çarpanın Lagrange yöntemini kullanarak MIFCM yönteminin amaç fonksiyonu analitik olarak çözülmüştür. Tereddüt derecesini belirlemek için Sugeno ve Yager deęilleme (negation) fonksiyonları sezgisel bulanık tanımlayıcı olarak kullanılmıştır. MIFCM yönteminin performansı, üç sezgisel bulanık kümeleme yöntemi ve açık erişimli iki MRI veri kümesi ve sentetik veri kümesi üzerindeki FCM ile karşılaştırılmıştır. Ortalama bölümlene doğruluęu, f1 skor, jaccard index, yanlış-negatif oran ve yanlış pozitif oran gibi performans ölçütleri kullanılarak MIFCM yönteminin performansı üç farkı sezgisel bulanık kümeleme yöntemi ve FCM algoritmasıyla karşılaştırılmıştır. Deneysel sonuçlar neticesinde önerilen yöntemin diğerler yöntemlere göre daha başarılı sonuç verdiği saptanmıştır (Kumar ve ark., 2019).

García-Fortea ve ark. (2020), polen gelişim aşamalarının tespiti ve polenlerin tanımlanması için Microscan adında derin öğrenme tabanlı yapay sinir ağı modeli geliştirdi. İlk deneyde patlıcan erişimlerinin mikrosporlarıyla RetinaNet modeli uygulanarak %86.30'luk ortalama bir hassasiyet elde ettiler. İkinci deneyde in vitro olarak yetiştirilecek anter aralığı Microscan modeline verilerek üç tane patlıcan genotip tanımlandı. Bu genotipler Cb ve E6 androjenez protokolleriyle yetiştirildiler. Microscan ile tahmin edilen genotip E6 protokolüyle en iyi sonucu verdi. Elde edilen bitkiler, akış sitometrisi ve single primer zenginleştirme teknolojisi karakterize edildi ve yüksek oranda onaylanmış haploid ve katlanmış haploid bitkiler elde edildiği vurgulanmıştır (García-Fortea ve ark., 2020).

Özyurt ve ark. (2020), görüntü çözünürlüklerinde iyileştirmeler yapan süper çözünürlük yöntemini kullanmıştır. Bu yöntemin beyin manyetik rezonans görüntüsündeki çözünürlüğü artırması görüntüdeki önemli bilgilerin daha görünür ve net olması açısından hayati önem taşıdığından bahsetmiştir. Ayrıca bu yöntem beyin tümör görüntülerinin daha net bir şekilde tanımlanmasını sağlamaktadır. Bu çalışmada süper çözünürlük yöntemiyle görüntü iyileştirme, FCM ile görüntü segmentasyonu, SqueezeNet ile özellik çıkarımı ve aşırı öğrenme makinası ile sınıflandırma işlemi gerçekleştirmişlerdir. Sonuç olarak süper çözünürlüklü FCM yöntemiyle %98.33

doğruluk elde edilirken süper çözünürlüksüz Fuzzy C Means ile %10 daha az başarı elde edildiği vurgulanmıştır (Özyurt ve ark., 2020).

Toğaçar ve ark. (2021), beyin manyetik rezonans görüntülerinde tümör tespiti için BrainMRNet adlı derin öğrenme modelini kullanmışlardır. Bu model üç işlem adımı içermektedir. Bunlar dikkat modülleri, hipersütun tekniği ve artık bloklardır. Bu çalışmada glioma, meningioma ve hipofiz adlı üç tip tümör incelenmiştir. Beyin kanserine neden olan bu tümörlerin en çok beyinin hangi lob bölgesinde daha yoğun olduğunu tanımlayan bir segmentasyon yöntemi önermişlerdir. Sınıflandırma neticesince glioma tümörü için %98.18, meningioma için %96.73 ve hipofiz için %98.18 doğruluk elde edilmiştir. Sonuç olarak glioma ve meningioma tümörünün alt kümeleri kullanılarak beyin hangi lob bölgesinde görüldüğü %100 başarı ile belirlenmiştir. Bu çalışmada hibrit bir derin öğrenme modelini sunmaktadır. Deneyler; yüksek düzeyde doğruluk, kesinlik ve özgüllük gibi performans ölçütlerinde umut vaat eden sonuçları göstermiştir (Toğaçar ve ark., 2021).



3. MATERYAL VE YÖNTEM

Bu tez çalışmasında, mısır imgeleri kullanılarak iki aşamalı (IFCM+CNN) ve tek aşamalı (CNN) modeller ayrı ayrı eğitilerek haploid ve diploidlerin sınıflandırılması gerçekleştirilmiştir. İki aşamalı yöntemde sezgisel bulanık kümeleme algoritması olan Chaira (2011) tarafından tanımlanan IFCM algoritması ile mısır imgelerinin bölütlenmesi ve bölütlenen imgelerin sıfırdan oluşturduğumuz özgün derin öğrenme modeliyle sınıflandırılması gerçekleştirilmiştir. Tek aşamalı yöntem de orijinal mısır imgeleri oluşturduğumuz evrişimli sinir ağı (convolutional neural network (CNN)) modeline verilerek haploid ve diploid mısır imgelerinin sınıflandırılması gerçekleştirilmiştir. Bu çalışmada 2017 yılında hasat edilen 1230 haploid, 1770 diploid olmak üzere toplamda 3000 adet mısır imgesinden faydalanılmıştır. IFCM algoritmasının bölütleme parametreleri; bulanıklaştırıcı (m), değilleme parametresi (α), epsilon (ϵ) ve maksimum iterasyon değerleri ampirik bir şekilde belirlenmiştir. Ayrıca küme sayısı (c) küme geçerlilik indeksleriyle belirlenmiştir. Kullandığımız CNN modelinin başarımını ve güvenilirliğini arttırmak için 5-katlı çapraz doğrulama tekniği tercih edilmiştir. Oluşturduğumuz CNN modelinde evrişim katmanları ve havuzlama katmanları yanı sıra dikkat modülleri, hiper sütun tekniği, artık bloklar ve iki boyutlu üst örnekleme tekniği kullanılmıştır. Sınıflandırma performansını değerlendirmek için karmaşıklık matrisi elde edilmiştir. Bu hata matrisindeki indeksler kullanılarak doğruluk, f1-score, duyarlılık, özgüllük ve kesinlik gibi performans metrikleriyle sınıflandırmanın başarımı ölçülmüştür.

Segmentasyon ve CNN modelinin eğitim işlemlerinde NVIDIA Quadro P6000 ekran kartlı iş istasyonu, TESLA K80 işlemcili Google Colab bulut sunucuları ve Harran Üniversitesi Yüksek Performanslı Hesaplama Merkezi'nde bulunan TESLA K20X ekran kartlı yüksek performanslı bilgisayarlar kullanılmıştır.

3.1. Veri Seti

Çalışmamızda kullandığımız veri seti 2017 yaz ayında Sakarya Mısır Araştırma Enstitüsü Müdürlüğü tarafından “Ülkesel Mısır Islah Araştırmaları” projesi kapsamında

invivo maternal haploid indirgeme yöntemi kullanılarak RWS/RWK76'nın 107 kaynak genotip 'in çaprazlanmasıyla elde edilmiştir. Mısır tohumları alan uzmanları tarafından R1-nj belirteci dikkate alınarak seçilmiştir. Veri setinde 1230 haploid ve 1770 diploid olmak üzere toplam 3000 adet mısır tohumundan oluşmaktadır. Mısır imgelerinin çözünürlük boyutları 300x289 piksel ile 610x637 piksel arasında değişmektedir. 107 farklı kaynak genotip ile indirgeyici hatlar arasında yapılan indükleme melezlemesi sonucu Çizelge 3.1'de verilmiştir (Altuntaş, 2018). Bu veri seti çalışmalarda kullanılmak üzere ilk olarak Altuntaş vd. (Altuntaş ve ark., 2019) tarafından dijital kamera kullanılarak internet ortamına aktarılmış ve açık erişimli¹ olarak yayımlanmıştır.

Çizelge 3.1. 107 kaynak donör genotip listesi (Altuntaş, 2018).


No	Donör	No	Donör	No	Donör
1	TTSM A.Ü.1 ÇN-1	20	TTSM A.Ü.1 ÇN-23	39	TTSM A.Ü.2 ÇN-19
2	TTSM A.Ü.1 ÇN-2	21	TTSM A.Ü.2 ÇN-1	40	TTSM A.Ü.2 ÇN-20
3	TTSM A.Ü.1 ÇN-3	22	TTSM A.Ü.2 ÇN-2	41	TTSM A.Ü.2 ÇN-21
4	TTSM A.Ü.1 ÇN-4	23	TTSM A.Ü.2 ÇN-3	42	TTSM A.Ü.2 ÇN-22
5	TTSM A.Ü.1 ÇN-5	24	TTSM A.Ü.2 ÇN-4	43	TTSM II.Ü.1 ÇN-1
6	TTSM A.Ü.1 ÇN-6	25	TTSM A.Ü.2 ÇN-5	44	TTSM II.Ü.1 ÇN-2
7	TTSM A.Ü.1 ÇN-7	26	TTSM A.Ü.2 ÇN-6	45	TTSM II.Ü.1 ÇN-3
8	TTSM A.Ü.1 ÇN-8	27	TTSM A.Ü.2 ÇN-7	46	TTSM II.Ü.1 ÇN-4
9	TTSM A.Ü.1 ÇN-9	28	TTSM A.Ü.2 ÇN-8	47	TTSM II.Ü.1 ÇN-5
10	TTSM A.Ü.1 ÇN-10	29	TTSM A.Ü.2 ÇN-9	48	TTSM II.Ü.1 ÇN-6
11	TTSM A.Ü.1 ÇN-11	30	TTSM A.Ü.2 ÇN-10	49	TTSM II.Ü.1 ÇN-7
12	TTSM A.Ü.1 ÇN-12	31	TTSM A.Ü.2 ÇN-11	50	TTSM II.Ü.1 ÇN-9
13	TTSM A.Ü.1 ÇN-14	32	TTSM A.Ü.2 ÇN-12	51	TTSM II.Ü.1 ÇN-10
14	TTSM A.Ü.1 ÇN-15	33	TTSM A.Ü.2 ÇN-13	52	TTSM II.Ü.1 ÇN-12
15	TTSM A.Ü.1 ÇN-16	34	TTSM A.Ü.2 ÇN-14	53	TTSM II.Ü.1 ÇN-13
16	TTSM A.Ü.1 ÇN-17	35	TTSM A.Ü.2 ÇN-15	54	TTSM II.Ü.1 ÇN-14
17	TTSM A.Ü.1 ÇN-19	36	TTSM A.Ü.2 ÇN-16	55	TTSM II.Ü.2 ÇN-1
18	TTSM A.Ü.1 ÇN-20	37	TTSM A.Ü.2 ÇN-17	56	TTSM II.Ü.2 ÇN-2
19	TTSM A.Ü.1 ÇN-22	38	TTSM A.Ü.2 ÇN-18	57	TTSM II.Ü.2 ÇN-3

¹ <https://www.rovile.org/datasets/haploid-and-diploid-maize-seeds-dataset/>

Çizelge 3.1. 107 kaynak donör genotip listesi (devam) (Altuntaş, 2018).

No	Donör	No	Donör	No	Donör
58	TTSM II.Ü.2 ÇN-4	75	TTSM II.Ü.2 ÇN-21	92	TTSM SİLAJ ÇN-15
59	TTSM II.Ü.2 ÇN-5	76	TTSM II.Ü.2 ÇN-22	93	SPANISH RAW WAXY CORN-1
60	TTSM II.Ü.2 ÇN-6	77	TTSM II.Ü.2 ÇN-23	94	SPANISH RAW WAXY CORN-2
61	TTSM II.Ü.2 ÇN-7	78	TTSM II.Ü.2 ÇN-24	95	SPANISH WAXY-1 F2
62	TTSM II.Ü.2 ÇN-8	79	TTSM SİLAJ ÇN-1	96	SPANISH WAXY-2 F2
63	TTSM II.Ü.2 ÇN-9	80	TTSM SİLAJ ÇN-2	97	WAXY CORN F2
64	TTSM II.Ü.2 ÇN-10	81	TTSM SİLAJ ÇN-3	98	P1429
65	TTSM II.Ü.2 ÇN-11	82	TTSM SİLAJ ÇN-4	99	P1570
66	TTSM II.Ü.2 ÇN-12	83	TTSM SİLAJ ÇN-5	100	P2088
67	TTSM II.Ü.2 ÇN-13	84	TTSM SİLAJ ÇN-6	101	CORNELL COLD TOL. SYN-2
68	TTSM II.Ü.2 ÇN-14	85	TTSM SİLAJ ÇN-7	102	CORNELL COLD TOL. SYN-3
69	TTSM II.Ü.2 ÇN-15	86	TTSM SİLAJ ÇN-8	103	DRK. SPA DROUGHT SYN-1
70	TTSM II.Ü.2 ÇN-16	87	TTSM SİLAJ ÇN-9	104	DRK. SPA DROUGHT SYN-2
71	TTSM II.Ü.2 ÇN-17	88	TTSM SİLAJ ÇN-11	105	DRK. SPA DROUGHT SYN-3
72	TTSM II.Ü.2 ÇN-18	89	TTSM SİLAJ ÇN-12	106	6100-A (WAXY)
73	TTSM II.Ü.2 ÇN-19	90	TTSM SİLAJ ÇN-13	107	WAXY F2 İSPANYA
74	TTSM II.Ü.2 ÇN-20	91	TTSM SİLAJ ÇN-14		


Veri setinde yer alan mısır imgelerinden bazıları Şekil 3.1’de gösterilmiştir. Şekilde görüldüğü üzere haploid mısır imgelerinde renksiz embriyo olduğu açıkça görülmektedir. Diploid mısır imgelerinin embriyo bölgelerindeki R1-nj renklenmesi açıkça görülmektedir.




Şekil 3.1. (a) haploid, (b) diploid mısır imgeleri.

