



TARSUS  
ÜNİVERSİTESİ

TARSUS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**PIRİNÇ ÇELTİĞİNİN ÇEKİLMESİ SONUCU ELDE EDİLEN  
PIRİNÇ TANELERİNİN SINIFLANDIRILMASI İŞLEMİNİN  
MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ**

**Kıvanç ERMEYDAN**

İMALAT MÜHENDİSLİĞİ ANA BİLİM DALI

TARSUS-2019

TARSUS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**PIRİNÇ ÇELTİĞİNİN ÇEKİLMESİ SONUCU ELDE EDİLEN  
PIRİNÇ TANELERİNİN SINIFLANDIRILMASI İŞLEMİNİN  
MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ**

**Kıvanç ERMEYDAN**

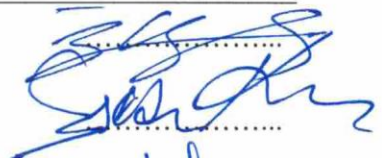

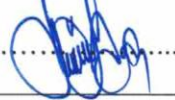
**Danışman  
Dr. Öğretim Üyesi İrem ERSÖZ KAYA**

İMALAT MÜHENDİSLİĞİ ANA BİLİM DALI

TARSUS-2019

## ONAY

Kıvanç ERMEYDAN tarafından Dr. Öğretim Üyesi İrem ERSÖZ KAYA danışmanlığında hazırlanan "Pirinç Çeltiğinin Çekilmesi Sonucu Elde Edilen Pirinç Tanelerinin Sınıflandırılması İşleminin Makine Öğrenmesi İle Gerçekleştirilmesi" başlıklı çalışma aşağıda imzaları bulunan jüri üyeleri tarafından 29/08/2019 tarihinde yapılan Tez Savunma Sınavı sonucunda oy birliği ile Yüksek Lisans tezi olarak kabul edilmiştir.

Görevi	Ünvanı, Adı ve Soyadı	İmza
Başkan	Dr. Öğretim Üyesi İrem ERSÖZ KAYA	
Üye	Dr. Öğretim Üyesi Ercan KÖSE	
Üye	Dr. Öğretim Üyesi Deniz ÜSTÜN	

Yukarıdaki Jüri kararı Lisansüstü Eğitim Enstitüsü Yönetim Kurulu'nun 26.../09/ 2019 tarih ve .....57...../.....231.....sayılı kararıyla onaylanmıştır.

Doç. Dr. Osman Murat ÖZKENDİR  
Lisansüstü Eğitim Enstitüsü Müdürü



*Bu tezde kullanılan özgün bilgiler, şekil, tablo ve fotoğraflardan kaynak göstermeden alıntı yapmak 5846 sayılı Fikir ve Sanat Eserleri Kanunu hükümlerine tabidir.*

## ETİK BEYAN

Tarsus Üniversitesi Lisansüstü Eğitim-Öğretim Yönetmeliğinde belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada,

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
  - Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlâk kurallarına uygun olarak sunduğumu,
  - Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
  - Atıfta bulunduğum eserlerin tümünü kaynak olarak kullandığımı,
  - Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
  - Bu tezin herhangi bir bölümünü Tarsus Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,
  - Tezin tüm telif haklarını Tarsus Üniversitesi'ne devrettiğimi
- beyan ederim.

## ETHICAL DECLARATION

This thesis is prepared in accordance with the rules specified in Tarsus University Graduate Education Regulation and I declare to comply with the following conditions:

- I have obtained all the information and the documents of the thesis in accordance with the academic rules.
- I presented all the visual, auditory and written informations and results in accordance with scientific ethics.
- I refer in accordance with the norms of scientific works about the case of exploitation of others' works.
- I used all of the referred works as the references.
- I did not do any tampering in the used data.
- I did not present any part of this thesis as an another thesis at Tarsus University or another university.
- I transfer all copyrights of this thesis to the Tarsus University.

29 Ağustos 2019 / 29 August 2019

İmza / Signature

Kıvanç ERMEYDAN

## İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
TABLolar DİZİNİ	iv
ŞEKİLLER DİZİNİ	v
GRAFİKLER DİZİNİ	vi
KISALTMALAR ve SİMGELER	vii
<b>1. GİRİŞ</b>	<b>1</b>
<b>2. LİTERATÜR TARAMASI</b>	<b>3</b>
<b>3. MATERYAL VE YÖNTEM</b>	<b>6</b>
3.1. Materyal	6
3.1.1. Pirinç Bitkisi	6
3.1.2. Pirinç Çeltiğinin Çekilmesi	8
3.1.3. Pirinçlerin Fotoğraflanması	9
3.1.3.1. Tam (Kırılmamış) Pirinçler	10
3.1.3.2. Kırık (Tam Olmayan) Pirinçler	12
3.1.4. Fotoğraflanmış Pirinçlerin Ayrılması	15
3.1.4.1. Sobel Kenar Bulma Algoritması	15
3.1.4.2. Derin Öğrenme Yöntemi İçin Pirinçlerin Standart Boyutlu Parçalanması	17
3.1.5. Pirinçlerin Tür Ve Durumlarına Göre Dağılımları	17
3.1.6. Özellik Çıkarımı	18
3.1.6.1. Pirinçlerin Boyutları	19
3.1.6.2. RGB (Red Green Blue) Renk Uzayı	19
3.1.6.3. HSL (Hue Saturation Lightness) Ve HSV (Hue Saturation Value) Renk Uzayları	20
3.1.6.4. CIEXYZ Renk Uzayı	22
3.1.6.5. CIELAB (CIE L*a*b*) Renk Uzayı	24
3.1.6.6. GLCM (Gray-Level- Co-Occurrence Matrix) Özellik Vektörü	25
3.2. Yöntem	30
3.2.1. Karar Ağaçları (Decision Tree)	30
3.2.2. Destek Vektör Makineleri (Support Vector Machines)	31
3.2.2.1. Doğrusal Destek Vektör Makineleri (Linear Support Vector Machines)	32
3.2.2.2. Doğrusal Olmayan (İkinci Dereceden) Destek Vektör Makineleri	33
3.2.3. Naive Bayes Sınıflandırıcı	34
3.2.4. K En Yakın Komşu Algoritması (K Nearest Neighborhood Algorithm)	35
3.2.4.1. Euclidean uzaklığı (Euclidean Distance)	35
3.2.5. Derin Öğrenme Yöntemi (Deep Learning)	35
3.2.5.1. İki Boyutlu Evrişim	36
3.2.5.2. Üç Boyutlu Evrişim	37
3.2.5.3. Kenar Bulma İşlemi	38
3.2.5.4. Piksel Ekleme (Padding)	38
3.2.5.5. Kaydırma (Stride)	38
3.2.5.6. Ortaklama (Pooling)	39
3.2.5.7. Seyreltme (Drop Out)	39
3.2.5.8. Yığın Normalizasyonu (Batch Normalization)	40
3.2.5.9. Üstel Normalizasyon Fonksiyonu (Softmax Function)	40
<b>4. UYGULAMA VE SONUÇLAR</b>	<b>42</b>
4.1. Pirinçlerin Tür Ve Durumlarına Göre Sınıflandırılması (Uygulama 1)	45
4.2. Pirinçlerin Türlerine Göre Sınıflandırılması (Uygulama 2)	57
4.3. Pirinçlerin Durumlarına Göre Sınıflandırılması (Uygulama 3)	65
<b>5. TARTIŞMA VE ÖNERİLER</b>	<b>67</b>
<b>KAYNAKLAR</b>	<b>70</b>
<b>ÖZGEÇMİŞ</b>	<b>72</b>

## ÖZET

### PIRİNÇ ÇELTİĞİNİN ÇEKİLMESİ SONUCU ELDE EDİLEN PİRİNÇ TANELERİNİN SINIFLANDIRILMASI İŞLEMİNİN MAKİNE ÖĞRENMESİ İLE GERÇEKLEŞTİRİLMESİ

Günümüzde pirinç çeltiğinin çekilmesi sonucu kabuğundan ayrılan pirinç tanelerinin sınıflandırılması el ile yapılmaktadır. Bu yöntem ilgili sektörde zaman kaybı ve iş gücü verimsizliğine neden olarak ekonomik kayıplara yol açmaktadır. Bu soruna çözüm üretmek amacıyla daha önceden çekilmiş pirinç tanelerin makine öğrenmesi yöntemiyle sınıflandırılması bu tez sonucunda amaçlanmaktadır. Söz konusu sınıflandırılma işlemi için makine öğrenmesi yöntemlerinden faydalanılmıştır. Makine öğrenmesi yöntemleriyle ilgili makineler ses, görüntü, sinyal, metin gibi verileri kullanarak sınıflandırma, nesne tanıma, ses tanıma ya da dil çevirileri gibi özelleşmiş görevleri en az hatayla yerine getirir duruma gelmişlerdir. Son yıllarda makine öğrenme yöntemlerinin sürekli geliştirilmesiyle görüntü işleme, ses işleme ve robotik gibi alanlara bu yöntemler önemli bir yer bulmuştur.

Bu tezde kullanılan makine öğrenmesi yöntemleri ile ilgili sektörde zaman kaybı ve iş gücü verimsizliğinin giderilmesi hedeflenmekte, ilerleyen süreçlerde sınıflandırılmaya ihtiyaç duyulan diğer sektörlerde de mevcut sorunların giderilmesine katkıda bulunulacak çalışmalara temel oluşturması amaçlanmaktadır.

Tezde pirinçlerin fotoğraflanması ve parçalanması süreci ayrıntılı biçimde anlatılmıştır. Parçalanma sürecinde Sobel Kenar Bulma Algoritması'ndan faydalanılmıştır. Pirinçlere ait görüntülerin özelliklerinin çıkarılmasında, boyut kestirimi, RGB, HSL, HSV, CIEXYZ, CIELAB renk uzayları ve değerlerinin tespiti ve GLCM özellik vektörü ile ilgili ayrıntılı bilgilere yer verilmiştir.

Teze ismini veren makine öğrenmesi bahsinde kullanılan yöntemler Karar Ağaçları (Decision Tree), Destek Vektör Makineleri (Support Vector Machine), Naive Bayes, K En Yakın Komşu Algoritması (K-Nearest Neighborhood Algorithm) ve Derin Öğrenme Yöntemi (Deep Learning) olmuştur. Bu modellere ait bilgiler ile uygulamada nasıl kullanıldıkları ve uygulamaya ilişkin sonuçlar son bölümde paylaşılmıştır.

Tez sonucunda uygulanan makine öğrenmesi yöntemlerine ait sonuçlar karşılaştırmalı olarak gösterilmiş ve en başarılı makine öğrenmesi yöntemi İkinci Dereceden Destek Vektör Makineleri olmuştur.

**Anahtar Kelimeler:** Yapay Sinir Ağları, Makine Öğrenmesi, Görüntü İşleme, Sınıflandırma, Derin Öğrenme

**Danışman:** Dr. Öğretim Üyesi İrem ERSÖZ KAYA, Tarsus Üniversitesi, Yazılım Mühendisliği Anabilim Dalı, Tarsus.

## ABSTRACT

### CLASSIFICATION OF RICE GRAINS OBTAINED FROM PROCESSED RICE PADDY WITH MACHINE LEARNING

Nowadays, the classification of the rice grains separated from the husk by pulling the rice paddy is made by hand. This method results in economic loss by causing time loss and labor inefficiencies in the related sector. In order to produce a solution to this problem, in this study, it is aimed to classify previously extracted rice grains by machine learning method. Machine learning method has been used for this classification. With this method, machines are able to perform specialized tasks such as classification, object recognition, voice recognition or language translations with the least error by using data such as voice, image, signal and text. In recent years, with the continuous development of machine learning methods, this method has found an important place in fields such as image processing, sound processing and robotics.

With this thesis, it is aimed to eliminate time loss and labor inefficiency in the related sector by using machine learning method and to provide the basis for the studies that will contribute to the elimination of existing problems in other sectors that need to be classified in the following processes.

In this thesis, the process of photographing and shredding of rice is explained in detail. Sobel Edge Detection Algorithm was used in the process of fragmentation. In order to obtain the properties of the images of rice, detailed information about size estimation, determination of color spaces and values of RGB, HSL, HSV, CIEXYZ, CIELAB and GLCM feature vector were explained.

Machine learning designs, which give its name to this thesis, are Decision Trees, Support Vector Machines, Naive Bayes, K-Nearest Neighborhood Algorithm and Deep Learning Method. The information about these models, how they are used in practice and the results related to the application are shared in the last section.

At the end of the thesis, the results of machine learning method are shown comparatively and the most successful network model is Quadratic Support Vector Machines.

**Keywords:** Artificial Neural Networks, Machine Learning, Image Processing, Classification, Deep Learning

**Advisor:** Assoc. Prof. Dr. İrem ERSÖZ KAYA, Department Of Software Engineering, University Of Tarsus, Tarsus-Mersin.

## TEŐEKKÜR

Tez alıőmamın her aőamasında yardımını ve desteęini esirgemeyen bilgi ve tecrübelerinden faydalandıęım deęerli hocam Dr. Öğretim Üyesi İrem ERSÖZ KAYA'ya, materyallerin elde edilme sürecinde katkıda bulunan Fatih TÜRKMENOĐLU'na, fotoęraflanmalarında yardımını esirgemeyen Yasin Tayyip TÜRKMENOĐLU'na ve tez jürimde bulunan hocalarıma yapıcı eleőtiri ve önerileri için teőekkür ederim.

*Bana dünyanın en güzel hediyesini veren eőim Aybike ve kızım Iőıl Alben'e...*



## TABLolar DİZİNİ

	<b>Sayfa</b>
Tablo 2.1. 100 gram pirincin besin deęerleri	7
Tablo 3.1. Fotoęraflamada Kullanılan Ayarlar	10
Tablo 3.2. Sobel Kenar Bulma Algoritmasında Kullanılan Kernel Matrisleri	15
Tablo 3.3. Pirinçlerin Tür Ve Durumlarına Göre Daęılımı	18
Tablo 3.4. Pirinçlerin Türlerine Göre Daęılımı	18
Tablo 3.5. Pirinçlerin Durumlarına Göre Daęılımı	18
Tablo 4.1. Pirinçlerin Tür Ve Durumlarına Göre Daęılımı	42
Tablo 4.2. Pirinçlerin Türlerine Göre Daęılımı	42
Tablo 4.3. Pirinçlerin Durumlarına Göre Daęılımı	42
Tablo 4.4. Uygulama 1'deki Başarı Oranları	45
Tablo 4.5. Uygulama 1'in Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları	56
Tablo 4.6. Uygulama 1'in Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri	57
Tablo 4.7. Uygulama 2'deki Başarı Oranları	57
Tablo 4.8. Uygulama 2'nin Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları	64
Tablo 4.9. Uygulama 2'nin Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri	65
Tablo 4.10. Uygulama 3'teki Başarı Oranları	65
Tablo 4.11. Uygulama 3'ün Modellerdeki Tahmin Sayıları Ve Başarı Yüzdeleri	65
Tablo 4.12. Uygulama 3'ün Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları	66
Tablo 4.13. Uygulama 3'ün Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri	66

## ŞEKİLLER DİZİNİ

	<b>Sayfa</b>
Şekil 3.1. Bir Asya pirinç çeltiği ve üzerinde olgunlaşmış pirinç taneleri	8
Şekil 3.2. Plaka üzerinde fotoğraflanmış 30 adet birinci kalite pirinç	10
Şekil 3.3. Fotoğraflanmış birinci kalite tam pirinçler	11
Şekil 3.4. Fotoğraflanmış ikinci kalite tam pirinçler	11
Şekil 3.4. Fotoğraflanmış az çekilmiş tam pirinçler	11
Şekil 3.5. Fotoğraflanmış çekilmemiş tam pirinçler	12
Şekil 3.6. Fotoğraflanmış olgunlaşmamış veya çürümüş tam pirinçler	12
Şekil 3.7. Fotoğraflanmış birinci kalite kırık pirinçler	13
Şekil 3.8. Fotoğraflanmış ikinci kalite kırık pirinçler	13
Şekil 3.9. Fotoğraflanmış az çekilmiş kırık pirinçler	14
Şekil 3.10. Fotoğraflanmış çekilmemiş kırık pirinçler	14
Şekil 3.11. Fotoğraflanmış çürümüş veya olgunlaşmamış kırık pirinçler	14
Şekil 3.12. Siyah Beyaz Tonlamalı Papatya Çiçeği	15
Şekil 3.13. Şekil 3.12'ye 3x3'lük matrisle Sobel Kenar Bulma Algoritması Uygulanması Sonucu	16
Şekil 3.14. Şekil 3.12'ye 5x5'lik matrisle Sobel Kenar Bulma Algoritması Uygulanması Sonucu	16
Şekil 3.15. Sobel Kenar Bulma Algoritması Uygulanarak Plaka Üzerinde Fotoğraflanmış Pirinç Tanelerinin Tespiti	16
Şekil 3.16. Plakalardan Parçalanmış Farklı Türlerde Pirinçlerin Fotoğrafları	17
Şekil 3.17. RGB Renk Uzayı	19
Şekil 3.18. HSL Renk Uzayı	21
Şekil 3.19. HSV Renk Uzayı	21
Şekil 3.20. CIEXYZ Renk Uzayı	23
Şekil 3.21. CIELAB Renk Uzayı	24
Şekil 3.22. Doğrusal Destek Vektör Makinesi Ayrıcısı Örneği	32
Şekil 3.23. Doğrusal Ayrılan Veri Setleri İçin Hiper-Düzlem Belirlenmesi Örneği	33
Şekil 3.24. Doğrusal Olmayan Destek Vektör Makinesi Örneği	34
Şekil 3.25. 7x6 Boyutundaki İki Kanallı Görüntüye 3x3 Matrisiyle Uygulanan İki Boyutlu Evrişim İşlemi	37
Şekil 3.26. 6x6 Boyutundaki Üç Kanallı Görüntüye Uygulanan 3x3 Evrişim İşlemi	37
Şekil 3.27. Rastgele Seçilmiş İnsan Yüzlerine Uygulanmış Kenar Bulma Algoritmaları	38
Şekil 3.28. En Büyük Değerin Alınması İlkesine Dayanan 2x2'lik Maksimum Ortaklama İşlemi (Max-Pooling) Ve Sonucu	39
Şekil 3.29. 3x6'lık Matrisin Dikey Yönde Ortalama Ve Standart Sapma Değeri Üzerinden Yığın Normalizasyonu İşlemi	40
Şekil 3.30. 5 Tür Çıkışlı Örnek Softmax Katmanı	41
Şekil 4.1. Tezde kullanılan Derin Öğrenme Yöntemi için tasarlanan ağ modeli	43