3.2. Embriyo ve R1-nj Belirtecinin Bölütlenmesi

Tez çalışmamızın birinci aşaması olan bölütleme işlemi, embriyo ve R1-nj bölgelerinin segmente etmek üzere IFCM algoritması tercih edilmiştir. IFCM algoritmasının parametreleri ve çalışma prensibine dayalı detaylı bilgi Bölüm 3.6.1’ de yer verilmiştir. IFCM algoritmasında kullanılan bulanıklaştırıcı (m), değilleme parametresi (a), epsilon (ϵ) ve maksimum iterasyon değerleri benzer çalışmalar ışığında deneye dayalı bir biçimde gözlem yapılarak belirlenmiştir. Küme sayısı (c) ise küme geçerlilik indeksleri kullanılarak belirlenmiştir. Küme sayısının belirlenmesinde üç farklı küme geçerlilik indeksi kullanılmıştır. Bu küme geçerlilik indekslerine Bölüm 3.7’ de yer verilmiştir. Deneysel çalışma sonucunda IFCM parametreleri (c) = 3, (m) = 1.3, (a) = 3, ϵ = 0.00001 ve maksimum iterasyon sayısı 50 olarak belirlenmiştir. Parametre değerleri değiştirilmeden veri setindeki tüm mısır imgesine aynen uygulanmıştır. Gözlemler neticesinde el elde edilen segmentasyon sonuçlarının bazılarına yer verilmiştir. Şekil 3.2 bölütlenmiş imgeyi, Şekil 3.3 ise bölütlenen imgenin kayıp eğrisini göstermektedir.




Şekil 3.2. Diploid imgeye ait segmentasyon sonucu.




Şekil 3.3. Diploid imgeye (d (101).jpg) ait kayıp eğrisi.

Grafikte görülen 0-5 iterasyon arasındaki kayıp eğrisinin yükselmesi, rastgele değerlerle elde edilen başlangıç matrisinden kaynaklanmaktadır.



Şekil 3.4. Haploid imgeye ait segmentasyon sonucu.

Şekil 3.4.'de görüldüğü üzere en belirgin R1-nj belirteci ve embriyo bölgesi 3. kümededir ve nihai kümeyi ifade etmektedir. Üçüncü küme daha sonra gürültü azaltma işleminden geçirilmiş ve evrişimli sinir ağına verilmiştir. Şekil 3.5 ise segmentasyon işleminin kayıp eğrisini göstermektedir.




Şekil 3.5. Haploid imgeye (h (149).jpg) ait kayıp eğrisi.

Her bir segmentasyon sonucunun nihai kümesi gözlem yoluyla belirlenmiştir. Nihai kümenin elde edilmesinde R1-nj belirteci ve embriyo bölgesi dikkate alınmıştır. Daha sonra elde edilen bölütlenmiş nihai mısır imgeleri evrişimli sinir ağına verilmek üzere hazır hale getirilmiştir.

3.3. Mısır İmgelerinin Sınıflandırılmasında Kullanılan Derin Öğrenme Mimarisi

Bu tez çalışmasında kullanmış olduğumuz özgün derin öğrenme modelinin mimarisi Şekil 3.6. 'da gösterilmiştir. Bu model Toğaçar ve ark. (2020) tarafından önerilen BrainMRNet adlı derin öğrenme modelinden esinlenerek oluşturulmuştur. BrainMRNet modelinden farklı olarak ilk evrişim aşamasından sonra evrişim bloklu dikkat modülü (Convolution Block Attention Module (CBAM)) ve artık bloklar kullanılmıştır. Ayrıca evrişim katmanına 0.01 oranında L2 düzenlileştirme ve her katman sonrasında 0.45 oranında seyreltme işlemi uygulanarak aşırı öğrenme engellenmiştir. Eğitim aşamasında kullanmış olduğumuz derin öğrenme modelinde evrişim ve tam bağlı katmanlardan sonra yığın normalleştirme ve *ReLU* aktivasyon fonksiyonu kullanılmıştır. Çıkış katmanında ise softmax aktivasyon fonksiyonu kullanılarak ikili sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 3.6. Derin öğrenme modelinin mimarisi.

Sınıflandırma için kullandığımız derin öğrenme modelinin katmanlarına, hiper parametrelere, popüler derin öğrenme modellerine ve performans ölçüm metriklerine Bölüm 3.8 ve alt başlıklarında yer verilmiştir.

3.4. Kümeleme

Denetimsiz öğrenme tekniği olan kümeleme, bir veri setindeki benzer veya farklı nesnelerin homojen alt gruplara ayrılması işlemini gerçekleştiren yöntemdir. Kümelemenin genel amacı örüntü tanıma ve doğal gruplamalardaki nesnelerin tespitidir. Dünya genelinde veri hacmindeki hızlı artışın yanı sıra video, resim, metin vb. veri türlerinin analizi ve kullanılabilirliği açısından kümeleme oldukça önemlidir (Oyelade ve ark., 2019). Bir veriyi alt gruplara ayırmanın yöntemlerinden biride kümelemedir. Kümeleme işlemlerinde en popüler olan uygulamalardan biride k ortalamalar (k means) algoritmasıdır. K ortalamalar algoritması klasik kümele prensibine dayalı olarak kümeleme işlemini gerçekleştirir. Bölüm 3.4.1’de k means algoritmasından bahsedilmiştir.

3.4.1. K ortalamalar algoritması

En yaygın kümeleme algoritmalarından biri olan k ortalamalar ilk olarak MacQueen (1965) tarafından önerilmiştir. K ortalamalar gözetimsiz öğrenme yöntemidir ve atama işlevi her verinin sadece bir kümeye üye olmasına izin verir. Üyelik işlevinde keskin bir

ayrım olduğundan dolayı keskin kümelemeye dayalı bir algoritmadır (Işık ve Çamurcu, 2007).

Bu algoritma veri setini k adet gruba ayırır böylece bu kümeler k ayrık kümesini temsil eder. İki farklı aşamadan oluşur. İlk aşama da k adet kümenin ağırlık merkezleri hesaplanır ikinci aşamada ise her noktayı ilgili veri noktasına en yakın ağırlık merkezinin bulunduğu kümeye götürür. En yakın kümenin ağır merkezinin hesaplanması uzaklık metrikleri ile gerçekleştirilir ve en sık tercih edilen Öklid uzaklığıdır. Gruplama işlemi gerçekleştirildikten sonra yeni ağırlık merkezi yeniden hesaplanır. Ağırlık merkezine dayalı olarak küme merkezi ve veri noktası arasındaki Öklid mesafesi hesaplanır ve minimum Öklid mesafesine sahip noktaları atar. Bölümdeki her küme üye nesneleri ve ağırlık merkezi tarafından tanımlanır. Her kümenin ağırlık merkezi, o kümedeki tüm nesnelerden uzaklıkların toplamının minimuma indirildiği noktadır. Bu nedenle k ortalamalar tüm kümeler üzerinde her nesneden küme merkezine olan mesafelerin toplamını en aza indirildiği yinelemeli bir algoritmadır (Dhanachandra ve ark., 2015).

3.4.2. Uzaklık metrikleri

Kümeleme analizinde en önemli işlemlerden biri veri noktaları arasındaki benzerliğin diğer bir deyişle uzaklığın ölçülmesidir. Bunun için uzaklık metriklerinden faydalanılır (Atal, 2015). Literatürde sıklıkla kullanılan uzaklık metrikleri Eş. 3.1, 3.2, 3.3 ve 3.4 verilmiştir.

Öklid uzaklık metriği:

$$d(X, Y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.1)$$

Manhattan uzaklık metriği:

$$d(X, Y) = \sum_{i=1}^k |x_i - y_i| \quad (3.2)$$

Minkowski uzaklık metriği:

$$d(X, Y) = \left(\sum_{i=1}^k (|x_i - y_i|)^p \right)^{\frac{1}{p}} \quad (3.3)$$

Canberra uzaklık metriği:

$$d(X, Y) = \sum_{i=1}^k \frac{|x_i - y_i|}{(x_i + y_i)} \quad (3.4)$$

3.5. Bulanık Küme Teorisi

Bulanık küme, literatürdeki adıyla Fuzzy Sets (FS), teorisi ilk olarak Zadeh (Zadeh 1965) tarafından tanımlanmıştır. Bulanık küme teorisinde bir küme her nesneye $[0,1]$ aralığında değişen üyelik derecesi atayan bir üyelik fonksiyonu ile karakterize edilir. Üyelik derecesi sadece 0 veya 1 ile ifade edilen klasik kümelerin aksine Bulanık kümelerde üyelik derecesi $[0,1]$ kapalı aralığında değerlenen ve sıklıkla sürekli olarak seçilen bir dönüşümün karakterize ettiği bir kümedir. Bulanık küme kavramı özellikle örüntü tanıma ve bilgi işlem alanlarında çok geniş bir uygulanabilirliğe sahip olduğu kanıtlanmıştır (Alata ve ark., 2013; Pham ve Prince, 1999; Valsalan ve ark., 2020). Bulanık kümeler, esas olarak belirsizlik problemlerinde yani keskin bir şekilde tanımlanmış küme üyeliği kriterlerinin olmadığı problemlerin çözümünde kolaylık sağlar (Zadeh, 1965). Tanım 3.2.1 'de bulanık kümenin tanımı yapılmıştır.

Tanım 3.2.1: Boş olmayan bir X kümesi üzerinde A bulanık kümesi, $\mu_A: X \rightarrow I = [0,1]$ olmak üzere, $A = \{(x, \mu_A(x)); x \in X\}$ olarak tanımlanır. Burada μ_A , A bulanık kümesinin üyelik fonksiyonudur ve $\mu_A(x) \in [0,1]$ değeri de her bir $x \in X$ için x 'in A fuzzy kümesine ait olma derecesini gösterir.

Tanım 3.2.1'den her klasik kümesi Eş. 3.5' de tanımlı karakteristik fonksiyonu ile bir fuzzy kümesi ifade edilebileceği anlaşılır.

$$\chi_A(x) = \begin{cases} 1 & x \in A \\ 0 & x \notin A \end{cases} \quad (3.5)$$

FS^X ile X kümesi üzerinde tanımlı tüm bulanık kümelerin ailesi gösterilmektedir (Kutlu 2016) .

Tanım 3.2.2: Boş olmayan bir x kümesi üzerinde A ve B bulanık kümeleri $A = \{(x, \mu_A(x)); x \in X\}$ ve $B = \{(x, \mu_B(x)); x \in X\}$ ile verilmiş olsun. Bulanık kümeler uzayında temel küme işlemleri aşağıdaki şekilde ifade edilir.

1. $A = B \Leftrightarrow \forall x \in X \text{ için } \mu_A(x) = \mu_B(x)$,
2. $A \subseteq B \Leftrightarrow \forall x \in X \text{ için } \mu_A(x) \leq \mu_B(x)$,
3. $\bar{A} = \{(x, 1 - \mu_A(x)); x \in X\}$, $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$
4. $A \cup B = \{(x, \mu_{A \cup B}(x)); x \in X\} = \{(x, \max\{\mu_A(x), \mu_B(x)\}); x \in X\}$
5. $A \cap B = \{(x, \mu_{A \cap B}(x)); x \in X\} = \{(x, \min\{\mu_A(x), \mu_B(x)\}); x \in X\}$

Bu tanımlamalar ile birlikte bulanık kümeler uzayında aşağıdaki temel küme özelliklerinin sağlandığı açıktır.

- a. $\bar{\bar{A}} = A$
- b. $A \cup B = B \cup A$
- c. $A \cap B = B \cap A$
- d. $(A \cup B) \cup C = A \cup (B \cup C)$
- e. $(A \cap B) \cap C = A \cap (B \cap C)$
- f. $A \cup A = A$
- g. $A \cap A = A$
- h. $A \cup (A \cap B) = A$
- i. $A \cap (A \cup B) = A$
- j. $A \cup \bar{1} = \bar{1}$
- k. $A \cap \bar{1} = A$
- l. $A \cup \bar{0} = A$
- m. $A \cap \bar{0} = \bar{0}$
- n. $\overline{(A \cup B)} = \bar{A} \cap \bar{B}$
- o. $\overline{(A \cap B)} = \bar{A} \cup \bar{B}$

(Zadeh, 1965).

3.5.1. Bulanık c ortalamalar algoritması (FCM)

FCM algoritması Dunn ve Bezdek (1973, 1981) tarafından geliştirilmiştir. Yaygın olarak örüntü tanıma ve görüntü bölütlenmesinde sıkça kullanılan popüler bir algoritmadır. FCM bulanık kümeleme prensibini esas aldığından dolayı veri noktalarının birden fazla kümeye atanmasına izin verir bu nedenle veri noktalarının her bir kümeye ait olma düzeyi vardır (Dewangan ve Ambhaikar, 2012). FCM algoritması çeşitli istatistiksel veri analizi problemlerinde kullanır. Nümerik bir veri seti için bulanık bölümler ve prototipler üretir. Bu bölümler bilinen alt yapıların doğruluğunu ölçmek ve henüz çalışılmamış verilerde alt yapı önermek için kullanışlı olduğuna değinmişlerdir. FCM algoritmasının amaç fonksiyonunda genelleştirilmiş en küçük kareler yöntemi kullanılır. FCM üç temel uzaklık metriğini (Öklid, Köşegen ve Mahalonobis), esas alarak gürültüye karşı hassasiyeti kontrol eden ayarlanabilir ağırlık faktörü, değişken sayıda kümenin kabulü ve küme geçerliliğini içeren çeşitli ölçütleri içerir (Bezdek ve ark., 1984).