## GRAFİKLER DİZİNİ

	Sayfa
Grafik 3.1. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin RGB Renk Uzayında Dağılımı	20
Grafik 3.2. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin HSL Renk Uzayında Dağılımı	21
Grafik 3.3. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin HSV Renk Uzayında Dağılımı	22
Grafik 3.4. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin CIEXYZ Renk Uzayında Dağılımı	23
Grafik 3.5. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin CIELAB Renk Uzayında Dağılımı	25
Grafik 4.1. Uygulama 1'in Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Sayıları	46
Grafik 4.2. Uygulama 1'in Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Yüzdeleri	46
Grafik 4.3. Uygulama 1'in Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları	47
Grafik 4.4. Uygulama 1'in Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri	47
Grafik 4.5. Uygulama 1 - Doğrusal Destek Vektör Makineleri (YK - YT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre	48
Grafik 4.6. Uygulama 1 - Doğrusal Destek Vektör Makineleri (YK - YT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre (Hatalılar)	48
Grafik 4.7. Uygulama 1'in İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları	49
Grafik 4.8. Uygulama 1'in İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri	50
Grafik 4.9. Uygulama 1 – İkinci Dereceden Destek Vektör Makineleri (TK - TT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre	50
Grafik 4.10. Uygulama 1 – İkinci Dereceden Destek Vektör Makineleri (TK - TT Karşılaştırması 2), riceApproximate ve riceSize Özelliklerine Göre (Hatalı)	51
Grafik 4.11. Uygulama 1'in Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Sayıları	52
Grafik 4.12. Uygulama 1'in Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Yüzdeleri	52
Grafik 4.13. Uygulama 1'in K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Sayıları	53
Grafik 4.14. Uygulama 1'in K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Yüzdeleri	54
Grafik 4.15. Uygulama 1 – K En Yakın Komşu Algoritması (KOK - YK Karşılaştırması 1), RedMean ve BlueMean Özelliklerine Göre	54
Grafik 4.16. Uygulama 1 – K En Yakın Komşu Algoritması (KOK - YK Karşılaştırması 2), RedMean ve BlueMean Özelliklerine Göre (Hatalı)	55
Grafik 4.17. Derin Öğrenme Yöntemi'nin Uygulama 1 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))	56
Grafik 4.18. Uygulama 2'nin Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Sayıları	58
Grafik 4.19. Uygulama 2'nin Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Yüzdeleri	58
Grafik 4.20. Uygulama 2'nin Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları	59
Grafik 4.21. Uygulama 2'nin Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri	59
Grafik 4.22. Uygulama 2'nin İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları	60
Grafik 4.23. Uygulama 2'nin İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri	61

---

	<b>Sayfa</b>
Grafik 4.24. Uygulama 2'nin Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Sayıları	61
Grafik 4.25. Uygulama 2'nin Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Yüzdeleri	62
Grafik 4.26. Uygulama 2'nin K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Sayıları	63
Grafik 4.27. Uygulama 2'nin K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Yüzdeleri	63
Grafik 4.28. Derin Öğrenme Yöntemi'nin Uygulama 2 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))	64
Grafik 4.29. Derin Öğrenme Yöntemi'nin Uygulama 3 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))	66

---



## KISALTMALAR ve SİMGELER

Kısaltma/Simge	Tanım
CIE	Commission Internationale de l'éclairage (Uluslararası Aydınlatma Komisyonu)
DÖY	Derin Öğrenme Yöntemi
DVM	Destek Vektör Makineleri
ESA	Evrişimsel Sinir Ağı
GLCM	Gray-Level Co-Occurrence Matrix
HSL	Hue Saturation Lightness
HSV	Hue Saturation Value
DDVM	Doğrusal Destek Vektör Makineleri
İDDVM	İkinci Dereceden Destek Vektör Makineleri
KA	Karar Ağaçları
KEYK	K-En Yakın Komşu
KDVM	Kuadratik Destek Vektör Makineleri
LDVM	Liner Destek Vektör Makineleri
NBS	Naive Bayes Sınıflandırıcı
RGB	Red Green Blue
YSA	Yapay Sinir Ağları

## 1. GİRİŞ

Makine öğrenmesi, bilgisayarların veritabanı veya sensör (algılayıcı) verilerini kullanarak öğrenimine imkân veren algoritmaların tasarımı ve geliştirilmesini temel alan bir bilim dalıdır. Makine öğrenmesi ile bilgisayara basit sayılabilecek veriler üzerinden karmaşık sayılabilecek karar verebilme yetisi sağlanmaktadır. Bu kabiliyetler genel olarak sınıflandırma, kümeleme, regresyon, farklılık tespiti, tahmin, öznitelik çıkarımı ve öğrenmesi şeklinde sıralanabilir [1, 2].

Halen geliştirilmekle beraber son yıllarda makine öğrenmesi amacıyla geliştirilen uygulamalarda yapay zekâ temelinde doğal dil işleme, konuşma analizi ve anlama, uzman sistemler, karar destek sistemleri, örüntü tanıma, bulanık mantık, sinyal işleme, görüntü işleme gibi alanlarda başarı oranı yüksek sonuçlar elde edilmiştir. Bu uygulamaların en önemli katkısı insan duyu organları ile algılanan birçok verinin çok daha hızlı ve farklı yönleriyle değerlendirilmesi sonucunda elde edilen insanüstü işlem kabiliyeti ve sonuçların elde edilmesidir.

Günümüzde birçok alanda olduğu gibi imalat alanında da makine öğrenmesi problemlerin çözümünde zaman ve iş gücü kazanımı sağlamaktadır. Makine öğrenmesi ile imalat alanında makinelerin iş gücüne katkısının artırılması, robot kolların imalatta kullanımı, daha verimli işlemler için endüstriyel araçların otomatikleştirilmesi, imalat sürecinde ve imalat sonrası ürünlere ait görüntülerin incelenmesi sonucu yargıya ulaşılması, kalite kontrol süreçlerinin makineler tarafından gerçekleştirilmesi, satış ve üretim alanında tahmin yürütme, kullanıcı talepleri ve kaynaklara göre ilgili süreçleri optimize etmek gibi amaçlara hizmet etmektedir.

İmalat alanında bir ürünün kalitesi, türü, durumu gibi benzer kategorilere göre sınıflandırılması işlemlerine odaklanılacak olunursa mevcut endüstriyel çözümlerin ileri taşınması için makine öğrenmesi ile daha gelişmiş yazılımsal destek sağlanmaktadır. Alanda yer alan endüstriyel çözümler incelendiğinde tarımsal ürünlerin ayrıştırılması işleminin makineler tarafından gerçekleştirildiği görülmektedir. Tarımsal ürünlerin istenmeyen nesnelere ayrıştırılması, belirli sınıflara kategorize edilmesi, kalite kontrol süreçleri gibi işlemler de bu alandaki çözümlerdendir. Bu tezde de imalat alanındaki çözümlerden esinlenilerek benzer bir uygulama olan pirinç çeltiğinin çekilmesi sonucu elde edilen pirinç tanelerinin ayrıştırılması hedeflenmiştir. Zira çeltik çekiminde kullanılan makinelerin tez sonucunda elde edilecek makine öğrenme algoritmalarıyla geliştirilmesi ve ilgili makinelerin AR-GE süreci imalat mühendisliği alanının hedeflerindedir.

Pirinç bitkisi pirinç çeltiği olarak adlandırılan otsu bir bitkidir. Bitkinin pirinç olarak adlandırılan kısmı otsu kökün uçlarında bulunan tanelerdir. Bu taneler çeltiğin çekilmesi sonucu elde edilir ve bu süreç makineler yardımıyla gerçekleştirilmektedir. Pirinç tanelerinin çeltikten ayrılması sürecinde tanelerde kabuktan ayrılmama veya ayrılan tanelerde kırılma gibi istenilmeyen durumlarla karşılaşmaktadır. Yine çeltiğin çekilmesi sürecinde pirinç tanelerinden bazıları çeşitli sebeplerle olgunlaşmama, çürüme, az olgunlaşma gibi farklı sebeplerle istenilmeyen pirinç taneleri olarak sınıflandırılmaktadır. Son tüketici için elde edilecek pirinç taneleri bu istenilmeyen sebeplerin dışında

kalan ve pirinç taneleridir. İstenilmeyen pirinç taneleri ile istenilen kalitede olan pirinç tanelerinin toplama oranı çekilmiş çeltiğın kalitesini ortaya koymaktadır.

Çeltiğın çekilmesi sonucu elde edilen bu pirinç tanelerinin sınıflandırılması işlemin günümüzde el ile yapılmakta, ilgili sektörde zaman ve iş gücü kaybına neden olmaktadır. Farklı çeltik çekme yöntemleri bulunmakla beraber, sektörde çeltik çekme makinesi görevini üstlenen makinelerde bu sınıflandırma işlemi istenilen ve istenilmeyen şekilde iki tür üzerinden yürütülmektedir. Tez sonucunda elde edilen sonuçların ilgili sektördeki makinelerde farklı makine öğrenmesi yaklaşımlarının entegre edilebilir olduğunu göstermesi ve ele alınacak makine öğrenme algoritmalarının bahsi geçen işlemdeki başarı yüzdelere ışık tutması amaçlanmaktadır.

Bu tez çalışmasında pirinç çeltiğının çekilmesi sonucu elde edilen pirinç tanelerinin sınıflandırılması işlemi makine öğrenmesi yaklaşımlarından denetimli öğrenme algoritmalarıyla sağlanmıştır. Denetimli öğrenme algoritmaları sınıf etiketleri gerçekleştirilen bir makine öğrenmesi yaklaşımıdır. Halen insan gücü ile gerçekleştirilen bu işlemin tez sonucunda ilgili sektördeki iş gücü ve zaman kaybını gidermesi amaçlanmaktadır. Tezde ele alınan farklı denetimli öğrenme algoritmalarıyla bu işlemin makine öğrenmesi ile gerçekleştirilebileceği ortaya konulmuş ve bu farklı algoritmaların başarı oranları karşılaştırmalı olarak verilmiştir.

Çalışmanın ikinci bölümünde literatürde yer alan benzer uygulamalara yer verilmiştir. Üçüncü bölümde pirinç bitkisi ve çeltiğın çekilmesi süreci ile çalışmada kullanılan materyallerin hazırlanması ve veri setinin elde edilmesinde kullanılan yöntemlere değinilmiştir. Bu süreçte pirinçlerin fotoğraflanması süreci ve Sobel Kenar Bulma Algoritması yardımıyla ayrılması anlatılmıştır. Parçalanmış pirinç fotoğraflarının özelliklerinin çıkarımı ve özellik çıkarımı için kullanılan GLCM (Gray-Level Co-Occurrence Matrix) özellik vektörüne ait alt özellikler açıklanmıştır. Yine bu bölümde veri setlerinin işlendiği sınıflandırma algoritmaları ile ilgili bilgiler verilmiştir. Dördüncü bölümde elde edilen veri setlerinin denetimli öğrenme yaklaşımına ait sınıflandırma algoritmalarıyla uygulanması ve sonuçları paylaşılmıştır. Ardından son bölümde uygulama sonuçlarından hareketle yapılan değerlendirmelere yer verilmiştir.

## 2. LİTERATÜR TARAMASI

Tez konusunun disiplinler arası bir konu olması neticesinde literatür taramasında alanda yapılan çalışmaların benzer yöntemlerde ele alındığı görülmektedir. Bununla beraber veri setinin hazırlanması aşamasında özellik çıkarımı, bu tezde uygulanan makine öğrenmesi yöntemlerinin imalat ve tarımsal ürünlerin ayrıştırılması hedeflenen çalışmalarda yaygın olarak kullanıldığı görülmektedir.

Makine öğrenmesi yöntemlerinin tarımsal ürünlerin sınıflandırılmasında ilk kullanılmaya başladığı yıllar 2000’li yılların başlarıdır. İlk çalışmalarda yemeklik tahıllar, mango ve yasemin çiçekleri çeşitli özellikleri ve bu özelliklerin kombinasyonları ele alınarak sınıflandırılmaya çalışılmıştır. Bu çalışmalarda makine öğrenmesi yöntemlerinin bu problemlere çözüm getirebileceği ortaya konmuştur [3].

Tarımsal ürünlerin sınıflandırılması işleminde görüntü işleme teknikleri ve makine öğrenme yöntemleri birlikte ele alınarak yapılmış çok sayıda çalışma bulunmaktadır. Sabancı tarafından 2012 yılında yapay sinir ağları ve görüntü işleme teknikleri kullanarak patates kalite ölçümü yapılmıştır. Çalışmada patates boyutları dış yüzey bozuklukları gibi faktörler görüntü işleme ve çok katmanlı yapay sinir ağları kullanılarak tespit edilmiştir. Sınıflandırma işlemi için Matlab yazılımı kullanılmıştır. Bu çalışmada görüntü işleme aşamasında işlemlerin daha hızlı ve hatasız yapılabilmesi için siyah arka plan kullanımına vurgu yapılmıştır. Sabancı bu çalışması ile tarımsal bir ürün olan patatesin kalite kontrolü ve büyüklükleri ile ilgili makinelerin yargıya ulaşabileceklerini ortaya koymuştur [4]. Hayıt öncülüğünde bir ekip tarafından 2013’te yayımlanan “Gıda Sektöründe Uygulanan Görüntü İşleme Çalışmalarının ve Tekniklerinin İncelenmesi” başlıklı çalışmada tarımsal ürünlerin sınıflandırılması dahil gıda ile ilgili alanda dünya genelinde birçok çalışma incelenmiştir. Bu çalışmada görüntü işleme tekniklerinin kullanımında renk, doku, şekil gibi özelliklerin kullanıldığı vurgulanmıştır [5]. Diğer bir çalışmada görüntü işleme teknikleri kullanılarak elma meyvesi üzerinde leke tespiti ve renk ve boyut bakımından sınıflandırma işlemi gerçekleştirilmiştir. 201 elma fotoğrafının kullanıldığı çalışmanın başarı yüzdesi renk sınıflandırması için %99, boyut sınıflandırması için %95,52’dir. [6]

Başka bir çalışmada makine öğrenmesi yaklaşımlarından Destek Vektör Makineleri’nin farklı yaklaşımları kullanılmış ve toplamda 1653 meyve fotoğrafının bulunduğu veri setinden faydalanılarak 18 farklı meyve türünün sınıflandırılması gerçekleştirilmiştir. Bu çalışmada en başarılı ayırıcı karar fonksiyonu Gauss radyal fonksiyonu olmuştur. Gauss radyal fonksiyonu ayırıcı fonksiyon olarak ele alınan destek vektör makinesi yönteminin başarı oranı %88,2 olarak ölçülmüştür [7].

Yine görüntü işleme teknikleri kullanılarak 2016 yılında Ataş tarafından Siirt Üniversitesi’nde “Fıstık sınıflandırma sistemi için Siirt fıstığı imgelerinden gürbüz özniteliklerin çıkarılması” başlıklı çalışmada Siirt Fıstığı’nın sınıflandırılması işleminde yapay sinir ağlarından faydalanılmış ve %83 başarı oranı elde edilmiştir [8]. Balcı ve arkadaşları 2016 yılında yayımlanan bir diğer çalışmada Napolyon tipi kirazların sınıflandırılmasını görüntü işleme teknikleri kullanarak gerçekleştirmişlerdir. Çalışmada kirazlara özel öznitelik oluşturmuş ve sınıflandırma işlemi bu şekilde gerçekleştirilmiştir [9].