N tane veriden oluşan $\{x_1, x_2 \dots x_n\}$ veri seti, $1 < c < N$ olmak üzere FCM kümeleme algoritmasını kullanarak c tane alt kümeye bölünsün. FCM kümeleme algoritmasının sonucu olarak küme merkezleri $\{v_1, v_2 \dots v_c\}$ olurken bölüm matrisi $U = [u_{ik}]$, $i = 1, 2 \dots c$ ve $k = 1, 2 \dots N$ elde edilir. Bunlara ek olarak bölüm matrisinin $u_{ik} \in [0,1]$, $\sum_{i=1}^c u_{ij} = 1$ ve $0 < \sum_{k=1}^N u_{ik} < N$ koşullarını sağlaması gerekir. FCM algoritmasının amaç fonksiyonu Eş. 3.6 'da gösterilmiştir.

$$J_m = \sum_{k=1}^N \sum_{i=1}^c u_{ik}^m \|x_k - v_i\|^2 \quad (3.6)$$

Amaç fonksiyonundaki $\|x_k - v_i\|$ sembolü x_k ve v_i arasındaki uzaklığı ve m ($m > 1$) bulanıklaştırma kat sayısını belirtir. Genellikle m parametresi 2 olarak seçilmektedir. Bulanıklaştırma katsayısı üyelik fonksiyonunun biçimine ve kümeler arasındaki örtüşmesine etki eder. Yüksek m parametreleri dalgalanma ve keskin üyelik fonksiyonları oluşmasına neden olur. Bulanıklaştırıcı değerinin doğru belirlenmesi bulanık modellerin sonuçları üzerinde oldukça etkilidir

Veri noktası olan x_k ile küme merkezi v_i arasındaki Öklid uzaklığı Eş. 3.7 de gösterilmiştir.

$$\|x_k - v_i\|^2 = \sum_{j=1}^n (x_{kj} - v_{ij})^2 \quad (3.7)$$

Eş. 3.6 'da verilen amaç fonksiyonun minimizasyonu Çizelge 3.2'de verilen iteratif bir algoritma ile elde edilebilmektedir. Bu amaç fonksiyonunun Lagrange çarpanları bulunarak küme merkezleri (Eş. 3.8) ve bölüm matrisleri (Eş. 3.9) aşağıdaki şekilde güncellenir.

Küme merkezlerinin güncellenmesi:

$$v_i = \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}^m} \quad (3.8)$$

Bölüm matrisinin güncellenmesi:

$$u_{ik} = \frac{1}{\sum_{h=1}^c \left(\frac{\|x_k - v_i\|}{\|x_k - v_h\|} \right)^{\frac{2}{m-1}}} \quad (3.9)$$

(Baykasoğlu ve ark., 2019)

Eş. 3.8 ve Eş. 3.9, belirtilen küme merkezleri (v) ve bölüm matrisleri (u) durdurma kriteri olan epsilon değerine (ϵ) ulaşana kadar amaç fonksiyonu (J_m) minimize edilir. Durdurma kriteri sağlandığında yineleme durdurulur.

Çizelge 3.2. FCM algoritmasının sözde kodu (Baykasoğlu ve ark., 2019).

Fuzzy C Means Algoritmasının Sözde Kodu

```

1:  Hiper parametrelerin tanımlanması (c,  $\varepsilon$ , m, maksimum_iterasyon)
2:  İlk bölüm matrisinin rastgele oluşturulması
3:  iterasyon=1
4:  while iterasyon<maksimum_iterasyon do
5:      Küme merkezlerini güncellene (Eş. 3.8)
6:      Bölüm matrisini güncelle (Eş. 3.9)
7:      Amaç fonksiyonunu ( $J_m$ ) hesapla (Eş. 3.6)
8:      if  $\|V^{yeni} - V^{eski}\| \leq \varepsilon$  or  $\|U^{yeni} - U^{eski}\| \leq \varepsilon$  then
9:          break
10:     else
11:         iterasyon= iterasyon+1
12:     end if
13: end while

```

3.6. Sezgisel Bulanık Küme Teorisi

Sezgisel bulanık küme, literatürdeki adıyla intuitionistic fuzzy sets (IFS) kavramı, bulanık küme teorisinin genişletilmiş halidir (Atanassov, 1986). Bu kavramda, bir veri noktasının bir kümeye üyelik derecesi ile beraber üye olmama derecesini tanımlamaktadır. Üye olma ve üye olmama derecelerinin toplamı 1'den küçük veya eşit olması gerekir. Bu iki derecelendirmeye ek olarak belirsizlik adı verilen üçüncü bir değer daha elde edilir. Üye olma, üye olmama ve belirsizlik değerleriyle beraber sezgisel bulanık küme teorisinin bipolar durumların (siyah-beyaz, olumlu-olumsuz, vb.) ve kesin olmayan problemlerin ele alınmasında yeterince etkili bir yöntem olduğu literatürdeki artan uygulamalarla kanıtlanmaktadır (Kutlu, 2016). Sezgisel bulanık kümenin formal tanımı Tanım 3.3.1 'de verilmiştir.

Tanım 3.3.1: Boş olmayan bir X kümesi üzerinde A sezgisel bulanık kümesi, $\forall x \in X$ için $0 \leq \mu_A(x) + \eta_A(x) \leq 1$ şartını sağlayan $\mu_A: X \rightarrow I, \eta_A: X \rightarrow I$ fonksiyonları olmak üzere $A = \{(x, \mu_A(x), \eta_A(x)): x \in X\}$ kümesidir. Burada her $x \in X$ için $\mu_A(x) \in [0,1]$ değeri x 'in A 'ya üye olma ve $\eta_A(x) \in [0,1]$ değeri x 'in A 'ya üye olmama derecelerini gösterir. Her $B = \{(x, \mu_B(x)): x \in X\}$ bulanık kümesinden, üye olmama derecesi $\eta_B(x) := 1 - \mu_B(x)$ olarak tanımlanarak bir sezgisel bulanık küme elde edilebilir (Atanassov, 1986).

A sezgisel bulanık kümesinde her $x \in X$ için x 'in sezgisel bulanık indeksi $\pi_A(x) := 1 - \mu_A(x) - \eta_A(x)$ ile elde edilir. $\pi_A(x)$ belirsizlik diğer bir deyişle tereddüt derecesi olarak adlandırılır (Atanassov, 1986). Sezgisel bulanık kümeler üzerinde temel küme işlemleri Atanassov tarafından Tanım 3.3.2 'deki gibi tanımlanmıştır.

Tanım 3.3.2: A ve B , X üzerinde birer sezgisel bulanık küme olmak üzere;

1. $A \subset B \Leftrightarrow \forall x \in X$ için $\mu_A(x) \leq \mu_B(x)$ ve $\eta_A(x) \geq \eta_B(x)$
 2. $A = B \Leftrightarrow A \subset B$ ve $B \subset A$
 3. $\bar{A} = \{(x, \eta_A(x), \mu_A(x)): x \in X\}$
 4. $A \cap B = \{(x, \min\{\mu_A(x), \mu_B(x)\}, \max\{\eta_A(x), \eta_B(x)\}): x \in X\}$
 5. $A \cup B = \{(x, \max\{\mu_A(x), \mu_B(x)\}, \min\{\eta_A(x), \eta_B(x)\}): x \in X\}$
 6. $A + B = \{(x, \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x), \eta_A(x) \cdot \eta_B(x)): x \in X\}$
 7. $A \cdot B = \{(x, \mu_A(x) \cdot \mu_B(x), \eta_A(x) + \eta_B(x) - \eta_A(x) \cdot \eta_B(x)): x \in X\}$
- (Atanassov, 2012).

3.6.1. Sezgisel bulanık c ortalamalar algoritması (IFCM)

IFS teorisini kullanan birçok algoritma farklı yaklaşımlarla tanımlanmıştır. Bu tanımlamalardan biri de Chaira (2011) tarafından gerçekleştirilmiştir. IFCM algoritması, üyelik fonksiyonunu tanımlanırken ortaya çıkan tereddüt derecesini de dikkate alır. Böylece geleneksel FCM algoritmasını kullanarak küme merkezlerinin istenilen bir konuma daha iyi biçimde yakınsamasını sağlar. IFCM algoritmasında geleneksel FCM algoritmasına intuitionistic fuzzy entropi (IFE) adı verilen bir ekleme yapılarak yeni bir amaç fonksiyonu tanımlanmıştır. Bu tanımlama veri noktalarının yararlılıklarını en üst

düzeye çıkarmak için önemlidir. IFE belirsizliğin bir ölçüsüdür. $IFE: IFS^X \rightarrow \{0\} \cup \mathbb{R}^+$ fonksiyonu eğer aşağıdaki şartları sağlıyorsa bir intuitionistic fuzzy entropi adını alır:

1. $\forall A \in IFS^X$ için $IFE(A) = 0$,
2. $IFE(A) = cardinal(X)$ ancak ve ancak $\forall x \in X$ için $\mu_A(x) = \eta_A(x) = 0$ 'dır,
3. Her bir elemanın üye olma ve olmama derecesi azalırsa, toplamaları azalacak ve bir küme içindeki belirsizlikler azalacak, dolayısıyla tereddüt derecesi artacak ve böylece IFE artacaktır. Yani $A \Leftarrow B$ ise $\mu_A(x) \leq \mu_B(x)$ ve $\eta_A(x) \leq \eta_B(x)$ buradan $\mu_A(x) + \eta_A(x) \leq \mu_B(x) + \eta_B(x)$ eşitsizliği elde edilir. Böylece $\pi_A(x) \geq \pi_B(x)$ olduğu sonucuna ulaşılır (Chaira, 2011).

$X = \{x_1, x_2, \dots, x_n\}$ için sırasıyla $\mu_A(x_i)$, $\eta_A(x_i)$ ve $\pi_A(x_i)$, x_i 'nin A sezgisel bulanık kümesine üye olma, üye olmama ve belirsizlik derecelerini göstermek üzere sezgisel bulanık entropi Eş. 3.10 'da tanımlanmıştır (Chaira, 2011).

$$IFE(A) = \sum_{i=1}^n \pi_A(x_i) e^{[1-\pi_A(x_i)]} \quad (3.10)$$

Burada $\pi_A(x_i) = 1 - (\mu_A(x_i) + \eta_A(x_i))$ ile tanımlıdır. Sürekli ve azalan (artan) bir $\varphi: [0,1] \rightarrow [0,1]$ fonksiyonu aşağıdaki şartları sağlarsa sürekli ve azalan (artan) bir intuitionistic fuzzy üreteç (generator) adını alır (Chaira, 2011).

1. Tüm $x \in [0,1]$ için $\varphi(x) \leq (1 - x)$

$\varphi(0) \leq 1$ ve $\varphi(1) \leq 0$ IFCM algoritması Yager üreteç fonksiyonu kullanılarak oluşturulmuştur. $g: [0,1] \rightarrow [0,1]$ artan fonksiyon olmak üzere:

$$N(\mu(x)) = g^{-1}(g(1) - g(\mu(x))) \quad (3.11)$$

Eğer $\alpha > 0$ için $g(x) = x^\alpha$ alınırsa

$$N(x) = (1 - x^\alpha)^{\frac{1}{\alpha}} \quad (3.12)$$

Burada $A_{\lambda}^{IFS} = \{(x, \mu_A(x), (1 - \mu_A(x)^\alpha)^{\frac{1}{\alpha}}) : \forall x \in X\}$ ve böylece $\pi_A(x_i) = 1 - (\mu_A(x) + (1 - \mu_A(x)^\alpha)^{\frac{1}{\alpha}})$ olur.

IFCM algoritmasında minimize edilecek ölçüt fonksiyonu iki terim içerir:

1. IFS kullanılarak geleneksel FCM'nin değiştirilmiş amaç fonksiyonu
2. Intuitionistic fuzzy entropi (IFE).

Geleneksel FCM algoritması, Eş. 3.13 'de belirtilen amaç fonksiyonunun yerel minimumlarını arayarak özellik vektörlerini kümelendirme anlamına gelir:

$$J_m(U, v; X) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d^2(x_k, v_i) \quad (3.13)$$

Eş. 3.13' deki $d(x_k, v_i)$ her bölgenin v_i (küme merkezi) ile x_k (modeldeki noktalar) arasındaki Öklid uzaklık (veya herhangi bir uzaklık) ölçüsüdür. Burada u_{ik} , i. kümedeki k 'inci x_k verisinin üye olma derecesi, c küme sayısı, n veri noktalarının sayısıdır. J_m 'nin küçültülmesi, aşağıdaki eşitlik aracılığıyla yinelemeli bir işlem kullanılarak uygun U (üyelik matrisi) ve v seçimine dayanır (Chaira, 2011). Üyelik matrisi, Eş. 3.14 ile verilmiştir.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}}} \quad (3.14)$$

Sezgisel bulanık özelliği geleneksel bulanık kümeleme algoritmasına dâhil etmek için, küme merkezleri aşağıdaki şekilde güncellenir. Tereddüt derecesi başlangıçta kullanılarak hesaplanır ve sezgisel bulanık üyelik değerleri Eş. 3.15 ile elde edilir.

$$u_{ik}^* = u_{ik} + \pi_{ik} \quad (3.15)$$

Eş. 3.15 'deki u_{ik}^* , i'inci sınıftaki k'inci verinin sezgisel bulanık kümeye üyeliğini gösterir (Chaira, 2011).

$$v_i^* = \frac{\sum_{k=1}^n u_{ik}^* x_k}{\sum_{k=1}^n u_{ik}^*} \quad (3.16)$$

Her yinelemede, küme merkezi ve üyelik matrisi güncellenir. Güncellenen üyelik matrisi ve önceki üyelik matrisi arasındaki fark $\max_{i,k} |U_{i,k}^{*new} - U_{i,k}^{*prev}| < \varepsilon$ olduğunda durdurma kriteri aracılığıyla algoritma durmuş olur.

$$J_2 = \sum_{i=1}^c \pi_i^* e^{1-\pi_i^*} \quad (3.17)$$

Eş. 3.17 'deki $\pi_i^* = \frac{1}{N} \sum_{k=1}^n \pi_{ik}$ ile tanımlıdır. Amaç, bir görüntünün histogramının entropisini en aza indirmektir. Her kümedeki tüm elementlerin tereddüt değerleri eklenir ve ardından her bir sınıfın entropisi hesaplanır. Kümede bulunan belirsizliği veya belirsizlik miktarını söyler. Böylece, iki terim içeren son ölçüt fonksiyonu aşağıdaki şekilde tanımlanır:

$$J = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d^2(x_k, v_i) + \sum_{i=1}^c \pi_i^* e^{1-\pi_i^*} \quad (3.18)$$

(Chaira, 2011).