Diğer bir çalışma da Solak ve Altunışık tarafından 2018 yılında gerçekleştirilmiştir. Bu çalışmada fındık taneleri kapladıkları alan ve boyutlarına göre küçük, orta ve büyük olmak üzere üç farklı sınıfa ayrılmıştır. Makine öğrenmesi yöntemlerinden K En Yakın Komşu Algoritması'nın kullanıldığı çalışmanın başarı oranı %100'dür [10].

Görüntü işleme tekniklerinin tarımsal ürünlerin sınıflandırılması dışında kalite kontrolünde de kullanıldığı çalışmalar mevcuttur. Bul ve arkadaşları bu iş için tarımsal ürün olarak seçilen fasulyeleri kullanmışlar ve fasulyeleri iyi kalite veya kötü kalite olarak sınıflandırmışlardır. Fasulye görüntülerinin video olarak hareketli biçimde elde edildiği ve ikili parametre karşılaştırma ile yapay sinir ağları kullanılarak iki farklı yöntemin denendiği çalışma Matlab ortamında gerçekleştirilmiş başarı oranı %93 bulunmuştur [11].

Ikhisawa önderliğindeki ekibin 2018 yılında yayımlanan çalışmalarında çilek meyvesi şekil yönünden ele alınarak sınıflandırılmış ve çalışmada çilek meyvesi için önceden belirlenen 7 farklı şekle göre bu işlem gerçekleştirilmiştir. Çalışmanın diğer tarımsal ürünlere esin kaynağı olması düşüncesinin altı Ikhisawa ve arkadaşları tarafından çizilmiştir [12].

Özellikle son yıllarda görüntü işleme üzerine yapılan çalışmalarda Derin Öğrenme Yöntemi ve bu yöntemin atası olan Evrişimsel Sinir Ağları'nın kullanımı yaygınlaşmıştır. Tıbbi görüntülerin işlenmesi alanında Claesson ve Hansson tarafından 2015 yılında Chalmers Teknoloji Üniversitesi İletişim Mühendisliği ve Biyomedikal Mühendislik Bölümü'nde bir yüksek lisans tez çalışması gerçekleştirilmiştir. "Trafik Işıklarının Sınıflandırılması ve Alzheimer Hastalığının Resimlerden Tespiti" başlığıyla yayımlanan çalışmada, sağlıklı beyin hücreleri ile daha önceden Alzheimer teşhisi konulan beyin hücrelerinden oluşan bir veri seti kullanılmıştır. Çalışma sonucunda hastalığın teşhisinin %98.90 oranında tespit etme başarısı ortaya konulmuştur [13]. 2016 yılında "DeepFruits: A Fruit Detection System Using Deep Neural Networks" adında bir çalışma yayımlanmıştır. Çalışmanın amacı farklı meyve türlerini Evrişimsel Sinir Ağları kullanarak sınıflandırma, bu sınıflandırma işleminin performansını en üst düzeye ulaştırmak amacıyla ağı optimize edilmesi şeklindedir. Çalışma ile daha önceden aynı ekibin gerçekleştirdiği diğer çalışmada elde edilen %80,7'lik başarı oranını %83,8'e taşımıştır [14].

Türkiye'de hem imalat alanında hem de tarımsal ürünlerin sınıflandırılması işlemlerinde Derin Öğrenme Yöntemi kullanılan çalışmalar mevcuttur. Şeker ve Yüksek'e ait 2017 yılında yayımlanan bir çalışmada derin öğrenme yöntemi imalat sektöründe karşılaşılan kumaş hatası tespitinde uygulanmış ve %96'lık bir başarı elde edilmiştir. Bu çalışmada ulaşılan önemli bir husus da derin öğrenme yöntemi için hazırlanan modelin hiper parametrelerinin ince ayarının hazırlanan veri setinde başarı oranı arttırdığı sonucudur [15]. Aynı yıl Razavi ve Yalçın tarafından yayımlanan bir diğer çalışmada, bu tezde ele alınan problem ve yöntemlere çok benzer olarak tohum sınıflandırılması işlemi Evrişimsel Sinir Ağları kullanılarak gerçekleştirilmiştir. Zira Evrişimsel Sinir Ağları tezde uygulanan Derin Öğrenme Yöntemi'ne temel oluşturması bakımından önemlidir. Buna ek yayımlanan çalışmalarında Rezavi ve Yalçın sınıflandırma işleminde Evrişimsel Sinir Ağları ile Destek Vektör Makineleri ile elde edilen

sonuçları karşılaştırılmışlardır. Çalışmaları Türkiye’de yer alan 1200’den fazla tarımsal istasyonun yerleştirildiği devlet destekli bir proje olan TARBIL aracılığıyla toplanan veri seti üzerinden gerçekleştirilmiştir [16].



### 3. MATERYAL VE YÖNTEM

#### 3.1. Materyal

Çalışmada pirinç çeltiğinin çekilmesi sonucu harman şeklinde elde edilen pirinç kullanılmıştır. Bu pirinçler önce kırık ve tam pirinçler olmak üzere durumlarına göre ikiye ayrılmış, hem kırık hem de tam pirinçler birinci kalite, ikinci kalite, az çekilmiş, çekilmemiş ve çürümüş veya olgunlaşmamış pirinçler olarak 5 kategoride ele alınmıştır.

##### 3.1.1. Pirinç Bitkisi

Buğdaygiller familyasından otsu bir bitki türü olan pirinç besin değeri yüksek ve nişasta yönünden zengin bir tahıl türüdür (Tablo 2.1). Bilimsel adı *Oryza*'dır. Dünyada kırktan fazla pirinç türü bulunmakla beraber en yaygın pirinç türleri Asya Pirinci (*Oryza Sativa*) ve Afrika Pirinci'dir (*Oryza Glaberrima*). Birleşmiş Milletler Yiyecek Ve Tarımsal Ürünler Organizasyonu (Food And Agriculture Organization Of The United Nations) verilerine göre 741,5 milyon ton ile 2014 yılında şeker kamışı ve mısırdan sonra dünyada en çok üretilen üçüncü tarımsal üründür [17]. Şeker kamışı ve mısır farklı amaçlarla da kullanıldığı için, insanlar tarafından dünyada tüketilen kalorilerin beşte birinden fazlası pirinçten sağlanmaktadır. Bu açıdan pirinç insan beslenmesi ve kalori alımı açısından en önemli tahıldır [18].

**Tablo 2.1.** 100 gram pirincin besin değerleri [19].

<b>Besin</b>	<b>100 gram pirinçte</b>
Su (g)	12
Enerji (kJ)	1528
Protein (g)	7,1
Yağ (g)	0,66
Karbonhidratlar (g)	80
Elyaf (g)	1,3
Şeker (g)	0,12
<b>Mineraller</b>	
Kalsiyum (mg)	28
Demir (mg)	0,8
Magnezyum (mg)	25
Fosfor (mg)	115
Potasyum (mg)	115
Sodyum (mg)	5
Çinko (mg)	1,9
Bakır (mg)	0,22
Manganez (mg)	1,9
Selenyum (µg)	15,01
<b>Vitaminler</b>	
C vitamini (mg)	0
Tiamin (B1) (mg)	0,07
Riboflavin (B2) (mg)	0,05
Niasin (B3) (mg)	1,6
Pantotenik asit (B5) (mg)	1,01
B6 Vitamini (mg)	0,16
Folate Toplamı (B9) (µg)	8
A vitamini (IU)	0
E vitamini , alfa-tokoferol (mg)	0,11
K1 Vitamini (µg)	0,1
Beta karoten (µg)	0
Lutein + zeaksantin (µg)	0
<b>Yağlar</b>	
Doymuş yağ asitleri (g)	0,18
Tekli doymamış yağ asitleri (g)	0,21
Çoklu doymamış yağ asitleri (g)	0,18

Pirinç bitkisinin tohumları tipik olarak embriyonik bir yaprak ve kotiledon içerir. Bu yapısı nedeniyle bilimsel olarak monokotiledon olarak sınıflandırılır. Diğer bütün monokotiledonlar gibi pirinç de otsu bir kökte büyür ve tohumu olgunlaşınca bitkiden ayrılır. Pirincin bu otsu kökü çeltik olarak adlandırılmaktadır (Şekil 3.1). Her bir pirinç çeltiği kendi üzerinde pirinç tahılının olgunlaşmasını sağlar ve olgunlaşma sonucu çeltiğin çekilmesiyle pirinç elde edilir.



Şekil 3.1. Bir Asya pirinç çeltiği ve üzerinde olgunlaşmış pirinç taneleri [20].

### 3.1.2. Pirinç Çeltiğinin Çekilmesi

Pirinç çeltiğinin çekilmesi makine yardımı ile olmaktadır. Dünyada farklı markalar tarafından patentlenmiş çeltik çekme makineleri mevcuttur. Bazı çeltik çekme makineleri sadece pirinci kabuğundan ayırma işlemini gerçekleştirmekte ama sınıflandırma işlemini gerçekleştirmemektedir. Bu makinelere çeltik soyma makinesi adı verilmektedir. Soyma işlemi birbirine zıt, yönleri ve hızları farklı iki adet silindirin arasından geçirilmek üzere gerçekleştirilmektedir. Bu aşamada elde edilen soyulan kabuk ve kabuğundan ayrılan pirinç taneleri karışımı sonraki aşamada hava kanalında hava akımına maruz bırakılmakta ve kabuğun karışımdan ayrılması sağlanmaktadır. Soyulan kabuğun pirinç tanelerinden ayrımı hava kanalından Bu makinelerin ilk aşaması Bu makinelerin genel sınıflandırması

istenilen pirinç taneleri ve istenilmeyen pirinç taneleri şeklindedir. Pirinç tanelerinin kabuğundan ayrılmamış ve kırılmış olanları bu aşamada uygulanan işlemler sonucu oluşmaktadır [21].

Bu makinelerdeki ayırım mantığı pirincin ağırlığına göredir. Mantiğa göre kabuğu ayrılmayan veya olgunlaşmayan pirinç taneleri daha ağır, istenilen pirinç taneleri daha hafif olmaktadır. Ayırım işlemi kabuğun karışımından ayrılmasından sonra gerçekleştirilir ve anlaşıldığı üzere sınıflandırma iki tür şeklinde gerçekleştirilir.

İki türde de elde edilen kırık pirinç tanelerinin, kırılmamış pirinç tanelerinden ayrılması işlemi sonraki aşamada pirinç tanelerinin elenmesi ile gerçekleştirilir. Eleme yöntemi pirinç gibi kotiledon tohum olarak sınıflandırılan tarım ürünlerinin hem kendi aralarında boyutlarına göre hem de taş, toprak, metal, cam, plastik gibi diğer yabancı maddelerden ayrıştırılması işlemlerinde kullanılan en yaygın yöntemdir.

Genel olarak çeltik çekim sürecinde pirinç taneleri en başta kabuğun ayrılma sürecinden itibaren istenilmeyen şekillerde sonuçlanabilir. Kabuğun ayrılmamasına ve istenilen kalitede olmamasına pirincin olgunlaşmaması, yetiştirme sürecinde zararlı parazitlerin konaklaması, çeltiğin az su alması ya da istenenden fazla su içermesi, çeltiği çeken makine kaynaklı hatalar ve diğer istenmeyen durumlar sebep olabilir.


Çeltik soyma makinelerinde iki tür sınıflandırma mevcutken gerçek hayatta pirinç çeltiğinin çekilmesi sonucu kabuğundan ayrılan pirinç taneleri, birinci kalite, ikinci kalite, az çekilmiş, çekilmemiş ve çeşitli nedenlerle olgunlaşmamış veya çürümüş taneler şeklinde beş türde sınıflandırılmak istenmektedir. Zira sınıflandırılan tanelerin sayısının ürünün geneline katkısı (oran) ürünün kalitesini ve birim fiyatını belirlemektedir. Tezde bu beş sınıflandırma temel alınmıştır.

### 3.1.3. Pirinçlerin Fotoğraflanması

Çalışmada 7522 adet pirinç fotoğraflanmıştır. Pirinçler tür ve durumlarına göre ayrılmıştır. Fotoğraflama işleminde CANON marka EOS 700D model fotoğraf makinesi kullanılarak aşağıdaki ayarlarla fotoğraflanmıştır (Tablo 3.1). Fotoğraflanma aşamasında flaş kullanılmamış ışıklandırma yapay ışık kaynağı ile gerçekleştirilmiştir. Her bir fotoğrafta rastgele seçilmiş pirinçler siyah plaka zemin üzerine rastgele yerleştirilmiş ve fotoğraf makinesinin objektifi plakanın merkezine 35 cm uzaklıkta olacak şekilde sabit konumlandırılmış ve fotoğraflama işlemi gerçekleştirilmiştir. Fotoğraflar makinenin görüntü üzerinde herhangi bir işlem yapmaması için işlenmemiş (RAW) formatta çekilmiştir.

**Tablo 3.1.** Fotoğraflamada Kullanılan Ayarlar


Özellik	Değer
Hız	ISO-100
F Durağı	5.6
Poz Süresi	1/20 saniye
Pozlandırma	Manuel
Odak Uzunluğu	124

**Şekil 3.2.** Plaka üzerinde fotoğraflanmış 30 adet birinci kalite pirinç

Tez için bu şekilde (Şekil 3.2) 213 fotoğraf çekilmiş, bu fotoğraflarda 7522 adet pirinç yer almıştır.

### 3.1.3.1. Tam (Kırılmamış) Pirinçler

Tez için fotoğraflanan pirinçlerden tam olan pirinçler Birinci Kalite (Şekil 3.3), İkinci Kalite (Şekil 3.4), Az Çekilmiş (Şekil 3.5), Çekilmemiş (Şekil 3.6) ve Çürümüş veya Olgunlaşmamış (Şekil 3.7) olmak üzere beş sınıfta ele alınmıştır.



Şekil 3.3. Fotoğraflanmış birinci kalite tam pirinçler



Şekil 3.4. Fotoğraflanmış ikinci kalite tam pirinçler



Şekil 3.4. Fotoğraflanmış az çekilmiş tam pirinçler






Şekil 3.5. Fotoğraflanmış çekilmemiş tam pirinçler



Şekil 3.6. Fotoğraflanmış olgunlaşmamış veya çürümüş tam pirinçler

### 3.1.3.2. Kırık (Tam Olmayan) Pirinçler

Yine çeltiğin çekilmesi sonucu elde edilen pirinçler çeşitli sebeplerle kırılabilir. Bu pirinçler de kırık pirinçler olarak adlandırılmaktadır. Bu durum ürünün kalitesini etkilemektedir. Tez için fotoğraflanan pirinçlerden kırık olan pirinçler Birinci Kalite (Şekil 3.7), İkinci Kalite (Şekil 3.8), Az Çekilmiş (Şekil 3.9), Çekilmemiş (Şekil 3.10) ve Çürümüş veya Olgunlaşmamış (Şekil 3.11) olmak üzere beş sınıfta ele alınmıştır.



Şekil 3.7. Fotoğraflanmış birinci kalite kırık pirinçler



Şekil 3.8. Fotoğraflanmış ikinci kalite kırık pirinçler



Şekil 3.9. Fotoğraflanmış az çekilmiş kırık pirinçler



Şekil 3.10. Fotoğraflanmış çekilmemiş kırık pirinçler



Şekil 3.11. Fotoğraflanmış çürümüş veya olgunlaşmamış kırık pirinçler

### 3.1.4. Fotoğraflanmış Pirinçlerin Ayrılması

Toplu fotoğraflanmış pirinç gruplarının ayrılması için Matlab üzerinde hazırlanan scriptte Sobel Kenar Bulma Algoritması kullanılmıştır. Derin Öğrenme Yöntemi için de 600x600 piksellik kare biçiminde bir çerçeve üzerinden her pirinç tanesi merkezde kalacak şekilde standart boyutlu olarak pirinçler ayrıca ayrılmıştır.

#### 3.1.4.1. Sobel Kenar Bulma Algoritması

Sobel Kenar Bulma Algoritması en çok kullanılan kenar bulma algoritmasıdır. Bu algoritma 2 temel kernel matrisinin (Tablo 3.2) alınması ve bu matrislerin toplanması sonucu bulunan değerlerin karekökü alınması esasına dayanır. Bu işlem resimdeki her bir nokta için gerçekleştirilir ve her bir nokta için ışık geçişinin değişimine göre söz konusu şeklin kenarının bulunması sağlanır [32].

**Tablo 3.2.** Sobel Kenar Bulma Algoritması'nda Kullanılan Kernel Matrisleri


-1	0	1	1	2	1
-2	0	2	0	0	0
-1	0	1	-1	-2	-1

Dikkat edilirse iki matris birbirinin yatay ve dikey yönde çevrilmiş şekindedir. Bu matrisler 3x3'lüktür. Bu matrislerin kullanım sebebi bu hesaplama işleminin daha hızlı gerçekleştirilebilmesidir. Eğer işlem hızında düşüş önemsenmezse daha büyük matrislerle aynı işlemler gerçekleştirilebilir. Bu durumda 3x3'lük matrislerin kullanımına göre daha yavaş ama başarılı sonuçlar elde edilebilir.


Örnek verecek olursak Gupta ve Mazumdar'a ait çalışmada siyah beyaz tonlamalı papatya çiçeği resmine (Şekil 3.12), ilkinde 3x3'lük (Şekil 3.13), ikincisinde 5x5'lik (Şekil 3.14) matrislerle Sobel Kenar Bulma Algoritması uygulanmış ve aşağıdaki sonuçlar elde edilmiştir [32].



**Şekil 3.12.** Siyah Beyaz Tonlamalı Papatya Çiçeği




Şekil 3.13. Şekil 3.12'ye 3x3'lük matrisle Sobel Kenar Bulma Algoritması Uygulanması Sonucu



Şekil 3.14. Şekil 3.12'ye 5x5'lik matrisle Sobel Kenar Bulma Algoritması Uygulanması Sonucu

Fotoğraflanan her bir plaka için kenar bulma işlemi uygulanmış ve aşağıdaki şekilde pirinç tanelerinin konumları tespit edilmiş ve parçalanmaya hazır hale getirilmiştir (Şekil 3.15).



Şekil 3.15. Sobel Kenar Bulma Algoritması Uygulanarak Plaka Üzerinde Fotoğraflanmış Pirinç Tanelerinin Tespiti (Yeşil Çizgi İle Seçilmişlerdir)

Konumları belirlenen pirinç taneleri ayrılmış ve özellik çıkarımı işlemine hazır hale getirilmiştir (Şekil 3.16).



Şekil 3.16. Plakalardan Parçalanmış Farklı Türlerde Pirinçlerin Fotoğrafları

#### 3.1.4.2. Derin Öğrenme Yöntemi İçin Pirinçlerin Standart Boyutlu Parçalanması

Derin Öğrenme Yöntemi'nde veri setinin fotoğrafları standart boyutta olmak zorundadır. Bu yüzden bütün pirinçlerin en büyük boyutlusu tespit edilmiştir. En büyük boyutlu pirincin eni 552 ve boyu 483 piksel bulunmuştur. Buradan hareketle 600x600 piksellik kare biçiminde bir çerçeve üzerinden her pirinç tanesi merkezde kalacak şekilde derin öğrenme için standart boyutlu bir veri seti hazırlanmıştır.

Derin Öğrenme için hazırlanan bu pirinçler, arkaplanı plaka olduğu için diğer ağlarda hem performansın hem de işlem süresinin kayba uğrayacağı düşünülerek sadece Derin Öğrenme Yöntemi için hazırlanan modelde kullanılmıştır.

#### 3.1.5. Pirinçlerin Tür Ve Durumlarına Göre Dağılımları

Pirinçler tür ve durumlarına göre ayrılmıştır. Her bir pirinç türünün tam veya kırık olması durumuna göre kodu belirlenmiştir. Elde edilen 7522 adet pirincin türleri ve durumlarına göre dağılımı şu şekildedir (Tablo 3.3).

**Tablo 3.3.** Pirinçlerin Tür Ve Durumlarına Göre Dağılımı

Tür	Durum	Adet	Kodu	Yüzde (%)	Grafiklerde	
					Rengi	Göstergesi
Birinci Kalite	Tam	1025	IT	13,63	Siyah	○ (Çember)
	Kırık	875	IK	11,63	Siyah	△ (Üçgen)
İkinci Kalite	Tam	442	TT	5,88	Sarı	○ (Çember)
	Kırık	186	TK	2,47	Sarı	△ (Üçgen)
Az Çekilmiş	Tam	882	YT	11,73	Yeşil	○ (Çember)
	Kırık	227	YK	3,02	Yeşil	△ (Üçgen)
Çekilmemiş	Tam	1004	KT	13,35	Kırmızı	○ (Çember)
	Kırık	911	KK	12,11	Kırmızı	△ (Üçgen)
Olgunlaşmamış veya çürümüş	Tam	965	KOT	12,83	Mavi	○ (Çember)
	Kırık	1005	KOK	13,36	Mavi	△ (Üçgen)

Elde edilen 7522 adet pirincin türlerine göre dağılımı şu şekildedir (Tablo 3.4).

**Tablo 3.4.** Pirinçlerin Türlerine Göre Dağılımı

Tür	Adet	Kodu	Yüzde (%)	Grafiklerde Rengi
Birinci Kalite	1900	I	25,26	Siyah
İkinci Kalite	628	T	8,35	Sarı
Az Çekilmiş	1109	Y	14,74	Yeşil
Çekilmemiş	1915	K	25,46	Kırmızı
Olgunlaşmamış veya çürümüş	1970	KO	26,19	Mavi

Elde edilen 7522 adet pirincin durumlarına göre dağılımı şu şekildedir (Tablo 3.5).

**Tablo 3.5.** Pirinçlerin Durumlarına Göre Dağılımı

Durum	Adet	Kodu	Yüzde (%)	Grafiklerde Göstergesi
Tam	4318	Tam	57,4	○ (Çember)
Kırık	3204	Kirik	42,6	△ (Üçgen)

### 3.1.6. Özellik Çıkarımı

Özellik çıkarımında parçalanmış pirinçlerin en boy değerleri, muhtemel boyutları (piksel ölçeğinde), farklı renk uzaylarında renkli ve binarize edilmiş değerleri ve GLCM (Gray-Level Co-Occurrence Matrix) özellik vektörü kullanılmıştır.


### 3.1.6.1. Pirinçlerin Boyutları

Parçalanmış pirinçlerin boyutları alınırken her bir parçanın piksel türünden en (**riceSizeWidth**) ve boy (**riceSizeHeight**) değerleri alınmış ve bu değerlerin çarpımından pirinç resimlerinin boyutları (**riceSize**) bulunmuştur.

Buna ek her bir pirincin plaka üzerinde kalan kısmı daha önceden belirlenmiş kenarları dışında kalan kısımlar çıkarılarak piksel türünden pirincin muhtemel boyutu (**riceApproximateSize**) tespit edilmiştir.

### 3.1.6.2. RGB (Red Green Blue) Renk Uzayı

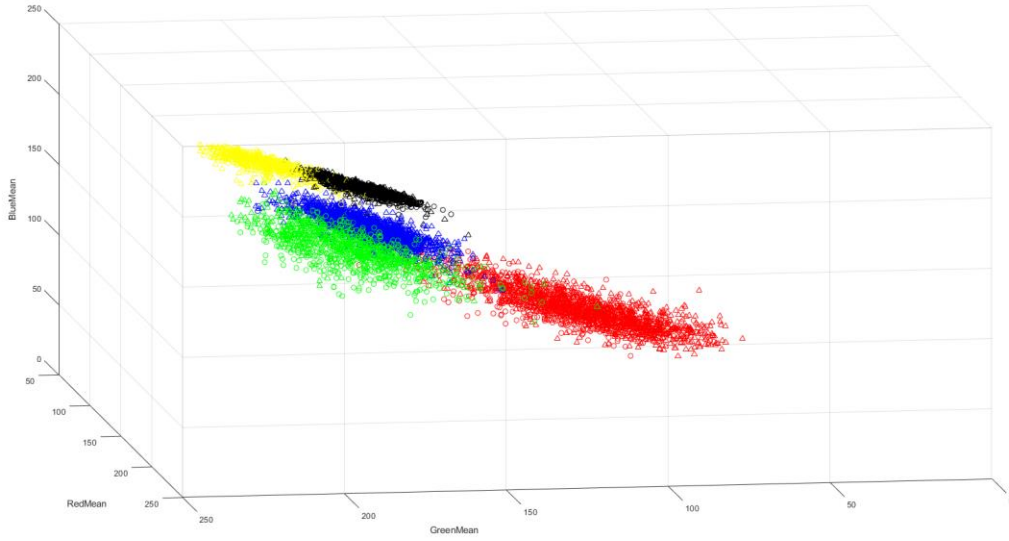
Kırmızı (Red), Yeşil (Green), Mavi (Blue) renklerin ana renk kabul edilerek oluşturulmuş renk uzayıdır (Şekil 3.17). Günümüz televizyon, kamera, tarayıcılar gibi aygıtlarda kullanılan en yaygın renk standardıdır. Tarihi 1861 yılında JC Maxwell tarafından yapılan renkli fotoğraf çalışmalarına dayanır. (Hirsch, 2004) Görüntünün her bir pikseli üç ana renk üzerinden oluşturulur. Her bir renk değeri 0 ile 255 arasında bir değer almaktadır.



Şekil 3.17. RGB Renk Uzayı [23].

Pirinç fotoğraflarının RGB renk uzayına göre kırmızı değerlerinin ortalaması (**RedMean**), yeşil değerlerinin ortalaması (**GreenMean**), mavi değerlerinin ortalaması (**BlueMean**) hesaplanmıştır (Grafik 3.1).





**Grafik 3.1.** Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin RGB Renk Uzayında Dağılımı (Gösterge İçin Tablo 3.3)

Yine fotoğrafların gri tonlamalı dönüşümleri gerçekleştirilmiş ve kırmızı (**RedBinarizeMean**), yeşil (**GreenBinarizeMean**) ve mavi (**BlueBinarizeMean**) değerlerinin gri tonlamalı değerlerinin ortalamaları alınmıştır. Fotoğrafların gri tonlamalı dönüşümünde aşağıdaki formül kullanılmıştır [24].

$$Y = 0,2126R + 0,7152G + 0,0722B$$


Fotoğraflarda gri tonlamalı değerlerin alınmasının sebebi pirinçlerin fotoğraflandığı plakanın siyah olmasıdır.

### 3.1.6.3. HSL (Hue Saturation Lightness) Ve HSV (Hue Saturation Value) Renk Uzayları


RGB renk uzayına alternatif olarak 1970'lerde geliştirilmiştir. Geliştirilmesindeki temel amaç RGB renk uzayına kıyasla insan gözünün renk algılama biçimine daha yakından uyum sağlamaktır. Bu renk uzayında genel biçim kübik değil radyaldır. Ana renkler yine kırmızı, yeşil ve mavidir. Fakat ana renkler bir kübün köşelerinde değil bir çemberin üç bölünmüş aralıklarında dağıtılmıştır. Yani kırmızı  $0^0$ , yeşil  $120^0$ , mavi  $240^0$  şeklinde açısız boyutlarda bulunurlar. Bu çember bir silindir içindedir. Silindirin zemini tam siyahtır [25].

HSL renk uzayında silindirin tepesi tam beyazdır. Hue değeri renkler arası değişimi, Saturation değeri rengin doygunluğunu, Lightness değeri parlaklığını belirler. Hue değeri silindirin çevresi iken, Saturation yarıçapı, Lightness uzunluğu ile ölçülür (Şekil 3.18).

HSV renk uzayında silindirin merkezi tam beyazdır. Hue değeri silindirin çevresi iken, Saturation yarıçapı, Value uzunluğu ile ölçülür. Hue değeri renkler arası değişimi, Saturation değeri rengin doygunluğunu, Value değeri Hue değerinin belirlediği renk ile tam siyah arasındaki renk geçişini belirler (Şekil 3.19).




Şekil 3.18. HSL Renk Uzayı [23].




Şekil 3.19. HSV Renk Uzayı [23].

HSL ve HSV renk uzayı arasındaki farkın oluşmasındaki temel sebep, HSL renk uzayında rengin parlaklığının siyah beyaz arası belirlenmesi, HSV renk uzayında rengin karanlıktan renge gelen aralıklarda belirlenebilmesidir.

Pirinç fotoğraflarının HSL ve HSV renk uzaylarına göre Hue değerlerinin ortalaması (**HueMean**), Saturation değerlerinin ortalaması (**SaturationMean**), Lightness değerlerinin ortalaması (**LightnessMean**), Value değerlerinin ortalaması (**ValueMean**) hesaplanmıştır (Grafik 3.2 ve Grafik 3.3).



**Grafik 3.2.** Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin HSL Renk Uzayında Dağılımı (Gösterge İçin Tablo 3.3)



**Grafik 3.3.** Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin HSV Renk Uzayında Dağılımı (Gösterge İçin Tablo 3.3)


Yine fotoğrafların gri tonlamalı dönüşümleri gerçekleştirilmiş ve Hue (**HueBinarizeMean**), Saturation (**SaturationBinarizeMean**), Lightness (**LightnessBinarizeMean**) ve Value (**ValueBinarizeMean**) değerlerinin gri tonlamalı değerlerinin ortalamaları alınmıştır.

#### 3.1.6.4. CIEXYZ Renk Uzayı

Uluslararası Aydınlatma Komisyonu (Commission Internationale de l'éclairage, kısaca CIE) tarafından 1931 yılında tanımlanmış renk uzayıdır. İnsan gözü ile görünür spektrumdaki dalga boylarının dijital görüntülerde oluşturulması amacıyla geliştirilmiş ilk renk uzayıdır. Diğer bilinen adı CIE1931'dir.


İnsan gözünün ışığı algılayan üç tür koni hücresine sahip olması ve bu hücrelerin farklı dalga boylarını algılaması durumundan esinlenilerek tasarlanmıştır. Bu dalga boyları LMS (Long, medium, short) olarak adlandırılır. Bir nesneden yansıyan ışık insan gözünün çoğu zaman iki ve bazen üç dalga boyunu algılayan konilerini uyarır. Bu durumdan etkilenecek yapılan çalışmalarda CIE renklerin dalga boylarının üç boyutlu düzlemdeki koordinatları üzerinden CIEXYZ renk uzayını geliştirmiştir (Şekil 3.20).

Bu renk uzayı görünür renklerden oluşur ve oluşturulabilen renkler sınırlıdır.



Şekil 3.20. CIEXYZ Renk Uzayı [26].

Pirinç fotoğraflarının CIEXYZ renk uzayına göre X değerlerinin ortalaması (**XMean**), Y değerlerinin ortalaması (**YMean**) ve Z değerlerinin ortalaması (**ZMean**) hesaplanmıştır (Grafik 3.4).



Grafik 3.4. Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin CIEXYZ Renk Uzayında Dağılımı (Gösterge İçin Tablo 3.3)

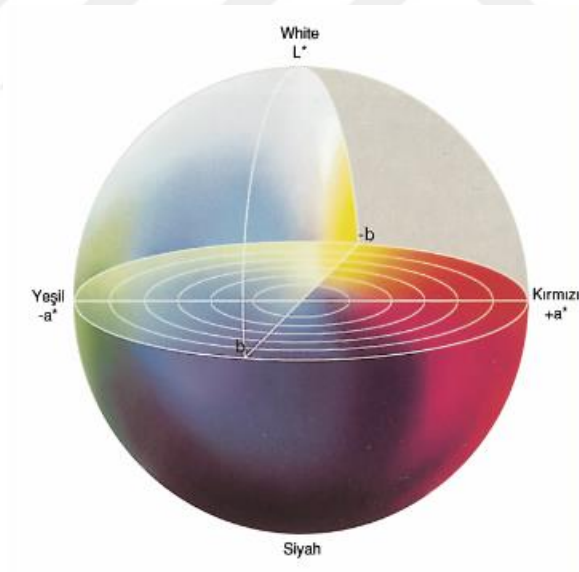
Yine fotoğrafların gri tonlamalı dönüşümleri gerçekleştirilmiş ve X (**XBinarizeMean**), Y (**YBinarizeMean**) ve Z (**ZBinarizeMean**) değerlerinin gri tonlamalı değerlerinin ortalamaları alınmıştır.

### 3.1.6.5. CIELAB (CIEL\*a\*b\*) Renk Uzayı

CIEXYZ renk uzayının devamında geliştirilmiştir. Uluslararası Aydınlatma Komisyonu (Commission Internationale de l'éclairage, kısaca CIE) tarafından 1976 yılında tanımlanmış renk uzayıdır. Renklerin nasıl görüntülediklerinden ve nasıl oluşturulduklarından bağımsız olma hedefiyle tasarlanmıştır. CIELAB renk uzayının renk gamı hem RGB hem de baskı için kullanılan CMYK renk uzayının renk gamlarını içerdiği için dijital görüntülerin baskı için dönüşümünde ara formül olarak kullanılır [27].


CIELAB renk uzayı  $L^*$ ,  $a^*$ ,  $b^*$  şeklinde üç temel değer ile kodlanır.  $L^*$  değeri 0 tam siyah 100 tam beyaz olacak şekilde 0 ile 100 arası bir değerdir.  $a^*$  değeri -100 değeri ile yeşil ve +100 değeri ile kırmızı verecek şekilde iki renk arası geçişleri içerir.  $b^*$  değeri -100 değeri ile mavi ve +100 değeri ile sarı verecek şekilde iki renk arası geçişleri içerir. Bazı durumlarda  $a^*$  ve  $b^*$  değerleri +128 ile -127 (8bit veya 1 byte) arası değerlendirilebilir. Buna temel sebep dijital görüntü oluşumundaki 1 bytelik değer aralığıdır (Şekil 3.21).

CIELAB renk uzayında  $a^*$  ve  $b^*$  değerleri belirtilen aralıklar dışında da değer alabilir. Dolayısıyla bir sınırlama yoktur. Bu sınırsız değer aralığı CIELAB renk uzayında insan algısı dışında renk oluşturabilme kabiliyeti sunar.