3.7. Kümeleme Geçerlilik İndeksleri

Kümeleme işlemlerindeki en önemli aşamalardan biri de optimal küme sayısının yani en uygun c parametresinin belirlenmesidir. Literatürde küme sayısının belirlenmesiyle alakalı birçok küme geçerlilik indeksleri mevcuttur (Bezdek, 1973; 1975; Fukuyama ve Sugeno, 1989; Gunderson, 1978; Windham, 1981; 1982; Xie ve Beni, 1991). Bazı küme geçerlilik indeksleri üyelik değerleriyle bazıları ise üyelik değeri, veri kümesi ve küme merkezi değerleriyle hesaplama yapar.

Çizelge 3.3'de bazı önemli küme geçerlilik indekslerine yer verilmiştir. Bölünme kay sayısı (partition coefficient (V_{PC})) (Pal ve Bezdek, 1995) ve modifiye edilmiş bölünme katsayısı (modified partition coefficient (V_{MPC})) (Dave, 1996) küme geçerlilik


indeksleri maksimum ile Xie-Beni (V_{XB}) (Xie ve Beni, 1991) küme geçerlilik indeksi ise minimum olan değer ile küme sayısı (c) belirlenir.

Çizelge 3.3. Küme geçerlilik indeksleri.

Küme Geçerlilik İndeksi	Eşitlikler	Uygun Küme sayısının elde edilmesi
V_{PC}	$V_{PC}(U) = \frac{1}{n} \sum_{i=1}^c \sum_{j=1}^n u_{ik}^2$	$Max\{V_{PC}(U, c_i, m)\}$
V_{MPC}	$V_{MPC}(U) = 1 - \frac{c}{c-1} (1 - V_{PC})$	$Max\{V_{MPC}(U, c_i, m)\}$
V_{XB}	$V_{XB}(U; V; X) = \frac{\sum_{c=1}^c \sum_{i=1}^n u_{ci}^2 \ x_i - v_c\ ^2}{n(\min_{k,l} \ x_k - v_l\ ^2)}$	$Min\{V_{XB}(U, c_i, m)\}$

3.8. Derin Öğrenme


Derin öğrenme, birçok işlem katmanından oluşan hesaplama modelinin veri setini birden çok soyutlama biçimiyle öğrenimini sağlayan bir makine öğrenmesi türüdür. Bu yöntem örüntü tanıma, nesne algılama, ses tanıma ve ilaç keşfi gibi birçok alanda tercih edilmiştir. Hesaplama modeli içindeki parametrelerin güncellenmesi için geri yayılım algoritmasını kullanır. Böylece büyük veri kümesindeki karmaşık yapı keşfedilmiş olur. Derin öğrenme, zor problemlerin çözümünde büyük ilerleme kaydetmiştir. Bunlardan bazıları ilaç moleküllerinin aktivitesini tahmin etmede, parçacık hızlandırma verilerinin analizinde, beyin iletişim sistemini yeniden yapılandırmada, DNA'daki mutasyonların gen ekspresyonu ve hastalık üzerindeki problemleri tespit etmede yüksek başarılı sonuçlara ulaşarak geleneksel makine öğrenmesi tekniklerini geride bırakmıştır (Lecun ve ark., 2015). Derin öğrenme makine öğrenmesinin, makine öğrenmesi ise yapay zekanın bir alt dalıdır. Yapay zekanın çalışma alanı Şekil 3.7 'de gösterilmiştir.



Şekil 3.7.Yapay zekanın çalışma alanları.

3.8.1. Evrişimsel sinir ağı (convolutional neural networks - CNN)

Evrişimsel sinir ağı (ESA), mimariye göre değişmekle beraber kendi içinde giriş katmanı, evrişim katmanı, havuzlama katmanı, aktivasyon katmanı, tam bağlı katman, çıkış katmanı gibi çeşitli katmanlar barındıran bir yapay sinir ağıdır. İlk ESA modeli Fukushima (1988) tarafından tanımlanan aynı zamanda hiyerarşik bir sinir ağı olan Neocognitron adındaki pörseptrondur. ESA bu dönemlerde donanımsal yetersizlikten dolayı pek uygulanamamıştır. 1990 yılında LeCun vd. gradyan tabanlı bir derin öğrenme modeli önererek el yazısı ve rakam sınıflandırma probleminde başarılı sonuçlar elde etmiştir. ESA katmanındaki girdi nöronları aktivasyon fonksiyonunun çıktısına dönüşür ve nihai sonuç elde edilmiş olur. Her bir çıkış nöronu diğer bir katmanın girdisini temsil eder (Başaran, 2020; Chandra ve ark., 2020). Şekil 3.8 ‘de ESA modelinin genel mimarisini göstermektedir.



Şekil 3.8. ESA mimarisinde bulunan katmanlar (Albelwi ve Mahmood, 2017).

ESA'ların, geleneksel makine öğrenmesi algoritmasının sınıflandırıcılarından daha iyi bir sonuç göstermesinin nedenlerinden birisi de öznetelik çıkarımı ve örnekleme katmanlarına sahip olmasıdır (Tümen, 2019).

3.8.1.1. Giriş katmanı (input layer)

Giriş katmanı, ESA modeline verilen ilk ham giriş verisidir. Bu katmandaki veri boyutunun büyüklüğü hesaplama maliyetinin artmasına neden olmakla birlikte veri boyutunun büyüklüğü ayrıntılı bilginin elde edilmesini sağlar. Veri boyutunun küçüklüğü ise hesaplama maliyetini azaltır (Başaran, 2020).


3.8.1.2. Evrişim katmanı (convolution layer)

Evrişimsel sinir ağındaki çekirdek (kernel) olarak bilinen evrişim katmanı, filtre ve özellik haritalarından oluşmaktadır. Filtreler ESA modelindeki nöronları temsil eder ve rastgele üretilen sayılarla ağırlıkların güncellenmesini sağlar. Görüntü matrisi üzerinde soldan sağa veya yukarıdan aşağıya doğru filtrenin uygulanması ile elde edilir. Görüntü matrisinin tüm bölgesi tarama boyunca çarpma işlemi uygulanır. Uygulanan filtrenin temel amacı öznetelik çıkarımıdır. Uygulanan filtre sayısı imge derinliği ile doğru orantılıdır. ESA modelindeki ilk evrişim katmanı genellikle kenar bilgileri gibi basit özneteliklerin elde edilmesini sağlar. Model boyunca uygulanan diğer evrişim katmanları

önemli özneliliklerin tespit edilmesini sağlar. Eş. 3.19’ da evrişim katmanının matematiksel ifadesini göstermektedir (Başaran, 2020; Tümen, 2019).

$$(f * h)[m, n] = \sum_j \sum_k h[j, k], f(m - j, n - k) \quad (3.19)$$

Burada f ham giriş verisi ve h çekirdek (kernel) olmak üzere, çıkış matrisinin satır indisi m , sütun sayısı n ile gösterilmektedir. Evrişim işleminden sonra elde edilen yeni matrisin satır ve sütun sayısı sırasıyla j ve k ‘dır (Başaran, 2020). Giriş katmanındaki verinin sayısal değerleri evrişim katmanında filtreler aracılığıyla rastgele üretilmiş $[0,1]$ aralığına sahip matrisin elemanları ile çarpılır ve tüm değerlerin toplamı çapraz korelasyon yöntemi ile çıkış matrisine verilir (Tümen, 2019). Evrişim işleminin aşamaları Şekil 3.9 ‘da gösterilmiştir.



Şekil 3.9. Evrişim aşamaları.


Şekil 3.9’ a göre çıkış matrisindeki 5 sayısı $(f * h)(1,1) = (1 * 1) + (1 * 1) + (1 * 1) + (1 * 0) + (0 * 1) + (0 * 0) + (1 * 1) + (0 * 1) + (1 * 1) = 5$ işlemi ile evrişim gerçekleşmiş olur. Bu işlemden sonra aktivasyon haritası oluşur. Elde edilen aktivasyon haritası giriş verisinin boyutu, çekirdeğin (kernel) boyutu, adım sayısı (stride) ve dolgu (padding) parametrelerine bağlı olarak değişir. Çıkış matrisi adım sayısı arttıkça küçülür. Bu küçülmeyi önlemek için girdi verisine dolgu yöntemi uygulanır. Dolgu değeri genellikle 0 değeri ile tanımlıdır. Çıkış boyutu Eş. 3.20 ile elde edilir.

$$\text{Çıkış Boyutu} = \frac{a - b + 2p}{2s} + 1 \quad (3.20)$$

Burada $a \times a$ boyutlu bir giriş verisi, $b \times b$ filtre boyutu, s adım kaydırma sayısı ve p dolgu değeridir (Başaran, 2020).

3.8.1.3. Havuzlama katmanı (pooling layer)

Havuzlama katmanı, evrişim işleminden sonra elde edilen özellik haritalarının boyutunu azaltmak için başvurulan bir tekniktir. Genellikle evrişim katmanından sonra kullanılır. Bu katmanda *Maksimum havuzlama* ve *Ortalama havuzlama* teknikleri yer alır. Evrişim işleminden sonra orta çıkan çok sayıda gereksiz parametrenin fazlalığı hesaplama maliyetinin artmasına ve yapay sinir ağının ezberlenmesine neden olabilmektedir. Bu problemleri önlemek için havuzlama katmanları kullanılır. Evrişim işleminden sonra elde edilen matristeki fazla sayıda parametreye havuzlama işlemi uygulanarak özetleme işlemi yapılmış olur. Bu nedenle havuzlama katmanı alt-örnekleme olarak da adlandırılır. Bu katmanda filtre ve adım sayısı (stride) kullanılarak ortalama ve maksimum gibi istatistiksel değerler hesaplanmaktadır. Havuzlama katmanının işlem aşaması Şekil 3.10.'daki gibidir (Başaran, 2020; Cömert, 2019; Tümen, 2019).




Şekil 3.10. Havuzlama katmanı işlem aşamaları (Tümen, 2019).

3.8.1.4. Tam bağı katman (fully connected layer)

Genellikle havuzlama ve çıkış katmanı arasında bulunan tam bağı katman, kendinden önce gelen evrişim katmanındaki çok boyutlu nöronları vektör haline getirir. Çok boyutlu nöronun $5 \times 5 \times 30$ boyutunda bir tensör olduğu düşünülürse, bu katman sayesinde $5 \times 5 \times 30 = 750$ uzunluğunda bir özellik vektörü haline gelir. Bu katmanın temel amacı özellik vektörünü kullanarak çıkış katmanında sınıflandırma işleminin yapılmasını sağlamaktır (Başaran, 2020).

3.8.1.5. Seyreltme katmanı (dropout)

Aşırı öğrenme evrişimli sinir ağları modellerinde en sık karşılaşılan problemlerden biridir. Bu problemi çözmenin yollarından biride seyreltme katmanını kullanmaktır. Seyreltme katmanının temel amacı eğitim sırasında ağdaki düğümleri seyrelterek aşırı uyumu önlemektir. Bu katman aşırı uyumu önleyerek ses tanıma, nesne tanıma, belge sınıflandırma gibi uygulamalarda başarılı sonuçlara ulaşıldığı kanıtlanmıştır (Srivastava ve ark., 2014). Şekil 3.11'de seyreltme katmanının etkisini göstermektedir.



Şekil 3.11. (a) Standart YSA, (b) seyreltme sonrası YSA (Srivastava ve ark., 2014).

3.8.1.6. Softmax katmanı

Lojistik regresyon tekniğinin genişletilmiş hali olan softmax, olasılık tabanlı sınıflandırıcıdır. Bu sınıflandırıcı iki veya daha fazla veri setine sahip problemlerde kullanılır. Sınıflandırıcı olması sebebiyle genellikle son katmanda yani çıkış katmanında kullanılır. Sınıflandırma yaparken olasılıksal olarak $[0,1]$ aralığında bir çıktı üretir. Eş. 3.21 softmax katmanın çıkış parametresini elde etmek için kullanılan matematiksel ifadesidir.

$$y_r(x) = \frac{\exp(a_r(x))}{\sum_{j=1}^k \exp(a_j(x))} ; 0 \leq y_r \leq 1, \sum_{j=1}^k y_j = 1 \quad (3.21)$$

Burada çıkış parametresinin sınıf değerlerinin toplamına bölünmesi ile elde edilen $y_r(x)$ değerinin matematiksel hesaplanması görülmektedir (Başaran, 2020; Tümen, 2019).

3.8.1.7. Evrişim bloklü dikkat modülü katmanı


Evrişim bloklü dikkat modülü (Convolution Block Attention Module (CBAM)), ileri beslemeli evrişimli ağ modülüdür. CBAM ilk olarak Woo ve ark. (Woo ve ark., 2018) tarafından sunulmuştur. CBAM katmanında, imgelerden elde edilen özellikler iki modül altında incelenir. Bunlar CBAM katmanın içerisinde yer alan kanal dikkat ve uzamsal dikkat modülleridir.

Kanal Dikkat Modülü (Channel Attention Module): İmgelerden elde edilen aktivasyon haritalarının kanallarını temsil eder. Bu modül özellik haritalarında evrişimli sinir ağını önemli noktalara yönlendirmek için oldukça kullanışlıdır. Verilen girdide neyin önemli olduğuna odaklanır. Ayrıca imgelerden elde edilen özellik haritalarını sıkıştırarak modelin ideal bir şekilde kullanılmasına izin verir, ortalama ve havuzlama katmanları hakkında bilgi edinmek için uzamsal dikkat modülünden yararlanır. Kanal dikkat modülü öncelikli olarak özellik haritalarının konumsal bilgilerini ortalama ve havuzlama işlemlerini uygulayarak F_{avg}^c , F_{max}^c değerlerini elde eder. Bu değerler sırasıyla ortalama havuzlama ve maksimum havuzlama da toplanan özelliklerdir. Bu değerler gizli

katmana sahip olan MLP ($M_c \in \mathbb{R}^{c \times 1 \times 1}$) ağına iletilir. Burada c kanal sayısıdır ve kanal dikkat modülü Eş. 3.22 ‘deki gibi hesaplanır (Canayaz, 2021; Toğaçar ve ark., 2020).

$$M_c(F) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (3.22)$$

Burada σ sigmoid fonksiyon, W_0 ve W_1 ağırlık değerleri, MLP ağının çok katmanlı algılayıcılarıdır. Kanala dikkat modülünün yapısı Şekil 3.12’deki gibidir.




Şekil 3.12. Kanal dikkat modülü yapısı (Woo ve ark., 2018).

Uzamsal dikkat modülü (Spatial attention module): İmgelerden elde edilen özelliklerin uzamsal ilişkisini kullanarak uzamsal bir dikkat haritası oluşturur. Uzamsal dikkat modülü, kanal dikkat modülünden farklı olarak bilginin nerede olduğuna odaklanır. Uzamsal dikkat modülünü hesaplamak için kanal eksenini boyunca ortalama havuzlama ve maksimum havuzlama işlemlerini uygular ve verim bir özellik tanımlayıcısı için birleştirilir. İki boyutlu harita oluşturmak için $F_{avg}^s \in \mathbb{R}^{1 \times H \times W}$ ortalama havuzlama, $F_{max}^s \in \mathbb{R}^{1 \times H \times W}$ maksimum havuzlama katmanları kullanılır. Bu havuzlama katmanları daha sonra birleştirilerek uzamsal dikkat haritası oluşturmak için $M_c(F) \in \mathbb{R}^{H \times W}$ gibi bir evrişim katmanı uygulanır. Uzamsal dikkat modülü Eş. 3.23 ‘deki gibi hesaplanır. Uzamsal dikkat modülünün yapısı Şekil 3.13’deki gibidir (Woo ve ark., 2018).


$$M_c(F) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (3.23)$$

Burada σ sigmoid fonksiyon, $f^{7 \times 7}$ 7x7'lik evrişim sürecini gösterir.



Şekil 3.13. Uzamsal dikkat modülü yapısı (Woo ve ark., 2018).


Evrişimli sinir ağlarının yapısını geliştirmek için CBAM katmanları geliştirilmiştir. CBAM katmanı performansı iyileştirerek neyi nerede vurgulayacağını veya bastırılacağını öğrenir, ara özellikleri etkin bir şekilde iyileştirir. CBAM katmanının genel yapısı Şekil 3.14'de gösterildiği gibidir.



Şekil 3.14. CBAM katmanının genel yapısı (Woo ve ark., 2018).

3.8.1.8. Artık bloklar (residual blok)

Evrişimli sinir ağlarında katman sayılarının artması ağı karmaşıklığına neden olduğu gibi ağı eğitilmesini de zorlaştırmaktadır. Artık bloklar ağı eğitimi kolaylaştırmak için kullanılır. Artık bloklar ResNet mimarisinin önemli bir parçasıdır. Bir artık blok $f(x) + x$ olarak ifade edilir (Tian ve ark., 2019). Artık blok bulunan fazla katmanlı bir ağda diğer ağlara göre daha hızlı bir eğitim süreci gerçekleşir. Microsoft, ResNet-50 modeli kendisinden 8 kat daha derin katmana sahip olan 152 katmanlı bir evrişimli sinir ağından daha iyi bir performans gerçekleştirdiğini belirtmiştir (Ahsan Jeny ve ark., 2019). Şekil 3.15 artık blok yapısını göstermektedir.



Şekil 3.15. Artık öğrenmenin yapısı.

3.8.1.9. Hiper sütun tekniği

Hiper sütun tekniği, model boyunca çıkarılan her pikselin aktivasyon haritasının sırasını koruyarak bir diziye aktarır. Buradaki temel amaç katmanlardaki uzamsal konum bilgilerini elde etmek ve daha verimli bir özellik seçiminin yapılabilmesini sağlamaktır. Hiper sütun tekniği, model tarafından işlenen imgenin piksellerini dizi gibi bir yapıda tutar ve böylece modelin doğruluğu artmış olur. Bu teknik, 2D upsampling yani iki boyutlu üst örnekleme katmanını içerir. Üst örnekleme katmanı her bir pikselin etrafındaki komşu piksellerin değerlerini kullanarak yeni komşu piksellerin sayısı olarak ifade edilebilir (Toğaçar ve ark., 2020).


3.8.2. Evrimsel sinir ağı ile geliştirilen derin öğrenme mimarileri

Bu bölümde AlexNet, GoogleNet, ResNet ve VGG-16 derin öğrenme mimarilerine yer verilmiştir.

3.8.2.1. AlexNet

Alex Krizhevsky ve ark. (2017) tarafından geliştirilen derin öğrenme modeli ILSVRC-2010 adlı yarışma için ImageNet verisetini eğitilmesini ve sınıflandırılmasını

yapmak üzere geliştirilmiştir. Şekil 3.16’da görüldüğü üzere beş evrişim katmanı (conv1-conv5) ve üç tam bağlı katmandan (fc6-fc8) oluşur. Bu mimari giriş katmanında 227×227 boyutunda RGB bir imge alır. Aynı zamanda aşırı öğrenmeyi engellemek için ReLU aktivasyon fonksiyonunu kullanır (Başaran, 2020; Hemmer ve ark., 2018).




Şekil 3.16. AlexNet mimarisi (Hemmer ve ark., 2018).

3.8.2.2. GoogLeNet

GoogLeNet mimarisinde Inception adlı mimariyi içerir. Bu mimari, hesaplama maliyetinin düşük olması sebebiyle tercih edilmektedir. Giriş katmanında 224×224 boyutunda bir imge alır. Yirmi bir evrişim ve bir tam bağlı katmandan oluşur. GoogLeNet mimarisi 2014 yılında gerçekleştirilen ImageNet yarışmasını %5.7 hata ile kazanmıştır (Başaran, 2020).

3.8.2.3. VGG-16

ImageNet nesne tanıma yarışmasında en gelişmiş performansı elde etmiştir. Ayrıca yüz tanıma için oldukça etkili bir mimari olduğu kanıtlanmıştır. Şekil 3.17’de görüldüğü gibi mimaride on üç evrişim katmanı, üç tam bağlı katmandan ve bir softmax katmanından oluşur.



Şekil 3.17. VGG-16 mimarisi (Blauch ve ark., 2021).

Şekil 3.17’de conv1-con5 evrişim katmanları, fc6-fc8 tam bağlı katman, turuncu renkle gösterilen katman havuzlama ve çıkış bloğu olan softmax katmanıdır. Şekilde görüldüğü üzere iki veya üç evrişimden sonra havuzlama işlemi yapılmıştır (Blauch ve ark., 2021).

3.8.2.4. ResNet

He ve ark. (2015) tarafından geliştirilen evrişimli sinir ağı modellerinden biridir. Evrişimli sinir ağlarında eğitim uzun zaman alır ve sınırlı sayıda katmandan oluşur. Bu mimari, ağın eğitilmesi aşamasındaki ikilemleri ortadan kaldırmak ve hızlı bir eğitim sürecini gerçekleştirmek için oluşturulmuştur. ResNet modelinin diğer modellere göre en önemli avantajı mimari derinleşse de modelin performansında düşüş meydana gelmemesidir. Ağın hafifliği eğitim yeteneğinin daha iyi sonuçlar üretmesini sağlar. ResNet, ReLU aktivasyon fonksiyonu ve yığın normalleştirme katmanlarını içeren iki veya üç katmanı atlayarak uygulanır. Bunları artık bloklar ile yapar. Bu mimari, görüntü sınıflandırmada iyi bir performans göstermiştir (Sarwinda ve ark., 2021). Şekil 3.18 ResNet mimarisini göstermektedir.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2.x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Şekil 3.18. ResNet mimarisi (Sarwinda ve ark., 2021).


3.8.3. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, doğrusal ifadeleri doğrusal olmayan ifadelere dönüştürülmesini sağlar. ESA’da girdi değerleri ağırlık değerleri ile çarpıldıktan sonra elde edilen değer bias değeri ile toplanır ve aktivasyon fonksiyonuna verilerek bir çıktı üretilmesi sağlanır. Elde edilen çıktı değeri kendinden sonra gelen katmanın girdi değeri olabileceği gibi nihai çıktı değeri de olabilir. Softmax, sigmoid, ReLU ve hiperbolik tanjant en sık kullanılan aktivasyon fonksiyonlarına Aşağıdaki bölümlerde yer verilmiştir (Başaran, 2020).

3.8.3.1. Sigmoid

Türevlenebilir bir aktivasyon fonksiyonudur ve giriş değeri olarak $(-\infty, +\infty)$ arasında bir değer alır ve $(0,1)$ aralığında değer üretir. Eş. 3.24 ’de matematiksel ifadesi gösterilmiştir. Sigmoid aktivasyon fonksiyonunun grafiği Şekil 3.19’deki gibidir.

$$\sigma = \frac{1}{1 + e^{-x}} \quad (3.24)$$



Şekil 3.19. Sigmoid aktivasyon fonksiyonu (Başaran, 2020).

3.8.3.2. Softmax

Sınıflandırma problemlerinde sıkça kullanılan ve lojistik regresyonunun genişletilmiş hali olan iki veya fazla sınıfa sahip olasılıksal tabanlı bir aktivasyon fonksiyonu ve sınıflandırıcıdır. Olasılıksal olarak $[0,1]$ aralığında yorumlama yapar. K farklı olası durumun olasılıksal dağılımı Eş. 3.25 'deki gibi hesaplanır (Başaran, 2020).


$$\sigma = \frac{e_j^z}{\sum_{k=1}^K e_k^z}, \quad for \ j = 1 \dots K \quad (3.25)$$

3.8.3.3. ReLU

İlk olarak Bozaltman makinasında kullanılmıştır. Bu fonksiyonda girdi değeri negatif bir değer ise 0, değilse girdi değerini olduğu gibi verir. Yapay sinir ağındaki eğitimi hızlandırmak, hesaplama maliyetini azalmak ve aşırı öğrenmeyi engellemek için önerilen bir aktivasyon fonksiyonudur. Eş. 3.26'de matematiksel ifadesi gösterilmiştir (Başaran, 2020; Cömert ve Kocamaz, 2019).

$$f(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3.26)$$

Şekil 3.20 'de ReLU 'nun grafiğini ifade etmektedir.




Şekil 3.20. Rectified linear unit grafiği.

3.8.3.4. Hiperbolik tanjant (tanh)

Bu fonksiyon -1 ile 1 arasında değer üretir. Sigmoid fonksiyonuna çok benzerdir tek farkı orijine göre simetrik olmasıdır. Sınıflandırma performansını arttırmak için Tanh fonksiyonu kullanılabilir. Eş. 3.27 'de matematiksel ifadesi, Şekil 3.21 'de ise grafiği gösterilmiştir (Tümen, 2019).

$$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.27)$$



Şekil 3.21. Tanh aktivasyon fonksiyonu.

3.8.4. Hiper parametreler

İyi bir derin öğrenme modeli oluşturmak için optimizasyon algoritması ve hiper parametreler gibi bileşenlerin doğru seçilmesi gerekir. Bu bileşenler derin öğrenme

modelinin performansını doğrudan etkilemektedir. Bu parametreler deneme yanılma yolu ile belirlenebileceği gibi optimizasyon algoritmaları vasıtasıyla da optimum (en uygun) parametreler belirlenebilir (Kim ve Cho, 2019). Bu bölümde yığın boyutu (batch size), eğitim tur sayısı (epoch), öğrenme oranı (learning rate), momentum katsayısı (momentum) ve optimizasyon yönteminin seçilmesi gibi hiper parametrelere değinilmiştir.

Yığın Boyutu (Batch Size): Yapay sinir ağının eğitilmesi ve nöron ağırlıklarının hesaplanması maliyet ve kapasite bakımından performansı etkilemektedir. Bu hesaplama performansı veri sayısına göre azalmakta veya artmaktadır. Hesaplama performansını artırmak, belleği iyi bir şekilde kullanmak için veriler parçalar halinde alınmakta ve küçük gruplar halinde işlem yapılmaktadır. Bu yönteme mini-batch adı verilir. Eğitim sırasında her bir mini-batch üzerinde ileri besleme işlemi gerçekleştirilerek hata değerleri hesaplanır. Hesaplanan hata değerleri her bir mini-batch üzerinde geri yayılım yöntemi kullanılarak gradyan hesaplamalarıyla ağırlıklar güncellenir (Tümen, 2019).

Eğitim Tur Sayısı (Epoch): Derin öğrenme modellerinde eğitim aşamasında mini-batch'de tüm veri tek seferde eğitilmez bunun temel sebebi bellek yönetimidir. Belleği iyi bir şekilde yönetebilmek için veriler parça parça eğitilir. Her bir parçada eğitilen verinin ağırlıkları geri yayılım yöntemiyle güncellenir. Tüm parçaların bir sefer eğitilmesi işlemine eğitim tur sayısı (epoch) denir. Mini-batch üzerinde eğitilen her bir parçanın bir sefer eğitilmesi iterasyon olarak adlandırılır (Başaran, 2020; Tümen, 2019).

Öğrenme Oranı (Learning Rate): Yapay sinir ağlarında ağırlık parametrelerinin güncellenmesi geri yayılım yöntemiyle yapılmaktadır. Bu güncellenme işlemi ters türev alınarak farkın bulunması ve bu fark değerini öğrenme oranıyla çarparak elde edilir. Öğrenme oranı artan veya azalan olabilir. Genellikle 0.1 ile 0.000001 arasında sıfıra yakınsayan bir değer seçilir. Öğrenme oranının çok küçük seçilmesi eğitim süresinin uzamasına sebep olur (Tümen, 2019).