Şekil 3.21. CIELAB Renk Uzayı [27].

Pirinç fotoğraflarının CIELAB renk uzayına göre  $L^*$  değerlerinin ortalaması (**LMean**),  $a^*$  değerlerinin ortalaması (**AMean**) ve  $b^*$  değerlerinin ortalaması (**BMean**) hesaplanmıştır (Grafik 3.5).



**Grafik 3.5.** Tezde Kullanılan Pirinç Tanelerine Ait Renk Değerlerinin CIELAB Renk Uzayında Dağılımı (Gösterge İçin Tablo 3.3)

Yine fotoğrafların gri tonlamalı dönüşümleri gerçekleştirilmiş ve  $L^*$  (**LBinarizeMean**),  $a^*$  (**ABinarizeMean**) ve  $b^*$  (**BBinarizeMean**) değerlerinin gri tonlamalı değerlerinin ortalamaları alınmıştır.

### 3.1.6.6. GLCM (Gray-Level Co-Occurrence Matrix) Özellik Vektörü

GLCM (Gray-Level Co-Occurrence Matrix), bir görüntünün gri tonlamalı dönüşümü üzerinde farklı piksellere ait parlaklık değerlerinin ne sıklıkta gerçekleştiğine ait bir tablolama imkânı veren özellik vektörüdür [28]. İlk olarak 1973 yılında Haralick'in çalışmasıyla ortaya çıkmıştır. En güncel hali Mryka Hall-Beyer'in 2017 Mart'ında yayımlanmıştır. Bu özellik vektörü görüntü üzerinde farklı hesaplamalar yapılmasıyla görüntüye ait özellikleri barındırır.

GLCM özellik vektörü birebir özellikleriyle veri setinde yer almıştır.

GLCM bazı özelliklerin hesaplanmasında GLCM Ortalaması adı verilen bir değeri referans alır. GLCM Ortalaması bir pikselin belirli bir komşu değeri ile oluşma sıklığına göre bulunur. Referans pikselin (i) ve komşu pikselin (j) GLCM Ortalaması ayrı ayrı hesaplanır [29]. Formülü şu şekildedir.

$$\mu_i = \sum_{i,j=0}^{N-1} i(P_{i,j}) \quad \mu_j = \sum_{i,j=0}^{N-1} j(P_{i,j})$$

**Autocorrelation (Otokorelasyon)**

Piksellerin uzaktaki komşularına göre yakın komşuları daha yüksek korelasyon değeri verir. Bu durum küçük görüntülerin daha büyük korelasyon değeri döndürmesine neden olur. Otokorelasyon ve korelasyon değerinin karşılaştırılmasıyla bu durum hakkında fikir yürütülebilir [29]. Otokorelasyon dokunun kabalığı ile ilgili bilgi verir.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ij p(i, j)$$

**Contrast (Kontrast)**

İki piksel arası renk değişimi ya da parlaklığın değişimini verir. GLCM için aşağıdaki formülle hesaplanır.

$$\sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2$$

Her bir pikselin bir sonraki piksele göre farkının kareleri toplamıdır. Diğer bir deyişle kareler toplamının varyansıdır [29].

**Correlation (Korelasyon)**

Bir referans pikselin komşu pikselle doğrusal ilişkisini gösterir [29]. Toplamları korelasyonu verir.

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[ \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$$

**ClusterProminence (Küme Önemi)**

Görüntünün asimetrikliği hakkında bilgi verir. Yüksek değer asimetriyi gösterirken düşük değer ortalama etrafında dağılmış bir görüntü olduğuyla ilgili fikir verir [30].

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ((i - \mu) + (j - \mu))^4 p(i, j)$$

### ClusterShade (Gölge Kümesi)

Görüntünün eğriliğini ölçer. Algısal olarak tekdüzelik var mı yok mu bu durum hakkında bilgi verir. Değerin yüksek olması asimetrikliği gösterir [30].

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ((i - \mu) + (j - \mu))^3 p(i, j)$$

### Dissimilarity (Farklılık)

İki piksel arası farkın mutlak değerlerinin toplamıdır. Kontrastın bulunmasına kıyasla karesi alınmadığı ve mutlak değeri alındığı için farklılıkların doğrusal olarak sonuç verdiği değerdir [29]. Görüntünün gri seviye farkını ölçer. Değerin büyüklüğü komşu pikseller arasında yoğunluk değerlerinde daha fazla eşitsizlik olduğunu gösterir.

$$\sum_{i,j=0}^{N-1} P_{i,j} |i - j|$$

### Energy (Enerji)

Görüntü içindeki piksellerin düzenlilik durumu hakkında bilgi verir. Düzenlilik arttıkça enerji değeri artar [29]. Aşağıdaki formülün karekökü alınarak bulunur.

$$\sum_{i,j=0}^{N-1} P_{i,j}^2$$

### Entropy (Entropi)

Her bir pikselin doğal logaritmasının negatifinin kendi ile çarpımlarının toplamı şeklinde bulunur. Amaç pikselin değeri 0 olan noktaların hesaplama dışı kalmasıdır. Bu sayede sadece görüntü için nesne bulunan noktaların değerinin hesaplanması için kullanılır [29].

$$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j})$$



**Homogeneity (Homojenlik)**

Farklılık ve kontrast hesaplamaları fazla kontrast içeren ya da büyük boyutlu görüntülerde büyük sonuçlar verir. Bu durumu tersine çevirmek için homojenlik hesaplaması yapılır. Homojenlik değeri küçüldükçe resmin renk geçişlerinin azlığı noktasında fikir verir [29].

$$\sum_{i,j=0}^{N-1} \frac{P_{i,i}}{1 + (i-j)^2}$$

**MaximumProbability (Maksimum Olasılık)**

Görüntünün bütün piksellerindeki en büyük değeri verir [31]. Aşağıdaki formülle bulunur.

$$\max(P_{ij})$$

**SumOfSquares (Kareler Toplamı)**

Bir diğer referans değer de varyanstır. Referans piksel (i) ve komşu pikselin (j) GLCM Ortalamasının karelerinin toplamıdır [29].

$$\sigma_i^2 = \sum_{i,j=0}^{N-1} P_{i,i} (i - \mu_i)^2 \quad \sigma_j^2 = \sum_{i,j=0}^{N-1} P_{i,i} (j - \mu_j)^2$$

Bu değerlerin karekökleri ilgili piksellerin varyansını verir [30].

**SumAverage (Ortalamaların Toplamı)**

Görüntünün gri seviyesinin toplamı dağılımının ortalamasını verir [30].

$$\sum_{k=2}^{2N_g} p_{x+y}(k)k$$

**SumVariance (Varyans Toplamı)**

Görüntünün gri seviyesinin dağılımının ortalamasını (dağılımını) hesaplar [30]. Varyansların ortalamasıdır.

$$\sum_{k=2}^{2N_g} (k - SA)^2 p_{x+y}(k)$$

**SumEntropy (Entropi Toplamı)**

Görüntünün gri seviyesinin dağılımının bozukluğunun toplamını verir [30].

$$\sum_{k=2}^{2N_g} p_{x+y}(k) \log_2 (p_{x+y}(k) + \epsilon)$$

**DifferenceVariance (Varyans Farkı)**

Her piksel için komşu piksellerin varyansının farkını verir [30]. Görüntü için ortalamadan daha fazla sapma gösteren farklı yoğunluk seviyeli çiftlere daha fazla ağırlık yerleştiren heterojenliği ortaya koyar.

$$\sum_{k=0}^{N_g-1} (k - \text{Difference Average})^2 p_{x-y}(k)$$

**DifferenceEntropy (Entropi Farkı)**

Her piksel için komşu piksellerin entropisinin farkını verir [30]. Görüntünün gri seviyesinin fark dağılımına bağlı bozukluğu hesaplar.

$$\sum_{k=0}^{N_g-1} p_{x-y}(k) \log_2 (p_{x-y}(k) + \epsilon)$$

**InformalMeasureOfCorrelation1 (Gayri Resmi Korelasyon Ölçümü 1)**

Ortak değerler üzerinden görüntüye ait karmaşıklığın korelasyonunu hesaplar.

**InformalMeasureOfCorrelation2 (Gayri Resmi Korelasyon Ölçümü 2)**

Görüntünün karmaşık değeri üzerinden aralarındaki ilişkiyi hesaplar.

**InverseDifference (Farkların Ters)**

İki piksel arası farkların mutlak değerinin tersinin toplamıdır [31]. Değerin yüksekliği görüntünün homojenliğini ortaya koyar. Aşağıdaki formülle bulunur.

$$\sum \frac{P_{ij}}{1 + |i - j|}$$

### InverseDifferenceNormalized (Normalleştirilmiş Farkların Tersi)

İki piksel arası farkların mutlak değerinin karesinin tersinin toplamıdır [31]. Aşağıdaki formülle bulunur.

$$\sum \frac{P_{ij}}{1 + |i - j|^2}$$

### InverseDifferenceMomentnormalized (Anormalleştirilmiş Farkların Tersi)

İki piksel arası farkların karesinin tersinin toplamıdır [31]. Aşağıdaki formülle bulunur.

$$\sum \frac{P_{ij}}{1 + (i - j)^2}$$

## 3.2. Yöntem

Tezde gerçekleştirilen sınıflandırılma işlemlerinde makine öğrenmesi yöntemlerinden Karar Ağaçları, Destek Vektör Makineleri, Naive Bayes Sınıflandırıcı, K En Yakın Komşu Algoritması ve Derin Öğrenme Yöntemi'nde faydalanılmıştır.

### 3.2.1. Karar Ağaçları (Decision Tree)

Karar ağaçları, ağaç benzeri bir model oluşturarak sonuçların nedenlerini girdilere bağlamayı hedefleyen bir algoritmadır. Karar Ağaçları analizde kullanılan bir yöntem olmasına rağmen makine öğrenmesinde yaygın olarak kullanılan bir araçtır.

Karar ağaçları, anlama ve yorumlanması kolay, görselleştirilebilen, hem sayısal hem de kategorik verileri işleyebilen, çok çıktılı verileri işleyebilen, doğrulanabilirdir.

İyi yönleriyle beraber karar ağaçlarında ezbere öğrenme yaşanabilen sorunlardan biridir. Bu durumda budama işlemi uygulanır. Budama işlemi karar ağacında az sayıda düğümü barındıran “yaprakların koparılması” şeklinde uygulanır.

Karar ağaçları basitçe yukarıdan aşağıya biçimini benimser. Sıralı bir yapısı olduğu için dinamik değildir. Yukarıdan aşağı inildikçe karar ağaçlarının dalları azalır ve sonuç kümeleri küçülür. Her sonuç kümesi bağlı olduğu dalın özelliklerini barındırır. Bu yüzden karar ağaçları için sınıflandırılacak veriler en basit şekilde kategorilere bölünmelidir.

Karar ağaçlarında oluşturulan modellerde sayısal değerler kategorik olarak değerlendirilebilir fakat her dalda veri sayısı azaldıkça modelin hatalı sonuç vermesi ihtimali artar.

Buna ek karar ağaçlarında aşağı doğru inildikçe verilerin karmaşıklığı artar. Bu durum karar ağaçlarının yönetilmesini, sonradan modellenmesini ya da model üzerinde değişiklik yapılmasını zorlaştırır.

Karar ağaçlarında en sık kullanılan algoritmalar C4.5 algoritması, entropi, sınıflandırma hatası, Gini, en küçük kareler yöntemidir. Bu tez çalışmasında bu yöntemlerden Gini'ye yer verilmiştir.

Karar ağaçlarında uygulama şu şekildedir.

- 1- Veri Kümesi içinden bir eğitim seti oluşturulur. Girdiler bu eğitim setidir (P).
- 2- İlk adımda bir düğüm oluşturulur (N).
- 3- Oluşturulan düğümün sınıfı (C), P ile aynı ise sınıfa bir etiket verilir, yani sınıf belirlenmiş olur. Eğer değilse düğümün çoğunluğu yeni bir etiketle bir sonraki dal için eğitim seti oluşturacak şekilde bölünür. Bu yeni sınıf da P ile gösterilir. Fakat bu sınıf öncekinden farklı olarak bir sonraki adımda değerlendirilmek üzere önceki düğümden bölünmüş yeni sınıftır.
- 4- Bu adımda ayırımın en iyi şekilde gerçekleştirilmesi için bir eşik değeri belirlenir. Burada yöntemler devreye girer. Uygulanan yöntem ile ayırım noktası bulunur (Tez için Gini Farkındalık İndeksi).
- 5- Sınıflandırılan kısım etiketlenir (N).
- 6- Ayrılan her yaprak yeniden aynı işlemlere tabi tutulmak üzere alt ağaçlar oluşturulur (Örneğin j tane alt ağaç için yeni  $P_j$  alt kümeleri oluşur) [22].

Karar ağacı ile sınıflandırma amacı ile kurulan modellerde veri seti eğitim ve test olmak üzere iki sınıfa ayrılır. Eğitim seti ile oluşturulan modelin test verileri üzerinde başarı oranı modelin başarısını verir.

### 3.2.2. Destek Vektör Makineleri (Support Vector Machines)

Destek Vektör Makineleri sınıflandırma ve regresyon analizi için kullanılan öğretmenli öğrenme algoritmalarından biridir. Destek vektör makineleri makine öğrenmesinde yaygın olarak kullanılır.

İlk olarak Vladimir Vapnik ve Alexey Ya tarafından 1962 yılında birbirinden bağımsız olarak uzayda serbest biçimde bulunan bir sınıfa mensup noktaların hiper düzlem ile birbirlerinden ayrılması ilkesi üzerinden ortaya atılmıştır. Yöntem 1993 yılında makine öğrenmesi için uygulanabilir bir algoritma haline gelmiştir [33].


Destek vektör makinelerinde ilk yıllarda ayırım iki boyutlu bir düzlemde tek boyutlu bir ayırıcı (çizgi) ile gerçekleştirilirken, yöntemin geliştirilmesiyle zamanla veri özellik sayısı (n) kadar boyutlu bir uzayda n-1 boyutlu bir ayırıcı düzlem -ya da hiperdüzlem- ile birbirinden ayrılır.

Ayırıcı düzlem doğrusal olduğu gibi doğrusal olmayan bir şekilde de olabilir. Örneğin bir polinom, hiperbolik tanjant eğrisi, Gauss radyal temel fonksiyonu ayırıcı olabilir. Bu durumdan dolayı destek vektör makineleri doğrusal ve ikinci dereceden (doğrusal olmayan) yöntemleri kendi içinde barındırır.

Destek vektör makineleri çok boyutlu uzay modellerinde etkilidir.

### 3.2.2.1. Doğrusal Destek Vektör Makineleri (Linear Support Vector Machines)

Doğrusal Destek Vektör Makineleri iki sınıfa ait verilerin doğrusal dağıldığı durumlarda etkili olan en eski destek vektör makinesi yaklaşımıdır. Sınıflandırmada genelde  $\{-1, +1\}$  şeklinde sınıf etiketleri kullanılır. İki sınıfı ayırmak içinse Karar Fonksiyonu kullanılır. Bu fonksiyon ile eğitim verisini uygun şekilde ayırabilecek bir hiper-düzlem bulunması sağlanır. Bu hiper-düzlem iki sınıfı veya daha fazla sınıfı ayırmak için çizilirken, bulunduğu konum sonsuz sayıda olabilir (Şekil 3.22 (a)). Bu durumda doğrusal destek vektör makinelerinde bu işlemi optimize etmek için ayırıcı hiper-düzlemin konumu yakın iki nokta arasındaki uzaklığı maksimize edecek şekilde hesaplanır. Bu maksimizasyon işlemi sonunda sınır genişliğini belirleyen noktalar destek vektör noktaları ya da destek vektörleri olarak adlandırılır (Şekil 3.22 (b)) [34].




Şekil 3.22. Doğrusal Destek Vektör Makinesi Ayırıcısı Örneği [34].

$i$  kadar sınıflandırılacak elemana sahip bir problemde optimum hiper düzleme ait eşitsizlikler bu durumda,

$$\text{Her } y = 1 \text{ için } w \cdot x_i + b \geq 1$$

$$\text{Her } y = -1 \text{ için } w \cdot x_i + b \leq -1$$

şeklinde formülize edilir. Formülde  $w$  ağırlık değerini,  $x$  değeri noktanın uzaydaki konumunu,  $b$  eğim değerini,  $y$  sınıf etiketlerini gösterir. Sonucunda bu hiper-düzlemi ayıran noktalar destek vektörü olarak adlandırılır ve  $w \cdot x_i + b = \pm 1$  olarak formülize edilir (Şekil 3.23).



Şekil 3.23. Doğrusal Ayrılan Veri Setleri İçin Hiper-Düzlem Belirlenmesi Örneği [34].

Hiper-düzlemin optimum değere getirilmesi için sınırının maksimize edilmesi yani  $w$  değerinin minimize edilmesi gerekir. Bu işlem için formül

$$\min \left[ \frac{1}{2} \|w\|^2 \right]$$

şeklinde dir.