Optimizasyon Algoritmasının Seçilmesi: Derin öğrenme bir optimizasyon problemi olarak tanımlanabilir. Optimizasyon algoritmaları doğrusal olmayan problemlerin çözümünde optimum (en uygun) değeri bulmak için kullanılan bir yöntemdir. Derin öğrenme modellerinde genellikle Adam, Adamax, Stochastic Gradient Descent, AdaGrad gibi optimizasyon algoritmaları kullanılır. Her bir optimizasyon algoritmasının diğerine göre olumlu ve olumsuz özellikleri vardır (Tümen, 2019).

Momentum Katsayısı (Momentum): Stochastic Gradient Descent(SDG) optimizasyon algoritması, eğim aşamasında global minimumu elde etmek için aşırı salınım gerçekleştirebilir. Bu salınım gürültü olarak adlandırılır. Geri yayılım esnasında ortaya çıkan gürültünün normalize edilmesi için momentum katsayısı kullanılır. Momentum katsayısı genellikle 0.9 olarak belirlenir, değer aralığı 0.8 ile 0.9 arasında değişmektedir (Başaran, 2020).



Şekil 3.22. (a) Momentum kullanılarak SGD, (b) Momentum kullanılmadan SGD.

3.8.5. Performans ölçümleri

Sınıflandırıcıların performanslarını değerlendirmek üzere karmaşıklık (hata) matrisi, alıcı işlem karakteristik eğrisi ve k-katlı çapraz doğrulama tekniği bu bölümde anlatılmıştır.

3.8.5.1. Karmaşıklık matrisi

Karmaşıklık matrisi diğer bir ifadeyle hata matrisi, genellikle bir algoritmanın nihai başarımını ölçmek için kullanılan bir yöntemdir. Karmaşıklık matrisi algoritmanın doğru ve yanlış tahmin ettiği örnekleri gerçek değerlerle karşılaştırması sonucunda Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP), Yanlış Negatif (YN) olarak adlandırılan 4 farklı indeksten oluşur (Cömert, 2017).

Karmaşıklık matrisi Şekil 3.23'de gösterilmiştir. Şekilde yer alan *DP* gerçekte pozitif olup, tahmin edilen sınıfında pozitif olduğu veri sayısıdır. *DN* gerçekte negatif olup, tahmin edilen sınıfında negatif olduğu veri sayısıdır. *YP* gerçekte pozitif olup, tahmin edilen sınıfın negatif olduğu veri sayısıdır. *YN* gerçekte negatif olup, tahmin edilen sınıfın pozitif olduğu veri sayısıdır (Cömert, 2017).

		Gerçek Sınıf	
		DP	YP
Tahmin Edilen Sınıf	DP	DP	YP
	YN	YN	DN

Şekil 3.23. Karmaşıklık matrisi.

Hata matrisindeki indeksler performans ölçütlerinin elde edilmesini sağlamaktadır. Bu kapsamda en sık kullanılan performans ölçütlerinin matematiksel ifadeleri tanımlanmıştır.

Doğruluk (Accuracy): Modellenen sistemin doğru tahminlerinin tüm örneklere oranı olarak ifade edilir ve tüm örnekler üzerindeki başarımını gösterir. Matematiksel ifadesi Eş. 3.28'deki gibidir.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + YN + DN} \quad (3.28)$$

Negatif Tahmin Değeri: Modellenen sistemin negatif örnekler üzerindeki doğru tahmin etme başarımını gösterir ve Eş. 3.29'daki gibi tanımlanır.

$$\text{Negatif Tahmin Değeri} = \frac{DN}{DN + YN} \quad (3.29)$$

Özgüllük (Specificity): Modellenen sistemin negatif örnekler üzerindeki başarımını ölçmek için kullanılır ve Eş. 3.30'daki gibi tanımlanır.

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.30)$$

Duyarlılık (Recall veya Sensitivity): Modellenen sistemin pozitif örnekler üzerindeki başarımını ölçmek için kullanılır ve Eş. 3.31'deki gibi tanımlanır.

$$Duyarlılık = \frac{DP}{DP + YN} \quad (3.31)$$

Kesinlik(Precision): Modellenen sistemin pozitif örnekler üzerindeki doğru tahmin etme başarımını gösterir ve Eş. 3.32'deki gibi tanımlanır.

$$Kesinlik = \frac{DP}{DP + YP} \quad (3.32)$$

F1-Skoru (F1-Score): Literatürde *Dice Score* olarak da geçmektedir. *Özgüllük* ve *Hassasiyet* değerlerinin harmonik ortalaması olarak ifade edilir ve Eş. 3.33'deki gibi tanımlanmaktadır (Cömert, 2017).


$$F1 = \frac{2DP}{2DP + YP + YN} = 2 \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.33)$$

3.8.5.2. Alıcı işletim karakteristiği

Alıcı işlem karakteristiği (Receiver Operating Characteristic (ROC)), sınıflandırıcı performansını değerlendirmek için sıkça kullanılan yöntemlerden biridir. ROC eğrisi, y ekseninde DP oranı, x ekseninde YP oranına bağlı olarak çizilir. Bu egride DP oranı sınıflandırıcının performansını tanımlarken, YP oranı sınıflandırıcının maliyetini gösterir (Cömert, 2017).

Şekil 3.24, örnek bir ROC grafiğini göstermektedir. Bu grafikte yer alan A, B, C, D, E, F, G olmak üzere 7 nokta ve L₁ ve L₂ olmak üzere iki eğri bulunmaktadır. Sol köşede bulunan A noktası (0,1) en iyi sınıflandırma anlamına gelir. E noktası veri setinde yer alan sınıfların rastgele tahminini temsil etmektedir. Taralı bölgede bulunan herhangi bir sınıflandırıcının kötü bir performansı olduğunu göstermektedir. Örneğin F noktası sınıflandırıcının tahmin edeceği değerlerin tamamen rasgele yapıldığını gösteren bölgeyi işaret eder. G noktası sınıflandırıcı bilgilendiricidir bu nedenle sınıflandırıcının elde edeceği kararların kabul edilebilir olduğunu gösterir. L₁ eğrisi, L₂ eğrisine kıyasla daha


geniş bir alana sahiptir. Bu L_1 eğrisinin ROC değeri L_2 'ye göre daha büyük bir alana sahip olduğu için L_1 sınıflandırıcısının daha iyi bir performans sağladığı anlamı çıkarılabilir (Cömert, 2017).



Şekil 3.24. Alıcı işletim karakteristiği grafiği (Cömert, 2017).

3.8.5.3. K-katlı çapraz doğrulama

k-Katlı çapraz doğrulama tekniği, veri setini k adet kümeye böler. k-1 adet veri kümesini eğitim verisi olarak kullanılırken bir küme ise doğrulama verisi olarak kullanılır. Bu işlem k adet küme boyunca tekrarlanır ve her iterasyon da bir küme doğrulama verisi geri kalan kümeler ise eğitim verisi olacak biçimde k adedince tekrarlanır. Eğitim işlemi bittikten sonra elde edilen performans sonuçlarının aritmetik ortalaması alınarak başarımlar belirlenir. Bu yöntem model değerlendirme yönteminde oldukça etkilidir (Başaran, 2020). Şekil 3.25 'de 5-katlı çapraz doğrulama tekniği gösterilmiştir.



$$\text{Final Doğruluk} = (\text{Doğrulukların Toplamı}) / 5$$

Şekil 3.25. 5-Katlı çapraz doğrulama tekniği.

4. BULGULAR

Bölütleme ve sınıflandırma işlemleri için Python programlama dili ile NVIDIA Quadro P6000 GPU ve NVIDIA TESLA K20X GPU kullanılmıştır. Bölütlenen imgeler ve orijinal imgeler ayrı ayrı eğitilerek test edilmiştir. IFCM yöntemiyle bölütlenen imgeler önerdiğimiz CNN modeli ile eğitilerek IFCM+CNN olarak, orijinal imgeler ise önerdiğimiz model ile eğitilerek CNN olarak adlandırılmıştır. Eğitim aşamasında 5-katlı çapraz doğrulama yöntemi kullanılmıştır.


IFCM algoritmasının hiper parametreleri küme sayısı (c) 3, bulanıklık değeri (m) 1.3, Yager üretic değeri (a) 3, durdurma kriteri (ϵ) 0.00001 ve maksimum iterasyon değeri 50 olarak seçilmiştir. Küme sayısını belirlemek için küme geçerlilik indekslerinden faydalanılmıştır. Bu küme geçerlik indekslerinin sonuçları Çizelge 4.1'de verilmiştir.

Çizelge 4.1. Küme geçerlilik indekslerinin sonuçları.

Küme Sayısı	PC	MPC	XB
3	453603	680412	1.2E+17
4	357151	476210	3.0E+18
5	280230	350295	3.3E+19
6	232241	278697	6.4E+19
7	187952	219286	1.0E+21
8	163414	186768	1.1E+19
9	147385	165817	1.6E+19
10	125310	139243	2.6E+19

Çizelge 4.1’de görüldüğü üzere PC ve MPC değerlerinin maksimum olduğu nokta ve XB'nin minimum olduğu nokta küme sayısının 3 olduğu yeri göstermektedir. Dolayısıyla algoritmanın c parametresi 3 olarak belirlenmiştir. Şekil 4.1 bölütlenmiş imgeleri göstermektedir. Şekilden de anlaşılacağı üzere embriyo ve R1-nj belirteci açık bir şekilde bölütlenmiştir. Bölütlenmiş haploid imgeler üzerindeki beyaz renkli alan embriyo bölgesini göstermektedir. Bölütlenmiş diploid imgeler üzerindeki beyaz alan

embriyoyu ve beyaz alan içerisindeki siyah renkli alan R1-nj belirtecini ifade etmektedir. Tohum dışındaki siyah renkli alanlar ise arka plan rengidir.



Şekil 4.1. Orijinal ve bölütlenmiş mısır imgeleri


IFCM+CNN ve CNN modelinin eğitiminde aynı hiper parametreler kullanılmıştır. Çizelge 4.2’ de hiper parametrelere yer verilmiştir.

Çizelge 4.2. IFCM+CNN ve CNN modellerinde kullanılan hiper parametreler.

Hiper Parametreler	Değer
Dönem (Epoch)	350
Mini Yığın Boyutu	32
Optimizasyon Algoritması	Adam
Öğrenme Oranı	0.0001
L2 Düzenleştirme	0.01
Momentum	0.9
Öğrenme Oranı Çizelge Algoritması	SGD
Rastgele Durum Numarası (Seed)	13

Şekil 4.2’de IFCM+CNN modelinin eğitim aşamasındaki doğruluk ve kayıp grafiklerini göstermektedir. Grafiklerde yer alan mavi (eğitim) ve turuncu (doğrulama)


renkli eğriler doğruluk (accuracy), kırmızı(eğitim) ve yeşil(doğrulama) renkli eğriler kayıp(loss) grafiğini göstermektedir. Şekil 4.2'den de anlaşılacağı üzere her katta (fold) 150 dönemden sonra doğrulama doğruluğu ve doğrulama kayıp eğrilerindeki salınım azalarak stabil hale gelmiştir. Şekilde yer alan grafiklerde de görüldüğü gibi kayıp minimize edilmiş ve kabul edilebilir bir doğruluk elde edilmiştir. Şekilde yer alan a, b, c, d ve e grafikleri sırasıyla 1, 2, 3, 4 ve 5. katları temsil etmektedir.



Şekil 4.2. IFCM+CNN modelinin döneme bağlı kayıp ve doğruluk grafikleri.

Daha önceden de bahsedildiği gibi Çizelge 4.2'de yer alan hiper parametreler kullanılarak eğitim gerçekleştirilmiştir. Şekil 4.3 CNN modelinin eğitim aşamasındaki

doğruluk ve kayıp grafiklerini göstermektedir. Grafiklerde yer alan eğrilerin renkleri Şekil 4.2'deki eğriler ile aynı anlama gelmektedir. Şekilde yer alan grafiklerin salınımı 100 dönemden sonra azalarak stabil hale gelmiştir. Şekil 4.3'den de anlaşılacağı üzere kayıp minimize edilerek yüksek bir doğruluk elde edilmiştir. Şekilde yer alan a, b, c, d ve e grafikleri sırasıyla 1, 2, 3, 4 ve 5. katları temsil etmektedir.



Şekil 4.3. CNN modelinin döneme bağlı kayıp ve doğruluk grafikleri.

Deneyde yapılan analizleri ölçmek için karmaşıklık matrisi parametreleri kullanılmıştır. Çizelge 4.3 ve Çizelge 4.4 sırasıyla IFCM+CNN ve CNN modellerinin karmaşıklık matrislerini ifade etmektedir. Karmaşıklık matrisinde DP, YP, DN ve YN

indeksleri yer alır. DP, gerçekte diploid olup önerdiğimiz modelinde diploid olarak tahmin ettiği örnek sayısını, YP, gerçekte diploid olup önerdiğimiz modelin haploid olarak tahmin ettiği örnek sayısını, DN, gerçekte haploid olup önerdiğimiz modelinde haploid olarak tahmin ettiği örnek sayısını, YN, gerçekte haploid olup önerdiğimiz modelin diploid olarak tahmin ettiği örnek sayısını ifade etmektedir.

Çizelge 4.3. IFCM+CNN modelinin her kattaki karmaşıklık matrisleri.

Fold 1		Fold 2		Fold 3		Fold 4		Fold 5	
312 ^a	42 ^b	319 ^a	35 ^b	278 ^a	76 ^b	298 ^a	56 ^b	239 ^a	115 ^b
59 ^c	187 ^d	82 ^c	164 ^d	28 ^c	218 ^d	31 ^c	215 ^d	28 ^c	218 ^d

^a DP – Doğru Pozitif

^b YP – Yanlış Pozitif

^c YN – Yanlış Negatif

^d DN – Doğru Negatif

Çizelge 4.4. CNN modelinin her kattaki karmaşıklık matrisleri.

Fold 1		Fold 2		Fold 3		Fold 4		Fold 5	
318 ^a	36 ^b	326 ^a	28 ^b	332 ^a	22 ^b	326 ^a	28 ^b	339 ^a	15 ^b
3 ^c	243 ^d	10 ^c	236 ^d	18 ^c	228 ^d	2 ^c	244 ^d	14 ^c	232 ^d

^a DP – Doğru Pozitif

^b YP – Yanlış Pozitif

^c YN – Yanlış Negatif

^d DN – Doğru Negatif


Karmaşıklık matrisindeki indeksler kullanılarak Doğruluk, F1 Skoru, Duyarlılık, Özgüllük ve Kesinlik performans metrikleriyle modellerin performansları ölçülmüştür. Ayrıca standart sapmaları da hesaplanmıştır. Çizelge 4.3 ve Çizelge 4.4 ‘de gösterilen karmaşıklık matrisleriyle elde edilen performans metrikleri Çizelge 4.5’de raporlanmıştır. IFCM+CNN modelinde 81.6%, CNN modelinde ise 94.13% üzerinde bir doğruluk elde edilmiştir. IFCM+CNN modelinde Se ve Sp sırasıyla 86.92% ve 76,60% başarımlar sağlanmıştır. CNN modelinde Se ve Sp performans metrikleri sırasıyla 97.27% ve 90.26% başarımlar sağlanmıştır. Çizelge 4.5’de görüldüğü üzere CNN modeli IFCM+CNN modeline göre daha başarılı bir sonuç vermiştir.

Çizelge 4.5. Her iki modelin performans ölçüm sonuçları.

	Doğruluk (%)	F1-Skoru (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)
IFCM+CNN	81.60± 3.52	83.81± 4.01	86.92± 4.95	76.60 ± 7.02	81.69 ± 9.08
CNN	94.13± 0.88	94.91± 0.78	97.27± 1.94	90.26 ± 2.52	92.71 ± 2.21

± Ortalama standart sapma

Şekil 4.4' de IFCM+CNN ve CNN modellerinin ROC eğrilerini göstermektedir. IFCM+CNN modelinin her kattaki AUC değerleri sırasıyla 0.9040, 0.8919, 0.9135, 0.9065, 0.8638'dir. CNN modelinin her kattaki AUC değerleri sırasıyla 0.9851, 0.9860, 0.9844, 0.9841, 0.9907 olarak hesaplanmıştır. Şekildeki eğrilerden ve AUC değerlerinde de anlaşılacağı üzere CNN modelinin başarımı IFCM+CNN modeline göre daha yüksek bir başarımla elde edildiği görülmektedir.



Şekil 4.4. (a) IFCM+CNN modelinin ROC eğrisi (b) CNN modelinin ROC eğrisi.

5. TARTIŞMA VE SONUÇ

Literatürde haploid ve diploid mısırların yapay zekâ yöntemleriyle ayrıştırılması ile alakalı az sayıda çalışma yapılmıştır. Bu çalışmalar da kullanılan veri seti ve veri setinin miktarı, verilerin dağılımı, kullanılan yöntemler ve genotip sayısı gibi parametrelerin farklı olması sebebiyle çalışmamızı birebir karşılaştırmamız mümkün değildir. Çizelge 5.1’de aynı veri setini kullanan çalışmalara yer verilmiştir.

Çizelge 5.1. Aynı veri setini kullanan çalışmalar ve performans metrikleri.

Yazarlar	#G	Eğitim Verisi		Test Verisi		Yöntem	Acc	Se	Sp
		H	D	H	D				
Altuntaş et al. (2019)	107	861	1239	369	531	CNN	93.4	95.1	92.2
Donmez et al. (2020)	107	861	1239	369	531	CNN	89.5*	90.9*	88.4*
IFCM+CNN	107	984	1416	246	354	CNN	81.60	86.92	76.60
CNN	107	984	1416	246	354	CNN	94.13	97.27	90.26

Çizelge 5.1 ve Çizelge 5.2 ‘de *G* genotip sayısını, *H* haploid veri sayısı, *D* diploid veri sayısı, N/A erişilemeyen bilgiyi ifade eder. Ayrıca * simgesi ise makalelerdeki sayısal verilerden elde edilen metrik bilgilerini ifade eder. Çizelge 5.2’de haploid ve diploid mısırların sınıflandırılması ile alakalı çalışmalara yer verilmiştir.

Çizelge 5.2. Haploid ve Diploid mısırların sınıflandırılmasıyla alakalı çalışmalar.

Yazarlar	#G	Eğitim Verisi		Test Verisi		Yöntem	Acc	Se	Sp
		H	D	H	D				
Boote ve ark. (2016)	7	–	–	59	N/A	Eşik değer	N/A	93.2*	N/A
Fuente ve ark. (2017)	6	600	600	60	60	3. parti yazılımlar	85.8*	76.6*	95.0*
Song ve ark. (2017)	4	314	736	314	736	Eşik değer	92.0*	91.4*	92.2*
Altuntaş ve ark. (2018)	150	87	326	87	326	SVM	81.3	94.2	77.9
L. Yu ve ark. (2018)	1	100	100	100	100	SVSKLPP	97.1	98.8	95.4
Wang ve ark. (2018)	2	100	100	100	100	BPR	N/A	N/A	N/A
Altuntaş ve ark. (2018)	150	87	326	87	326	DT, kNN, ANN	84.5	63.2	90.3
Sabadin ve ark. (2021)	N/A	144	143	61	62	CNN	94.39	97.07	91.71

Haploid mısır imgelerinin sınıflandırılması için farklı yöntemler kullanılmıştır. Bu yöntemlerde kullanılan veri setleri, genotip sayısı, eğitim ve test verilerinin dağılımı, sınıflandırma yöntemleri ve performans değerlendirme ölçütleri gibi parametreler Çizelge 5.1 ve Çizelge 5.2' de karşılaştırma tablosu olarak verilmiştir. Çizelge 5.1 ve Çizelge 5.2'deki veriler Altuntaş ve ark. (Altuntaş ve ark., 2019) tarafından oluşturulan karşılaştırma tablosunun genişletilmiş halidir.

Çizelge 5.2.'de görüldüğü üzere çalışmalarda kullanılan veri miktarının küçük olması çalışmalara olan güvenilirliği azaltmaktadır. Kendi çalışmamızda her katta 2400 eğitim ve 600 test verisiyle, verinin her noktası eğitim ve test olacak biçimde 5-katlı çapraz doğrulama tekniğini kullanarak CNN modeli eğitilmiştir. Kullandığımız veri setinin miktarı ve yöntem bakımından çalışmamızın diğer çalışmalara göre daha güvenilir olduğunu gösterdik.

De La Fuente ve ark. (De La Fuente ve ark., 2017) mısır sınıflandırmasında 80% ve üzeri bir doğruluğun emek ve zaman tasarrufu bakımından kabul edilebilir bir başarımlı olduğunu söylemişlerdir (De La Fuente ve ark., 2017). Önerdiğimiz yöntemlerden biri olan IFCM+CNN modelinde 81.60% doğruluk ve 86.92% hassasiyet ile De La Fuente ve ark. bahsettikleri sınır değerin üzerine çıkarak kabul edilebilir bir başarıma ulaştık. Öte yandan CNN modelinde haploid ve diploid mısır imgelerinin doğru tanımlanmasında 94.13% doğruluk ve 97.27% hassasiyet ile yüksek bir doğruluk elde ettik. Elde ettiğimiz bu yüksek başarımlı kullandığımız veri seti miktarı açısından literatürdeki en iyi ve en güvenilir sonuçlardan biridir.

Ek olarak tez kapsamında IFCM algoritmasının Python uygulaması geliştirilmiştir. Literatüre yeni bir derin öğrenme ağ mimarisi sunulmuştur. Eğittiğimiz modeli kullanarak web tabanlı mısır sınıflandırıcı bir akıllı uygulama geliştirilmiştir.

Bu tez çalışmasında sezgisel bulanık kümeleme ve derin öğrenme yöntemleri kullanılarak haploid ve diploid mısır imgelerini yüksek doğrulukla tanımlayabilecek otomatik bir yapay zekâ sistemi benimsenmiştir. IFCM algoritması ile haploid ve diploid mısır imgeleri bölütlenmiştir. Bölütlenen ve orijinal imgeler 5-katlı çapraz doğrulama tekniği kullanılarak önerdiğimiz CNN modeli ile eğitilmiştir. Önerdiğimiz model de evrimsel blok dikkat modülü, 2 boyutlu üst örnekleme, hiper sütun tekniği ve artık blok teknikleri modelimizin önemli taraflarıdır. Bu model ile mükemmel sonuçlar elde ettik. Deneysel sonuçlar, önerdiğimiz modelin haploid ve diploid mısırların ayrıştırılmasını

optimum başarı ve minimum hatayla gerçekleştirdiğini kanıtlıyor. IFCM+CNN modeli Doğruluk, F1-Skoru ve Duyarlılık performans metriklerinde sırasıyla 81.60%, 83.81% ve 86.92% olarak kabul edilebilir bir başarı elde edildi. CNN modelinde ise Doğruluk, F1-Skoru ve Duyarlılık performans metriklerinde sırasıyla 94.13%, 94.91% ve 97.27% olarak yüksek bir başarı elde edildi. Ek olarak IFCM+CNN modelinde AUC değeri ortalama 0.8959, CNN modelinde ise AUC değeri ortalama yaklaşık 0.9860 olarak elde edildi. Elde ettiğimiz bu sonuçlar, haploid ve diploid mısır tohumlarını başarılı ve düşük maliyetli bir çözüm olduğunu kanıtlamaktadır.

Son olarak gelecekte haploid ve diploid mısır tohumlarını önerdiğimiz model ile ayrıştırabilen bir makine ve akıllı telefonlarla uyumlu çalışabilen yapay zeka destekli toplu haploid tespit etme sistemi geliştirilecektir. Tüm bu çalışmalara Github² adresinden ulaşabilirsiniz.

² <https://github.com/ibrahimayaz/YukseklisansTezCalismalari>



KAYNAKLAR

- Alata, M., Molhim, M., Ramini, A., 2013. Using GA for Optimization of the Fuzzy C-Means Clustering Algorithm. *Research Journal of Applied Sciences, Engineering and Technology*, 5 (3): 695–701.
- Albelwi, S., Mahmood, A., 2017. A framework for designing the architectures of deep convolutional neural networks. *Entropy*, 19 (6): 242.
- Altuntaş, Y., 2018. *Haploid ve Diploid Mısır Tohumlarının İmge Analizi ve Makine Öğrenmesi Algoritmaları Kullanılarak Sınıflandırılması* (yüksek lisans tezi). İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya.
- Altuntaş, Y., Cömert, Z., Kocamaz, A. F., 2019. Identification of haploid and diploid maize seeds using convolutional neural networks and a transfer learning approach. *Computers and Electronics in Agriculture*, 163.
- Altuntas, Y., Kocamaz, A. F., Cengiz, R., Esmeray, M., 2018. Classification of haploid and diploid maize seeds by using image processing techniques and support vector machines. *26th IEEE Signal Processing and Communications Applications Conference*, 1–4.
- Altuntaş, Y., Kocamaz, A. F., Cömert, Z., Cengiz, R., Esmeray, M., 2018. Identification of haploid maize seeds using gray level co-occurrence matrix and machine learning techniques. In *2018 International Conference on Artificial Intelligence and Data Processing*. 1-5.
- Atal, S., 2015. *Bulanık kümeleme analizi ve OECD ülkelerinin gelişmişlik bakımından kümelendirilmesi*, ESOGÜ, Fen Bilimleri Enstitüsü, Eskişehir.
- Atanassov, K. T., 1986. *Intuitionistic fuzzy sets*. *Fuzzy Sets and Systems*, 20 (1): 87–96.
- Atanassov, K. T., 2012. On intuitionistic fuzzy sets theory. *Studies in Fuzziness and Soft Computing*, 283: 1–334.
- Başaran, E., 2020. *Timpanik Membran Görüntü Analizi Ve Yapay Zeka Kullanılarak Sanal Otitis Media Tanı Sisteminin Geliştirilmesi* (doktora tezi), Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük.
- Baykasoğlu, A., Gölcük, İ., Burçin Özsoydan, F., 2019. Improving fuzzy c-means clustering via quantum-enhanced weighted superposition attraction algorithm. *Hacettepe Journal of Mathematics and Statistics*, 48 (3): 859–882.
- Bezdek, J. C., 1973. Cluster validity with fuzzy sets. *Journal of Cybernetics*, 3 (3): 58–73.
- Bezdek, J. C., 1975. Mathematical models for systematics and taxonomy. In *Proceedings of the 8th International Conference on Numerical Taxonomy*, Freeman.
- Bezdek, J. C., Ehrlich, R., Full, W., 1984. FCM: The fuzzy c-means clustering algorithm. *Computers and Geosciences*, 10 (2–3): 191–203.
- Blauch, N. M., Behrmann, M., Plaut, D. C., 2021. Computational insights into human perceptual expertise for familiar and unfamiliar face recognition. *Cognition*, 208.
- Boote, B. W., Freppon, D. J., De La Fuente, G. N., Lübberstedt, T., Nikolau, B. J., Smith, E. A., 2016. Haploid differentiation in maize kernels based on fluorescence imaging. *Plant Breeding*, 135 (4): 439–445.
- Canayaz, M., 2021. C+EffxNet: A novel hybrid approach for COVID-19 diagnosis on CT images based on CBAM and EfficientNet. *Chaos, Solitons & Fractals*, 151.
- Cengiz, R., 2016. *In Vivo Tekniği ile Katlanmış Haploid Mısır Hatlarının Elde Edilmesi* (doktora tezi), Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Tekirdağ.