Lagrange denklemi kullanılarak bu optimizasyon problemi çözülür.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^k \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^k \alpha_i$$

### 3.2.2.2. Doğrusal Olmayan (İkinci Dereceden) Destek Vektör Makineleri

Doğrusal olarak ayrılamayan veri setleri için doğrusal olmayan (ikinci dereceden) destek vektör makineleri kullanılır. Bu nedenle çekirdek numarası (kernel trick) olarak adlandırılan noktalar ayırma kullanılır. Bu yöntem, doğrusal olmayan verilerde makine öğrenimini yüksek oranda arttırmaktadır.

Doğrusal ayırım yapılamayan verilerde optimizasyon formülü

$$\min \left[ \frac{\|w\|^2}{2} + C \cdot \sum_{i=1}^r \xi_i \right]$$

şeklinde olur. Bu durumda hiper-düzlemin sınırlamaları

$$y_i (w \cdot \varphi(x_i) + b) - 1 \geq 1 - \xi_i$$


$$\xi_i \geq 0 \text{ ve } i = 1, \dots, N$$

şeklinde ifade edilir (Şekil 3.24).

Çalışmada doğrusal olmayan destek vektör makineleri için kullanılan karar fonksiyonu Gaussian Çekirdek Yöntemi'dir (Şekil 3.24). Bu fonksiyondaki gama ( $\gamma$ ) değeri çekirdek boyutunu verir ve formül şu şekildedir [34].

$$K(x, y) = e^{-\gamma \|x - x_i\|^2}$$

Doğrusal ayırıcılar ađın performansını arttırsa da doğrusal olmayan ayırıcılar bazı örneklerde modelin hızını azaltmasına rağmen başarı yüzdesini arttırdığı gözlemlenmiştir. Yine bu tezde de aynı sonuç elde edilmiştir.



Şekil 3.24. Doğrusal Olmayan Destek Vektör Makinesi Örneđi [34].

### 3.2.3. Naive Bayes Sınıflandırıcı

Yöntem 1812 yılında Thomas Bayes tarafından keşfedilen “koşullu olasılık hesaplama formülü”ne dayanır. Bayes Teoremi, olasılık kuramı içinde önemli bir kuramdır. Teorem ile bir rassal deđişken için koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkinin gösterilmesi sağlanır.

$$P(A) = A \text{ olayının gerçekteşme olasılığı}$$

$$P(B) = B \text{ olayının gerçekteşme olasılığı}$$

$$P(A/B) = B \text{ olayı gerçekteştiğinde } A \text{ olayının gerçekteşme olasılığı}$$

$$P(B/A) = A \text{ olayı gerçekteştiğinde } B \text{ olayının gerçekteşme olasılığı}$$

şeklinde izah edilir.

Naive Bayes Sınıflandırıcısı bu teoreme dayanır. Çalışma şekli her bir eleman için her bir durumun olasılığının ayrı ayrı hesaplanması şeklindedir. Bu hesaplama sonucu elemanı olasılık değeri en yüksek olana göre sınıflandırarak sınıflandırma işlemi gerçekteştirilmiştir olur.

Naive Bayes Sınıflandırıcısı algoritması geređi küçük eğitim setleriyle başarılı sonuçlar elde etmede etkilidir. Buna ek dengesiz veri kümelerinde de etkilidir.

Naive Bayes Sınıflandırıcısı kendi içinde bazı sınırlılıklara sahiptir. Örneğin eğitim setinde görülmeyen bir değer test setinde görülmesi durumunda olasılığı 0 (sıfır) döndürür. Bu duruma Sıfır Frekans (Zero Frequency) adı verilir. Sınıflandırıcının bu sınırlılıklarını gidermek için çeşitli yöntemler mevcuttur. Bunların en yaygın kullanılabilecek Laplace Tahmini'dir.

Naive Bayes Sınıflandırıcı veri madenciliği, biyomedikal mühendisliği, metin ayrıştırılması, ürün sınıflama gibi alanlarda kullanılmaktadır.

### 3.2.4. K En Yakın Komşu Algoritması (K Nearest Neighborhood Algorithm)

K En Yakın Komşu Algoritması öğretmenli öğrenme algoritmalarından biridir. Sınıflandırma ve regresyon problemi için çözümler sunan bu algoritma endüstriyel problemlerin çözümünde etkilidir.

1967 yılında T. M. Cover ve P. E. Hart tarafından geliştirilmiştir. K En Yakın Komşu Algoritması'nda, daha önceden sınıfları belirlenmiş bir eğitim kümesi verileri ele alınarak ele alınan yeni bir verinin bu mevcut verilere olan uzaklığı hesaplanıp, yakın komşu sayısı (k ile temsil edilir) hesaplanır. Bu hesaplamada kullanılan fonksiyonlardan en yaygınları Euclidean, Manhattan ve Minkowski Uzaklıkları'dır. Tezde bu hesaplama fonksiyonlarından Euclidian Uzaklığı kullanılmıştır.

#### 3.2.4.1. Euclidean Uzaklığı (Euclidean Distance)

Euclidean Uzaklığı iki veya üç boyutta iki nokta arasındaki mesafeyi hesaplamaya yarayan bir fonksiyondur. Bir noktanın diğer nokta ile eksen farklarının karelerinin toplamının karekökü alınarak bulunur. Formülü şu şekildedir.

$$d(\mathbf{p}, \mathbf{q}) = d(\mathbf{q}, \mathbf{p}) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2}$$

$$= \sqrt{\sum_{i=1}^n (q_i - p_i)^2}.$$

K En Yakın Komşu Algoritmasının iş akışı şu şekildedir.

- 1- Verileri İncele
- 2- Yeni Veriyi İncele
- 3- Yeni Verinin Mevcut Verilere Uzaklıklarını Hesapla
- 4- En Yakın Komşuları Bul
- 5- Veriyi Sınıflandır

### 3.2.5. Derin Öğrenme Yöntemi (Deep Learning)

Derin Öğrenme Yöntemi makine öğrenme teknikleri içinde ses, görüntü, sinyal gibi verileri kullanarak nesne tanıma, görüntü işleme, ses tanıma, örüntü tanıma gibi işlemlerin gerçekleştirilmesini



sağlamaktadır. Bu yöntem 2000’li yılların ortasında itibaren geliştirilmeye başlanmış ve günümüzde imkânsız gibi görülebilecek problemlerin çözümüne olanak sağlamıştır [35].

Derin Öğrenme, bir ve daha fazla gizli katman içeren yapay sinir ağları ile farklı makine öğrenme algoritmalarını içeren ve bunların bir arada kullanılması mantığına dayanan bir çalışma alanıdır. Yöntem diğer yöntemler gibi temelinde daha önceden geliştirilmiş yöntemlerin bir adım ileri taşınması şeklinde oluşturulmuştur.

Bu açıdan bakıldığında Derin Öğrenme’ye ön ayak olan yapay sinir ağı modeli Evrişimsel Sinir Ağı’dır (Convolutional Neural Network - CNN).

Evrişimsel Sinir Ağları, klasik yapay sinir ağları modellerinin görüntü işleme tekniklerinde yöntem olarak kullanılan özellik çıkarımı, kenar bulma vb. yöntemlere ihtiyaç duymadan görüntüyü sınıflandırmaya imkân vermektedir.

Derin Öğrenme Yöntemi kendi başına ele alınırsa ilk olarak 2012 yılına Toronto Üniversitesi’nde Georghe Dahl önderliğindeki ekibin “Multi-task Neural Networks for QSAR Predictions” çalışması ile tarihlendirilebilir. Çalışmada temel alınan bir ilacın biyomoleküler hedefi Dahl önderliğindeki ekibin tasarladığı çok katmanlı yapay sinir ağı ile tahmin edilmiştir [36].

Derin Öğrenme Yöntemi’nde giriş verisi farklı öğrenme algoritmaları, özellik çıkarım yöntemleri, aktivasyon işlemi ile yönteme özel işlemlere tabi tutulur. Son aşamada elde edilen veri grubu çok katmanlı ve tam bağlı (Fully connected) bir ağ üzerinden değerlendirilir ve sınıflandırma işlemi tamamlanmış olur.


Derin Öğrenme Yöntemi’nde uygulanan işlemler şu şekildedir.

### 3.2.5.1. İki Boyutlu Evrişim

Derin Öğrenme Yöntemi’nde kullanılan işlemlerden biri evrişim işlemidir.

Bu işlemde giriş verisine uygulanacak olan filtrenin x ve y eksenine göre simetrisi alınır. Tüm değerler matriste eleman eleman çarpılır ve tüm değerlerin toplamı çıkış matrisinin ilgili elemanı olarak kaydedilir (Şekil 3.25). Bu işlem diğer bir deyişle “çapraz korelasyon ilişkisi”dir.


İki boyutlu evrişim iki kanallı görüntüler için uygulanabilir. Örneğin siyah-beyaz tonlamalı görüntüler ya da gri tonlamalı (Grayscale) görüntüler gibi.



**Şekil 3.25.** 7x6 Boyutundaki İki Kanallı Görüntüye 3x3 Matrisiyle Uygulanan İki Boyutlu Evrişim İşlemi [37]

### 3.2.5.2. Üç Boyutlu Evrişim

Giriş verisinin üç kanallı olması durumunda çıkış verisi için evrişim matrisi üç kanalıdır. Diğer bir deyişle çıkış verisi üç boyutlu matris olur. Örnek verecek olursak renkli bir görüntü oluşturulduğu renk uzayı gereği üç kanalıdır. RGB, HLS, YUV ren uzayları gibi. Bu durumda uygulanan evrişim işlemi üç boyutlu evrişim olarak adlandırılır (Şekil 3.26).



**Şekil 3.26.** 6x6 Boyutundaki Üç Kanallı Görüntüye Uygulanan 3x3 Evrişim İşlemi [38]

Evrişim işleminde kanal sayısı arttıkça ağırlık performansı artar. Bununla beraber işlem süresi uzar. Evrişim işlemi kaç kanallı uygulanırsa uygulansın kendi içinde geri yayılım (Back Propagation) ile ağırlıkların sürekli güncellendiği ve aktivasyon fonksiyonu uygulanan çıkış matrisine önceden belirlenmiş "bias" değerinin eklenmesi ile sonuçlanır.

### 3.2.5.3. Kenar Bulma İşlemi

Kenar bulma bir görüntüdeki yüksek frekanslı bölümlerin tespiti için kullanılan en etkili yöntemdir. Derin Öğrenme’de geleneksel kenar bulma algoritmaları (Sobel, Canny, Gabor, Prewit) yatay ve dikey olarak ayrı ayrı uygulanır. İşlemin yatay veya dikey uygulanması zorunlu değildir. İstenirse tek yönlü uygulanabilir. Fakat bu durum bazı görüntülerde ağır performansını olumsuz etkileyebilir.

Geleneksel kenar bulma algoritmalarına ek olarak Derin Öğrenme Yöntemi’nde açısall kenarların tespiti, karanlıktan aydınlığa (Kontrast geçişleri), renk geçişleri gibi özneliklerin değerlendirilmesi de kenar bulmak için kullanılır (Şekil 3.27).



Şekil 3.27. Rastgele Seçilmiş İnsan Yüzlerine Uygulanmış Kenar Bulma Algoritmaları (Soldan Sağa Açısall Kenarların Tespiti, Kontrast Geçişleri, Renk Geçişleri) [39]

### 3.2.5.4. Piksel Ekleme (Padding)

Giriş verisi ile çıkış verisi arasındaki boyut farkının giderilmesi için kullanılan iki işlem vardır. Birincisi piksel ekleme işlemidir. Bu işlem giriş görüntülerinin merkezde kalarak boyutunun belirlenen matrislerle büyütülmesini sağlar. Bu matrisler sayesinde eklenen pikseller siyah (0), uç noktasının aynısı, uç noktasının ortalaması şeklinde olabilir.

### 3.2.5.5. Kaydırma (Stride)

Giriş verisi ile çıkış verisi arasındaki boyut farkının giderilmesi için kullanılan diğer işlem kaydırma işlemidir. Kaydırma işlemi ile piksel ekleme işleminin tersine çıkış verisi giriş verisinden daha küçük boyutlu olur. Dolayısıyla bu yöntem giriş verisinin boyutunu düşürmek için kullanılır. Bu işlemde giriş verisi her bir adımda daha önceden belirlenen adım sayısınca kaydırılmasıyla yeni bir matris elde edilir. Her bir kaydırma adımında yine daha önceden belirlenmiş bir işlem bu matrislere uygulanır. Uygulanan bu işlemler kendi içinde veya başka bir matrisle toplama, çarpma, ortalama ya da en büyük/en küçük değeri alma gibi işlemler olabilir.


Kaydırma işlemi ağır işlem hızını artırır ama ağır başarısına olumsuz etki edebilir.

### 3.2.5.6. Ortaklama (Pooling)

Bu işlem diğerlerinden farklı olarak giriş verisinin boyutunu hem düşürebilir hem de büyütebilir. Bunu uygulanacak işlemim parametreleri belirler.

Ortaklama işlemi giriş matrisinin kanal sayısı sabit tutularak genişlik ve yükseklik değerlerinin azaltılması ilkesine dayanır. Matristeki her bir grubun belirlenen boyutta (Örneğin 2x2) ele alınarak kendi içinde belirlenen işlemden geçirilerek yeni bir matris elde edilmesi işlemidir.

Yeni matris elde edilirken ortaklanan her bir matris grubu kendi içinde toplama, ortalamasını alma, en büyük ya da en küçük değeri alma şeklinde olabileceği gibi bazı durumlar klasik aktivasyon formüllerinin uygulanması şeklinde de olabilir (Şekil 3.28).



**Şekil 3.28.** En Büyük Değerin Alınması İlkesine Dayanan 2x2'lik Maksimum Ortaklama İşlemi (Max-Pooling) Ve Sonucu [40]

### 3.2.5.7. Seyreltme (Drop Out)

Tam bağlı (Fully Connected) katmanlarda öğrenme katsayısı ya da diğer deyişle belli eşik değerin altında kalan bağların koparılması ile ağıın daha başarılı öğrenmesinin sağlanması adına uygulanan işlemidir. Ağıın hızı ve başarı yüzdesini arttırması açısından önemli bir işlemidir.

Çalışmada bu işlem kullanılmamıştır.

### 3.2.5.8. Yığın Normalizasyonu (Batch Normalization)

Yığın normalizasyon işlemi diğer bir deyişle katman normalizasyonudur. Basitçe ele alınan matrisin tek başına değil gruplar halinde işlenmesi şeklinde açıklanabilir. Esasında matrisin tek tek ele alınmasının başarı oranını teorik olarak arttırması beklenirken, bazı durumlarda küçük ayrıntıların işlenmesi genel başarı oranını düşürebilir. Bu açıdan yığın normalizasyonu verilerin genel ele alınmasını sağlar.

Mantık olarak birbirine yakın olsa da ortaklama işleminden farklıdır. Zira ortaklama işleminde matrisin bütün elemanları ele alınarak hesaplama yapılır fakat yığın normalizasyonunda bu işlem katmanın dikey veya yatay yönüyle gruplanır. Gruplanan yığınlar ortaklama işlemindeki gibi bir takım istatistiksel işlemlere tabi tutulur (Ortalama alma, en büyük veya en küçük değeri alma, medyan alma, standart sapma değerini alma gibi) (Şekil 3.29).

Yığın normalizasyonun ağı performans kazandırdığı yapılan çalışmalarla ispatlanmıştır [41, 42].

#### Batch Normalization




Şekil 3.29. 3x6'lık Matrisin Dikey Yönde Ortalama Ve Standart Sapma Değeri Üzerinden Yığın Normalizasyonu İşlemi [43].

### 3.2.5.9. Üstel Normalizasyon Fonksiyonu (Softmax Function)

Matematikte birden fazla girdinin olasılık dağılımlarını üstel şekilde normalleştirmek için kullanılan fonksiyondur. Yapay sinir ağları için kullanımı çıktı sınıfları üzerinde olasılık dağılımlarını eşlemek, diğer bir deyişle en büyük olasılığı öne çıkararak için kullanılır.

İki tür kullanımı mevcuttur. Birinci tür kullanımda bütün çıktılar için toplamı 1 edecek şekilde olasılık değeri hesaplanırken ikinci tür kullanımda çıktı değerleri oranlı belirlenmez. Bu kullanımda bazı çıktılar negatif olabilir dolayısıyla çıktının “ne olmadığına” cevap bulmak için kullanılır.

Bu katman sınıflandırma işleminde sınıflandırılması hedeflenen kategori kadar çıktı elemanına sahip olur (Şekil 3.30).



Şekil 3.30. 5 Tür Çıkışlı Örnek Bir Softmax Katmanı [44]

#### 4. UYGULAMALAR VE SONUÇLAR

Çalıřmada makine öğrenmesi yöntemlerinden Karar Ağaçları (KA), Doğrusal Destek Vektör Makineleri (DDVM), İkinci Dereceden Destek Vektör Makineleri (İDDVM), Naive Bayes Sınıflandırıcı (NBS), K En Yakın Komşu Algoritması (KEYK) ve Derin Öğrenme Yöntemi olmak üzere altı yöntem uygulanmıştır ve uygulamalar Matlab (Versiyon 2019a) üzerinde gerçekleştirilmiştir. Veriler üç grupta ele alınmıştır. Birinci uygulamada pirinçler tür ve durumlarına göre 10 sınıfta (Tablo 4.1), ikinci uygulamada pirinçler türlerine göre 5 sınıfta (Tablo 4.2), üçüncü uygulamada pirinçler durumlarına göre 2 sınıfta (Tablo 4.3) ele alınmıştır. Üç farklı uygulamaya ait pirinçlerin sayıları ve toplama oranları (yüzdeleri) aşağıdaki tablolarda verilmiştir.