- Cerit, İ., Cömertpay, G., Oyuncu, R., Çakır, B., Hatipoğlu, R., Özkan, H., 2016. Melez Mısır Islahında In-Vivo Katlanmış Haploid Tekniğinde Kullanılan Farklı Inducer Genotiplerin Haploid İndirgeme Oranların Belirlenmesi. **Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi**, 25 (1): 52–52.
- Chaikam, V., Martinez, L., Melchinger, A. E., Schipprack, W., Boddupalli, P. M., 2016. Development and Validation of Red Root Marker-Based Haploid Inducers in Maize. **Crop Science**, 56 (4): 1678–1688.
- Chaira, T., 2011. A novel intuitionistic fuzzy C means clustering algorithm and its application to medical images. **Applied soft computing**, 11 (2): 1711-1717.
- Chandra, A. L., Desai, S. V., Guo, W., Balasubramanian, V. N., 2020. Computer vision with deep learning for plant phenotyping in agriculture: A survey. **arXiv**, 11391.
- Chase, S. S., 1947. Techniques for isolating monoploid maize plants. **In American Journal of Botany**, 34 (10): 582-582.
- Chase, S. S., Nanda, D. K., 1969. Rapid inbreeding in maize. **Economic Botany** 1969, 23 (2): 165–173.
- Cömert, Z., 2017. **Kardiyotokografi işaretlerinin analizi ve makine öğrenmesi teknikleri ile sınıflandırılması** (doktora tezi), İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Malatya.
- Cömert, Z., 2019. Otitis media için evrimsel sinir ağlarına dayalı entegre bir tanı sistemi. **Bitlis Eren Üniversitesi Fen Bilimleri Dergisi**, 8 (4): 1498–1511.
- Cömert, Z., Kocamaz, A. F., 2018. Fetal hypoxia detection based on deep convolutional neural network with transfer learning approach. In **Computer Science On-line Conference**, 239-248.
- Dave, R. N., 1996. Validating fuzzy partitions obtained through c-shells clustering. **Pattern Recognition Letters**, 17 (6): 613–623.
- De La Fuente, G. N., Carstensen, J. M., Edberg, M. A., Lü bberstedt, T., 2017. Discrimination of haploid and diploid maize kernels via multispectral imaging. **Plant Breeding**, 136 (1): 50–60.
- Dewangan, O., Ambhaikar, A., 2013. Extended Fuzzy C-Means Clustering Algorithm in Segmentation of Noisy Images. **International Journal of Scientific Engineering and Research**, 1 (1-3): 16-19.
- Dhanachandra, N., Manglem, K., Chanu, Y. J., 2015. Image Segmentation Using K - means Clustering Algorithm and Subtractive Clustering Algorithm. **Procedia Computer Science**, 54: 764–771.
- Dönmez, E., 2020. Discrimination of Haploid and Diploid Maize Seeds Based on Deep Features. In **2020 28th Signal Processing and Communications Applications Conference**, 1-4.
- FAO, 2020. **The Global Maize Market**. Food and Agriculture Organization of the United Nations. <https://www.fao.org/3/cb5400en/cb5400en.pdf>. Food and Agriculture Organization of the United Nations, Roma, İtalya. Erişim tarihi: 05.06.2022.
- De La Fuente, G., 2015. **Improvements to the maize (Zea mays L.) in vivo maternal doubled haploid system**.
- Fukushima, K., 1988. Neocognitron: A hierarchical neural network capable of visual pattern recognition. **Neural Networks**, 1 (2): 119–130.
- Fukuyama, Y., 1989. A new method of choosing the number of clusters for the fuzzy c-mean method. In **Proc. 5th Fuzzy Syst. Symp**, 247-250.
- García-Fortea, E., García-Pérez, A., Gimeno-Páez, E., Sánchez-Gimeno, A., Vilanova,

- S., Prohens, J., Pastor-Calle, D. 2020. A Deep Learning-Based System (Microscan) for the Identification of Pollen Development Stages and Its Application to Obtaining Doubled Haploid Lines in Eggplant. *Biology* 2020, 9 (9): 272.
- Geiger, H. H., 2009. Doubled haploids. In *Handbook of maize*. Springer, 641-657, New York.
- Geiger, H. H., Gordillo, G. A., Koch, S., 2013. Genetic correlations among haploids, doubled haploids, and testcrosses in maize. *Crop Science*, 53 (6): 2313–2320.
- Gunderson, R. W., 1978. Application of Fuzzy Isodata Algorithms to Star Tracker Pointing Systems. *IFAC Proceedings Volumes*, 11 (1): 1319–1323.
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Hemmer, M., Van Khang, H., Robbersmyr, K. G., Waag, T. I., Meyer, T. J. J., 2018. Fault classification of axial and radial roller bearings using transfer learning through a pretrained convolutional neural network. *Designs*, 2 (4): 1–17.
- Huang, S., Fan, X., Sun, L., Shen, Y., Suo, X., 2019. Research on Classification Method of Maize Seed Defect Based on Machine Vision. *Journal of Sensors*.
- International Grains Council, 2021. https://www.igc.int/en/gmr_summary.aspx. Uluslararası Hububat Konseyi, Erişim tarihi: 05.06.2022.
- Işık, M., Çamurcu, A. Y., 2007. K-Means, K-Medoids Ve Bulanık C-Means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 6 (11): 31–45.
- Jeny, A. A., Junayed, M. S., Atik, S. T., 2018. PassNet-Country Identification by Classifying Passport Cover Using Deep Convolutional Neural Networks. In *2018 21st International Conference of Computer and Information Technology*, 1-6.
- Kim, J. Y., Cho, S. B., 2019. Evolutionary Optimization of Hyperparameters in Deep Learning Models. *2019 IEEE Congress on Evolutionary Computation*, 831–837.
- Krizhevsky, A., Sutskever, I., Hinton, G. E., 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60 (6): 84–90.
- Kumar, D., Verma, H., Mehra, A., Agrawal, R. K., 2019. A modified intuitionistic fuzzy c-means clustering approach to segment human brain MRI image. *Multimedia Tools and Applications*, 78 (10): 12663–12687.
- Kutlu, F., 2016. *Fuzzy, Intuitionistic Fuzzy ve Temporal Intuitionistic Fuzzy Küme Teorisinde Uzaklık - Benzerlik Ölçüleri ve Topolojik Özellikler*, Van Yüzüncü Yıl Üniversitesi, Fen Bilimleri Enstitüsü, Van.
- LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *nature*, 521 (7553): 436-444.
- MacQueen, J., 1967. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, 1 (14): 281-297.
- Majumdar, D., Ghosh, A., Kole, D. K., Chakraborty, A., Majumder, D. D., 2014. Application of Fuzzy C-Means clustering method to classify wheat leaf images based on the presence of rust disease. *Advances in Intelligent Systems and Computing*, 327: 277–284.
- Melchinger, A. E., Schipprack, W., Utz, H. F., Mirdita, V., 2014. In Vivo Haploid Induction in Maize: Identification of Haploid Seeds by Their Oil Content. *Crop Science*, 54 (4): 1497–1504.

- Oyelade, J., Isewon, I., Oladipupo, O., Emebo, O., Omogbadegun, Z., Aromolaran, O., Uwoghien, E., Olaniyan, D., Olawole, O., 2019. Data Clustering: Algorithms and Its Applications. *Proceedings - 2019 19th International Conference on Computational Science and Its Applications*, 71–81.
- Özyurt, F., Sert, E., Avcı, D., 2020. An expert system for brain tumor detection: Fuzzy C-means with super resolution and convolutional neural network with extreme learning machine. *Medical Hypotheses*, **134**: 109433.
- Pal, N. R., Bezdek, J. C., 1995. On Cluster Validity for the Fuzzy c-Means Model. *IEEE Transactions on Fuzzy Systems*, **3** (3): 370–379.
- Pham, D. L., Prince, J. L., 1999. An adaptive fuzzy C-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Pattern Recognition Letters*, **20** (1): 57–68.
- Prigge, V., 2012. Implementation and optimization of the doubled haploid technology for tropical maize (*Zea mays* L.), *breeding programs*.
- Sabadin, F., Galli, G., Borsato, R., Gevartosky, R., Campos, G. R., Fritsche-Neto, R., 2021. Improving the identification of haploid maize seeds using convolutional neural networks. *Crop Science*, **61** (4): 2387–2397.
- Sarwinda, D., Paradisa, R. H., Bustamam, A., Anggia, P., 2021. Deep learning in image classification using residual network (ResNet) variants for detection of colorectal cancer. *Procedia Computer Science*, **179**: 423–431.
- Smelser, A., Blanco, M., Lübberstedt, T., Schechert, A., Vanous, A., Gardner, C., 2015. Weighing in on a method to discriminate maize haploid from hybrid seed. *Plant Breeding*, **134** (3): 283–285.
- Song, P., Zhang, H., Wang, C., Luo, B., Zhang, J. X., 2018. Design and Experiment of a Sorting System for Haploid Maize Kernel. *International Journal of Pattern Recognition and Artificial Intelligence*, **32** (3).
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, **15** (1): 1929–1958.
- Taylor, J., Chiou, C. P., Bond, L. J., 2019. A methodology for sorting haploid and diploid corn seed using terahertz time domain spectroscopy and machine learning. In *AIP Conference Proceedings*, **2102** (1): 080001.
- Tian, C., Xu, Y., Fei, L., Yan, K., 2018. Deep learning for image denoising: A survey. In *International Conference on Genetic and Evolutionary Computing*, 563–572. Springer, Singapore.
- Toğaçar, M., Ergen, B., Cömert, Z., 2020. BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model. *Medical Hypotheses*, **134**: 109531.
- Toğaçar, M., Ergen, B., Cömert, Z., 2021. Tumor type detection in brain MR images of the deep model developed using hypercolumn technique, attention modules, and residual blocks. *Medical and Biological Engineering and Computing*, **59** (1): 57–70.
- TÜİK., 2021. Kurumsal. Bitkisel Üretim 2.Tahmini, 2021, <https://data.tuik.gov.tr/Bulten/Index?p=Bitkisel-Uretim-2.Tahmini-2021-37248>. Türkiye İstatistik Kurumu, Ankara. Erişim tarihi: 05.06.2022.

- Tümen, V., 2019. *Akıllı Ulaşım Sistemleri İçin Karayolu Tipi, Kavşak ve Virajların Derin Öğrenme Yöntemleri ile Belirlenmesi* (doktora tezi). Fen Bilimleri Enstitüsü, Fırat Üniversitesi, Elazığ.
- Valsalan, P., Sriramakrishnan, P., Sridhar, S., Latha, G. C. P., Priya, A., Ramkumar, S., Singh, A. R., Rajendran, T., 2020. Knowledge based fuzzy c-means method for rapid brain tissues segmentation of magnetic resonance imaging scans with CUDA enabled GPU machine. *Journal of Ambient Intelligence and Humanized Computing*, **1**: 1–14.
- Veeramani, B., Raymond, J. W., Chanda, P., 2018. DeepSort: deep convolutional networks for sorting haploid maize seeds. *BMC Bioinformatics* **2018**, **19** (9): 1–9.
- Wang, X. Y., Liao, W.-X., An, D., Wei, Y. G., 2018. Maize Haploid Identification via LSTM-CNN and *Hyperspectral Imaging Technology*. arXiv.
- Wang, Y., Lv, Y., Liu, H., Wei, Y., Zhang, J., An, D., Wu, J., 2018. Identification of maize haploid kernels based on hyperspectral imaging technology. *Computers and Electronics in Agriculture*, **153**: 188–195.
- Windham, M. P., 1981. Cluster validity for fuzzy clustering algorithms. *Fuzzy Sets and Systems*, **5** (2): 177–185.
- Windham, M. P., 1982. Cluster Validity for the Fuzzy c-Means Clustering Algorithm. *IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-4* (4): 357–363.
- Woo, S., Park, J., Lee, J. Y., Kweon, I. S., 2018. CBAM: Convolutional block attention module. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 3–19.
- Xie, X. L., Beni, G., 1991. A validity measure for fuzzy clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **13** (8): 841–847.
- Xu, Z., Wu, J., 2010. Intuitionistic fuzzy C-means clustering algorithms. *Journal of Systems Engineering and Electronics*, **21** (4): 580–590.
- Yu, L., Liu, W., Li, W., Qin, H., Xu, J., Zuo, M., 2018. Non-destructive identification of maize haploid seeds using nonlinear analysis method based on their near-infrared spectra. *Biosystems Engineering*, **172**: 144–153.
- Zadeh, L. A., 1965. Fuzzy sets. *Information and Control*, **8** (3): 338–353.



ÖZ GEÇMİŞ

İlkokul, ortaokul ve lise eğitimini Bitlis'te tamamlamıştır. 2019 yılında Muş Alparslan Üniversitesi Bilgisayar Mühendisliği bölümünden mezun olmuştur. 2020 bahar döneminde başladığı yüksek lisans eğitimine, 2022 bahar döneminde Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Yapay Zeka ve Robotik Anabilim Dalı'nda yüksek lisans eğitimini tamamlamıştır.





VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih: 10/06/2022

Tez Başlığı / Konusu: Sezgisel Bulanık Küme Tabanlı Derin Öğrenme Modelleriyle Haploid ve Diploid Mısırların Sınıflandırılması

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 91 sayfalık kısmına ilişkin, 10/06/2022 tarihinde şahsım/tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %5 (yüzde beş) dir.

Uygulanan filtreler aşağıda verilmiştir:

- Materyal ve yöntem hariç,
- Kaynaklar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimeden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

Tarih ve İmza

Adı Soyadı: İbrahim AYAZ

Öğrenci No: 19910001295

Anabilim Dalı: Yapay Zeka ve Robotik

Programı:

Statüsü: ☒ Yüksek Lisans

☐ Doktora

DANIŞMAN ONAYI
UYGUNDUR

Dr. Öğr. Üyesi Fatih KUTLU

ENSTİTÜ ONAY
UYGUNDUR