##### Pirinçlerin Tür Ve Durumlarına Göre Sınıflandırılması (Uygulama 1)

**Tablo 4.1.** Pirinçlerin Tür Ve Durumlarına Göre Dağılımı

Tür	Durum	Adet	Kodu	Yüzde (%)
Birinci Kalite	Tam	1025	IT	13,63
	Kırık	875	IK	11,63
İkinci Kalite	Tam	442	TT	5,88
	Kırık	186	TK	2,47
Az Çekilmiş	Tam	882	YT	11,73
	Kırık	227	YK	3,02
Çekilmemiş	Tam	1004	KT	13,35
	Kırık	911	KK	12,11
Olgunlaşmamış veya çürümüş	Tam	965	KOT	12,83
	Kırık	1005	KOK	13,36

##### Pirinçlerin Türlerine Göre Sınıflandırılması (Uygulama 2)

**Tablo 4.2.** Pirinçlerin Türlerine Göre Dağılımı

Tür	Adet	Kodu	Yüzde (%)
Birinci Kalite	1900	I	25,26
İkinci Kalite	628	T	8,35
Az Çekilmiş	1109	Y	14,74
Çekilmemiş	1915	K	25,46
Olgunlaşmamış veya çürümüş	1970	KO	26,19

##### Pirinçlerin Durumlarına Göre Sınıflandırılması (Uygulama 3)

**Tablo 4.3.** Pirinçlerin Durumlarına Göre Dağılımı


Durum	Adet	Kodu	Yüzde (%)
Tam	4318	Tam	57,4
Kırık	3204	Kirik	42,6

Pirinçler bütün uygulamalarda Karar Ağaçları (KA), Doğrusal Destek Vektör Makineleri (DDVM), İkinci Dereceden (Quadratic) Destek Vektör Makineleri (İDDVM), Çekirdek (Kernel) Naive

Bayes Sınıflandırıcı (NBS), K En Yakın Komşu Algoritması (KEYKA) ve hazırlanan Derin Öğrenme (Deep Learning) Yöntemi (DÖY) modeli ile sınıflandırılmıştır. Karar Ağaçları, Doğrusal ve İkinci Dereceden Destek Vektör Makineleri, Naive Bayes Sınıflandırıcı ve K En Yakın Komşu Algoritması yöntemlerinde her sette 10'lu çarpaz değerlendirme (cross validation) uygulanmıştır. Sonuçlarda bu 10'lu çarpaz değerlendirmelerin ortalamaları alınmıştır.

Karar Ağaçları yöntemi uygulanırken Gini Farklılık İndeksi ayrı kriter olarak kabul edilmiştir. Naive Bayes Sınıflandırıcı, Gauss (Gaussian) yöntemi ile uygulanmış ve K En Yakın Komşu Algoritması uygulanırken komşu sayısı 1, mesafe ölçümü Öklid (Euclidean), mesafe ölçümü ağırlıklara göre belirlenmiştir. Destek Vektör Makinelerinde Doğrusal Destek Vektör Makineleri ile İkinci Dereceden Destek Vektör Makineleri yöntemleri uygulanmış ve İkinci Dereceden Destek Vektör Makineleri yöntemi için Gaussian Çekirdek Yöntemi olarak belirlenmiştir.

Bu uygulamalardan Derin Öğrenme Yöntemi (DÖY) ile hazırlanan model diğer ağlar ile karşılaştırılmış fakat biçimsel olarak uygulaması diğerlerinden farklı olduğu için ayrı şekilde ele alınmıştır. Derin Öğrenme Yöntemi için model şekildeki (Şekil 4.1) gibidir.



Şekil 4.1. Tezde kullanılan Derin Öğrenme Yöntemi için tasarlanan ağ modeli

Derin Öğrenme Yöntemi için hazırlanan modelde giriş katmanındaki resimler 600x600 piksel şeklinde, çıkış katmanında ise her bir uygulamadaki sınıf sayısı kadar çıkış verisi bulunmaktadır. Modelin katmanları sırasıyla,

- 1- Giriş katmanı
- 2- İki Boyutlu Evrişim Katmanı



- 3- Yığın Normalizasyon Katmanı (Batch Normalization Layer)
- 4- ReLU Aktivasyon Katmanı
- 5- En Büyük Değere Göre Ortaklama Katmanı (Maximum Pooling)
- 6- İki Boyutlu Evrişim Katmanı
- 7- Yığın Normalizasyon Katmanı (Batch Normalization Layer)
- 8- ReLU Aktivasyon Katmanı
- 9- Ortalama Değere Göre Ortaklama (Average Pooling)
- 10- Tamamen bağlı katman (Fully Connected Layer)
- 11- Softmax Katmanı (Softmax Layer)
- 12- Çıkış katmanı

şeklinde.

Fotoğraflar ağa dahil olduktan sonra klasik evrişim işlemi uygulanmıştır. Evrişim işleminin uygulanmasının nedeni pirinç fotoğraflarının farkı özelliklerinin (renk, kontrast, kenar vb.) ağ içinde yer almasını sağlamaktır.

Farklı özellikleriyle ağda olan ve evrişim sonucu boyutu artmış olan veriler Yığın Normalizasyonu'na tabi tutulmuştur. Buradaki amaç ortalama değerler üzerinden artmış olan boyutları azaltmaktır. Bu işlem ağın performansına yöneliktir. Ek olarak normalizasyon işlemi kendi içinde verilerin tutarlılıklarını arttırmaktadır.

Aktivasyon formülü olarak ReLU (Rectified Linear Unit) ya da bilinen adıyla Doğrultucu Rampa Fonksiyonu kullanılmıştır. Bu fonksiyonun kullanılma sebebi değerlerin içindeki negatif değerlerin ihmal edilmesini sağlamak içindir. Negatif değerler özellikle siyah ağırlıklı piksellerin döndürdüğü sonuçlar şeklindedir. (Fotoğraflardaki arka plan plakadan dolayı siyahtır) Bu sayede hem ağın performansının artması hem de işlem süresinin kısaltılması amaçlanmıştır.

Aktivasyon formülü olan ReLU şu şekildedir.

$$f(x) = x^+ = \max(0, x),$$

Ardından uygulanan en büyük değere göre ortaklama katmanı ile verilerin en büyük değerlerinin alınması ve sonucunda ağın hem performansının artışı hem de düşük öneme sahip (değeri küçük) verilerden ayıklanması amaçlanmıştır. Sonrasında uygulanan iki boyutlu evrişim işlemi ile verilerin son kez farklı şekillerde ele alınması, yığın normalizasyonu ile tekrar artan boyutun azaltılması ve verilerin tutarlı hale gelmesi, ReLU aktivasyon formülü katmanı ile negatif değerlerin ayrıştırılması sağlanmıştır.

Eldeki veriler bu işlemden sonra ortalama değere göre ortaklanmıştır. Ortaklanmadaki amaç veri kaybını son aşamada minimize etmek bir yandan da ağın boyutunu azaltmaktır. Zira sonraki aşama tamamen bağlı katmandır ki bu katmana giren veri sayısının azlığı ağın performansını artırırken verilerin ayırıcı özelliklerini kaybetmemiş olması ağın başarı oranına doğrudan etki etmektedir.

Çıkış katmanı her uygulamada sınıflandırılmayı hedeflenen pirinç kategorisi kadardır. Örneğin 1. uygulamada pirinçlerin tür ve durumlarına göre sınıflandırılmasında 10, 2. uygulamada pirinçlerin türlerine göre sınıflandırılmasında 5, 3. uygulamada durumlarına göre sınıflandırılmasında 2 şeklindedir.

Çıkış katmanından önce uygulanan Softmax Katmanı ağıın sınıflandırma işleminde oransal fikirler sunmasının önüne geçmek için ağıa eklenmiş sonucun tek bir sınıfı işaret etmesi için eklenmiştir.

#### 4.1. Pirinçlerin Tür Ve Durumlarına Göre Sınıflandırılması (Uygulama 1)

Pirinçlerin tür ve durumlarına göre sınıflandırılması işleminde en başarılı yöntem İDDVM, en başarısız model DÖY olmuştur (Tablo 4.4). Sonuçlar gösterilirken her model için sınıflara ait beklenen/tahmin edilen sayıları ve yüzdeleri ayrı ayrı grafiklerle sunulmuştur.

**Tablo 4.4.** Uygulama 1'deki Başarı Oranları

Model	Başarı Oranı (%)
İkinci Dereceden Destek Vektör Makineleri (İDDVM)	97,2
Doğrusal Destek Vektör Makineleri (DDVM)	97
Karar Ağaçları (KA)	95,1
K En Yakın Komşu Algoritması (KEYK)	94,5
Çekirdek (Kernel) Naive Bayes Sınıflandırıcı (NBS)	93,3
Derin Öğrenme Yöntemi (DÖY)	82,05

Bu uygulamada KA, Çekilmemiş Kırık (KK) ve Çürümüş Veya Olgunlaşmamış Tam (KOT) pirinçlerin sınıflandırılmasında %98'in üzerinde başarı elde etmiştir. Yine KA ile başarı oranı %88'de kalarak en kötü tahmin edilen pirinçler İkinci Kalite Kırık (TK) ve Tam (TT) pirinçler olmuştur. KA'nda başarısızlığın nedeni olarak İkinci Kalite ve Birinci Kalite pirinçlerin birbirine çok benzemesi gösterilebilir. Zira dikkat edilirse Birinci Kalite (I) pirinçlerin en çok hatalı tahmin değerleri İkinci Kalite (T) pirinçlerde görülmektedir (Grafik 4.1 ve Grafik 4.2).

**Uygulama 1 - Karar Aęaęları**

Beklenen	IK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
IK	835	29	1	1			4	5		
IT	34	961		1		1		28		
KK			894			16			1	
KOK	3			957	24		3		16	2
KOT				21	937	1	1		1	4
KT			14		2	988				
TK	10			3			164	9		
TT	14	31			3		4	390		
YK			2	13					191	21
YT			1	7	15				19	840
	IK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
	Tahmin Edilen									

**Grafik 4.1.** Uygulama 1'in Karar Aęaęları'na Gre Beklenen / Tahmin Edilen Sayıları

**Uygulama 1 - Karar Aęaęları (%)**

Beklenen	IK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
IK	95%	3%	<1%	<1%			<1%	1%		
IT	3%	94%		<1%		<1%		3%		
KK			98%			2%			<1%	
KOK	<1%			95%	2%		<1%		2%	<1%
KOT				2%	97%	<1%	<1%		<1%	<1%
KT			1%		<1%	98%				
TK	5%			2%			88%	5%		
TT	3%	7%			1%		1%	88%		
YK			1%	6%					84%	9%
YT			<1%	1%	2%				2%	95%
	IK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
	Tahmin									

**Grafik 4.2.** Uygulama 1'in Karar Aęaęları'na Gre Beklenen / Tahmin Edilen Yzdeleri

DDVM ile bu uygulamada en kt tahmin edilen pirinęler Az ekilmiř Kırık (YK) pirinęler olmuřtur. Bařarı oranı %85'te kalmıřtır (Grafik 4.3). Bařarı oranını dřren YK ile YT arasındaki %10'u bulan beklenen/tahmin edilen rakamıdır (Grafik 4.3). Bunun sebebi incelendięinde birok

özelliđin iki sınıf için yakın deđerler vermesi gösterilebilir. Örneđin kırık ve tam ayırımından hareket edilerek yine de iki pirincin birbirine yakın deđerler içerdđi Grafik 4.5 ve Grafik 4.6 gösterilmiřtir. DDVM ile en iyi tahmin edilen pirinçler Çekilmemiř Kırık (KK) ve Tam (KT) ile Az Çekilmiř Tam (YT) pirinçler olmuřtur (Grafik 4.3). Bařarı oranı %99'un üzerindedir (Grafik 4.4).

Uygulama 1 - Doğrusal Destek Vektör Makineleri

Beklenen	İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT
İK	842	21		3			1	8		
İT	5	1007						13		
KK			889	1		19			2	
KOK	2			977	19		1		6	
KOT				12	952	1				
KT			7	1	3	993				
TK	7			1			163	15		
TT	5	17		1			8	411		
YK			2	11					192	22
YT			1		2	1			7	871
	İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT

Tahmin Edilen


**Grafik 4.3.** Uygulama 1'in Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları

Uygulama 1 - Doğrusal Destek Vektör Makineleri


Beklenen	İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT
İK	96%	2%		<1%			<1%	1%		
İT	<1%	98%						1%		
KK			98%	<1%		2%			<1%	
KOK	<1%			97%	2%		<1%	1%		
KOT				1%	99%	<1%				
KT			1%	<1%	<1%	99%				
TK	4%			1%			88%	8%		
TT	1%	4%		<1%			2%	93%		
YK			1%	5%					85%	10%
YT			<1%		<1%	<1%			1%	99%
	İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT

Tahmin Edilen

**Grafik 4.4.** Uygulama 1'in Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri



**Grafik 4.5.** Uygulama 1 - Doğrusal Destek Vektör Makineleri (YK - YT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre



**Grafik 4.6.** Uygulama 1 - Doğrusal Destek Vektör Makineleri (YK - YT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre (Hatalılar)

Uygulama 1 için en başarılı model olan İDDVM'nin toplam başarı yüzdesi %97,2'dir. Bu modelde en başarılı tahmin %99 ile Çekilmemiş Tam (KT) pirinçler için olmuştur (Grafik 4.8). Toplamda %97'yi geçen başarı oranını aşağı çeken Az Çekilmiş Kırık (YK) pirinçler olmuştur (Grafik

4.7). Burada başarı oranı %86'dır. Bununla beraber İkinci Kalite Kırık (TK) pirinçler için %89'luk başarı oranı toplam başarı oranını aşağı çeken diğer pirinç sınıfıdır. Bunların dışında kalan pirinç sınıflarında başarı oranı %97 ve üzeridir ki bu genele bakıldığında için önemli bir rakamdır (Grafik 4.8).

Başarı oranını aşağı çeken Az Çekilmiş Kırık (YK) ile Az Çekilmiş Tam (YT) arasındaki %7'lik tahmin başarısızlığıdır (Grafik 4.8). Bunun sebebi bir önceki model olan DDVM'nde de açıklanmaya çalışılmıştır. Yine İDDVM'inde başarı oranını aşağı çeken İkinci Kalite Kırık (TK) ile İkinci Kalite Tam (TT) pirinçler arasındaki %8'lik başarısız tahmin oranıdır ki sebebi incelendiğinde birçok özelliğin iki sınıf için yakın değerler vermesi gösterilebilir (Grafik 4.8). Örneğin kırık ve tam ayrımından hareket edilerek yine de iki pirincin birbirine yakın değerler içerdiği Grafik 4.9 ve Grafik 4.10'da gösterilmeye çalışılmıştır.

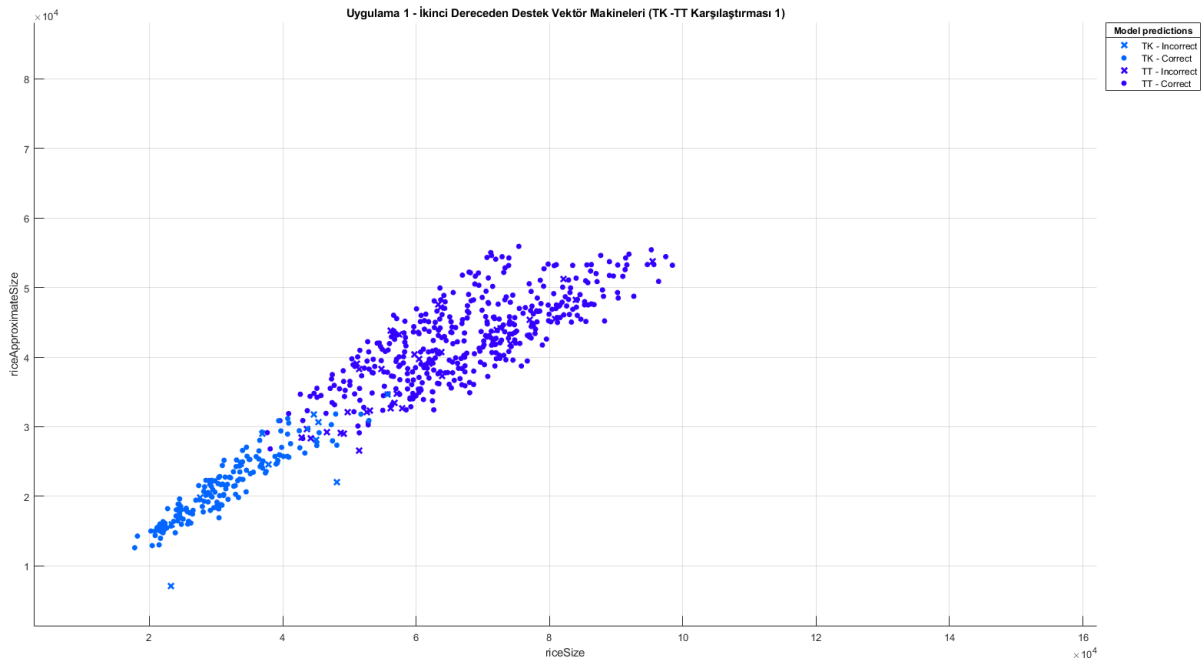
Uygulama 1 - İkinci Dereceden Destek Vektör Makineleri

Beklenen	İK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
	850	15		2			2	6		
	10	1002						13		
			893	1		15			2	
	1		1	982	14		2		5	
				14	948	2				1
			6		2	996				
	5			1			165	15		
	3	21		1			7	410		
			2	12					196	17
			1	1	1	1			10	868
	İK	IT	KK	KOK	KOT	KT	TK	TT	YK	YT
	Tahmin Edilen									


**Grafik 4.7.** Uygulama 1'in İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları



**Grafik 4.8.** Uygulama 1'in İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri



**Grafik 4.9.** Uygulama 1 – İkinci Dereceden Destek Vektör Makineleri (TK - TT Karşılaştırması 1), riceApproximate ve riceSize Özelliklerine Göre



**Grafik 4.10.** Uygulama 1 – İkinci Dereceden Destek Vektör Makineleri (TK - TT Karşılaştırması 2), riceApproximate ve riceSize Özelliklerine Göre (Hatalı)

Uygulama 1 için NBS ile en iyi tahmin edilen pirinçler Çekilmemiş Tam (KT) ve Birinci Kalite Tam (IT) pirinçler olmuştur (Grafik 4.11). Başarı oranı %98'in üzerindedir. En kötü tahmin edilen pirinç Az Çekilmiş Kırık (YK) olmuştur. Başarı oranı %79'da kalmıştır. Yine İkinci Kalite Tam (TT) %84, İkinci Kalite Kırık (TK) %85, Birinci Kalite Kırık (IK) %89 ile başarı oranını aşağı çeken pirinçlerdir (Grafik 4.12). Başarı oranının düşmesinde ilk bakıldığında Birinci Kalite (T) ve İkinci Kalite (T) pirinçlerin tahmin yüzdelerinin düşüklüğü göze çarpmaktadır (Grafik 4.12). Bu durumun sebebi DDVM ve İDDVM modellerinde de ortaya çıkan iki türün birbirine yakın değerler vermesidir (Grafik 4.9 ve Grafik 4.10). Bu durum DDVM ve İDDVM'ye göre NBS'da daha başarısız tahmin sayısı ile göze çarpmaktadır (Grafik 4.11).



**Uygulama 1 - Kernel Naive Bayes Sınıflandırıcı**

Beklenen	İK	783	58	2	10			1	21		
	İT	7	1001		7	1			9		
	KK			825		1	82			3	
	KOK	1		4	947	33	1	3		10	6
	KOT				15	936	8		1		5
	KT			23		1	980				
	TK	3			3	1		159	20		
	TT	4	33		6			29	370		
	YK			3	7	1				179	37
	YT			6		3	2			36	835
			İK	İT	KK	KOK	KOT	KT	TK	TT	YK
		Tahmin Edilen									

**Grafik 4.11.** Uygulama 1'in Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Sayıları

**Uygulama 1 - Kernel Naive Bayes Sınıflandırıcı (%)**

Beklenen	İK	99%	7%	<1%	1%			<1%	2%			89%	11%
	İT	1%	98%		1%	<1%			1%			98%	2%
	KK			91%		<1%	9%			<1%		91%	9%
	KOK	<1%		<1%	94%	3%	<1%	<1%		1%	1%	94%	6%
	KOT				2%	97%	1%		<1%		1%	97%	3%
	KT			2%		<1%	98%					98%	2%
	TK	2%			2%	1%		85%	11%			85%	15%
	TT	1%	7%		1%			7%	84%			84%	16%
	YK			1%	3%	<1%				79%	16%	79%	21%
	YT			1%		<1%	<1%			4%	95%	95%	5%
			İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT	
		Tahmin Edilen											

**Grafik 4.12.** Uygulama 1'in Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Yüzdeleri

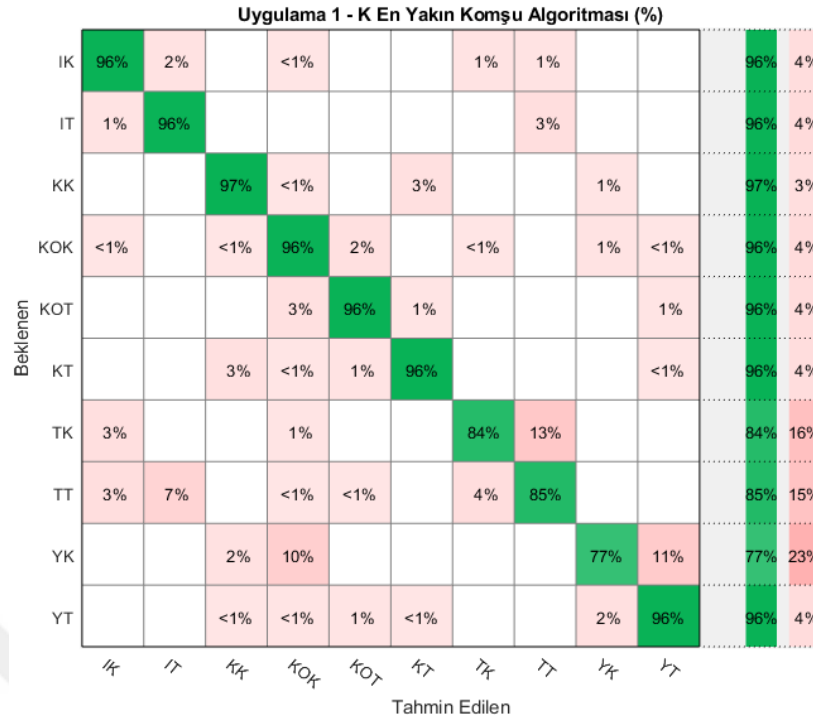
Uygulama 1 için KEYK ile en iyi tahmin edilen pirinçler Çekilmemiş Kırık (KK) pirinçler olmuştur. Başarı oranı %97'dir. En kötü tahmin edilen pirinçler de Az Çekilmiş Kırık (YK) pirinçler olmuştur. Başarı oranı %87'de kalmıştır (Grafik 4.14). Bu yöntemde dikkat çeken iki noktadan birincisi İkinci Kalite Tam (TT) ile Kırık (TK) arasındaki %13'lük tahmin başarısızlığıdır. İkinci nokta da

Uygulama 1 için bütün dięer yöntemlere kıyasla ilk kez karşılaşılan Olgunlaşmamış veya Çürümüş Kırık (KOK) ile Az Çekilmiş Kırık (YK) pirinçler arasındaki %10'u geçen tahmin başarısızlığıdır (Grafik 4.13 ve Grafik 4.14). Bu durumun sebebinin iki pirinç de kırık olduęu için büyüklük olmadığı muhtemeldir. Fotoęraflar incelendiğinde iki pirincin renklerine ait deęerlerin birbirine çok yakın deęerlere sahip oldukları görülmektedir. İki pirinç de gözle yeşil renge yakın olduęu görüldüğü için RGB renk uzayında RedMean ve BlueMean deęerleri bu durum referans alınmıştır (Grafik 4.15 ve Grafik 4.16).


**Uygulama 1 - Kernel Naive Bayes Sınıflandırıcı**

İK	783	58	2	10			1	21		
İT	7	1001		7	1			9		
KK			825		1	82			3	
KOK	1		4	947	33	1	3		10	6
KOT				15	936	8		1		5
KT			23		1	980				
TK	3			3	1		159	20		
TT	4	33		6			29	370		
YK			3	7	1				179	37
YT			6		3	2			36	835
	İK	İT	KK	KOK	KOT	KT	TK	TT	YK	YT
	Tahmin Edilen									


**Grafik 4.13.** Uygulama 1'in K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Sayıları



**Grafik 4.14.** Uygulama 1'in K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Yüzdeleri




**Grafik 4.15.** Uygulama 1 – K En Yakın Komşu Algoritması (KOK - YK Karşılaştırması 1), RedMean ve BlueMean Özelliklerine Göre



**Grafik 4.16.** Uygulama 1 – K En Yakın Komşu Algoritması (KOK - YK Karşılaştırması 2), RedMean ve BlueMean Özelliklerine Göre (Hatalı)

Tasarlanan DÖY modeli bu pirinçlerin tür ve durumlarına göre sınıflandırma işlemi için toplamda 50 devir (epoch) ile her bir devirde iterasyon sayısı 47 kez olmak üzere, toplamda 2350 iterasyonla gerçekleştirilmiş ve başarı oranı %82,05 olarak bulunmuştur (Tablo 4.1 ve Grafik 4.17). Bu rakam Uygulama 1 için en başarısız modelin DÖY olduğunu ortaya koymaktadır. Bunda biçimsel olarak DÖY'nin daha fazla katman ve daha ayrıntılı, uzun işlemlere –ve iterasyonlara- ihtiyaç duyması ve yine aynı şekilde daha büyük veri setlerinde daha iyi sonuçlar vermesi gösterilebilir. Yine diğer modellere kıyasla DÖY'nde başarısız tahmin edilen sınıflar sayısı Tablo 4.5'te ve oranı Tablo 4.6'da görüldüğü üzere daha fazladır.



**Grafik 4.17.** Derin Öğrenme Yöntemi'nin Uygulama 1 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))

**Tablo 4.5.** Uygulama 1'in Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları

Tahmin Edilen	<b>IT</b>	861	44	48	31	27		4	9	1	
	<b>IK</b>	26	772	19	16	16		9	8		9
	<b>TT</b>	17	22	372	18	5	1	2	1	4	
	<b>TK</b>	19	17	15	117	9	2	2	4		1
	<b>YT</b>	5	1	4	2	726	22	36	31	28	27
	<b>YK</b>	5		4		7	146	18	16	17	14
	<b>KT</b>	9	6	4	7	18	13	878	28	19	23
	<b>KK</b>	2			1	4	26	17	784	42	35
	<b>KOT</b>			8	5	29	27	42	53	765	36
	<b>KOK</b>	2	1	8	12	17	53	43	49	68	751
		<b>IT</b>	<b>IK</b>	<b>TT</b>	<b>TK</b>	<b>YT</b>	<b>YK</b>	<b>KT</b>	<b>KK</b>	<b>KOT</b>	<b>KOK</b>
	<b>Beklenen</b>										

**Tablo 4.6.** Uygulama 1'in Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri

Tahmin Edilen	IT	IK	TT	TK	YT	YK	KT	KK	KOT	KOK	84%	16%
	84,0%	4,3%	4,7%	3,0%	2,6%		0,4%	0,9%	0,1%		84%	16%
	3,0%	88,2%	2,2%	1,8%	1,8%		1,0%	0,9%		1,0%	88%	12%
	3,8%	5,0%	84,2%	4,1%	1,1%	0,2%	0,5%	0,2%	0,9%		84%	16%
	10,2%	9,1%	8,1%	62,9%	4,8%	1,1%	1,1%	2,2%		0,5%	63%	37%
	0,6%	0,1%	0,5%	0,2%	82,3%	2,5%	4,1%	3,5%	3,2%	3,1%	82%	18%
	2,2%		1,8%		3,1%	64,3%	7,9%	7,0%	7,5%	6,2%	64%	36%
	0,9%	0,6%	0,4%	0,7%	1,8%	1,3%	87,5%	2,8%	1,9%	2,3%	87%	13%
	0,2%			0,1%	0,4%	2,9%	1,9%	86,1%	4,6%	3,8%	86%	14%
			0,8%	0,5%	3,0%	2,8%	4,4%	5,5%	79,3%	3,7%	79%	21%
	0,2%	0,1%	0,8%	1,2%	1,7%	5,3%	4,3%	4,9%	6,8%	74,7%	75%	25%
	IT	IK	TT	TK	YT	YK	KT	KK	KOT	KOK		

**Beklenen****4.2. Pirinçlerin Türlerine Göre Sınıflandırılması (Uygulama 2)**

Pirinçlerin türlerine göre sınıflandırılması işleminde en başarılı yöntem İDDVM, en başarısız model DÖY olmuştur (Tablo 4.7). Sonuçlar gösterilirken her model için sınıflara ait beklenen/tahmin edilen sayıları ve yüzdeleri ayrı ayrı grafiklerle sunulmuştur.

**Tablo 4.7.** Uygulama 2'deki Başarı Oranları

Model	Başarı Oranı (%)
İkinci Dereceden Destek Vektör Makineleri (İDDVM)	98,9
Doğrusal Destek Vektör Makineleri (DDVM)	98,7
Karar Ağaçları (KA)	97,8
Çekirdek (Kernel) Naive Bayes Sınıflandırıcı (NBS)	97,8
K En Yakın Komşu Algoritması (KEYK)	97,5
Derin Öğrenme Yöntemi (DÖY)	97,05

Uygulama 2 için KA ile en iyi tahmin edilen pirinç türü Çekilmemiş (K) pirinçler olmuştur. Başarı oranı %99'un üzerindedir. Başarı oranı en düşük tür ise %91 ile İkinci Kalite (T) pirinç türü olmuştur. Uygulama 2 için KA'nın başarı oranını düşüren de tek başına bu pirinç türüdür. Bu pirinç türünün %8 ile Birinci Kalite (I) pirinçler ile arasında tahmin başarısızlığı vardır. Diğer türler arasında başarısızlık oranı eşit değerlerdedir (Grafik 4.18 ve Grafik 4.19).

**Uygulama 2 - Karar Ağaçları**

Beklenen	I	1853	2	2	43	
	K		1910	1	2	2
	KO	6	1	1939	2	22
	T	49		7	572	
	Y		2	27		1080
		/	←	↻	→	↘
		Tahmin Edilen				

**Grafik 4.18.** Uygulama 2'nin Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Sayıları

**Uygulama 2 - Karar Ağaçları (%)**

Beklenen	I	98%	<1%	<1%	2%		98%	2%
	K		>99%	<1%	<1%	<1%	>99%	<1%
	KO	<1%	<1%	98%	<1%	1%	98%	2%
	T	8%		1%	91%		91%	9%
	Y		<1%	2%		97%	97%	3%
		/	←	↻	→	↘	True Positive Rate	False Negative Rate
		Tahmin Edilen						

**Grafik 4.19.** Uygulama 2'nin Karar Ağaçları'na Göre Beklenen / Tahmin Edilen Yüzdeleri

DDVM pirinçlerin türlerine göre sınıflandırma işleminde bütün pirinç türlerinde %99 ve üzeri başarı oranına ulaşmıştır. Bu uygulamada da DDVM için yine KA'ndaki gibi İkinci Kalite (T) pirinç türü başarı oranını düşüren pirinç türü olmuştur. Bu pirinç türü ile Birinci Kalite (I) pirinç türü arasında

%7 oranında tahmin başarısızlığı vardır. Diğer türler arasında başarısızlık oranı eşit değerlerdedir (Grafik 4.20 ve Grafik 4.21). DDVM'nin bu uygulama için sonuçları KA'na çok benzerdir.

**Uygulama 2 - Doğrusal Destek Vektör Makineleri**

Beklenen	I	1879		5	16	
	K		1907	7		1
	KO	2	1	1961	1	5
	T	41		3	584	
	Y		4	9		1096
		/	←	← <sub>0</sub>	→	↘
		Tahmin Edilen				

**Grafik 4.20.** Uygulama 2'nin Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları

**Uygulama 2 - Doğrusal Destek Vektör Makineleri (%)**

Beklenen	I	99%		<1%	1%			99%	1%
	K		>99%	<1%		<1%		>99%	<1%
	KO	<1%	<1%	>99%	<1%	<1%		>99%	<1%
	T	7%		<1%	93%			93%	7%
	Y		<1%	1%		99%		99%	1%
		/	←	← <sub>0</sub>	→	↘			
		Tahmin Edilen						True Positive Rate	False Negative Rate

**Grafik 4.21.** Uygulama 2'nin Doğrusal Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri



Uygulama 2 için Uygulama 1 gibi yine en başarılı model İDDVM olmuştur. Başarı oranı toplamda %98,9'dur. Bu modelde İkinci Kalite (T) hariç diğer bütün pirinç türlerinde başarı oranı %99'un üzerindedir. İkinci Kalite (T) pirinç türünün bu modelde başarı oranı %94'tür (Grafik 4.22 ve Grafik 4.23). Fakat bu rakam pirinçlerin türlerine göre sınıflandırma işleminde diğer modellere kıyasla en yüksek değerdir.

**Uygulama 2 - İkinci Dereceden Destek Vektör Makineleri**

Beklenen	I	1882	1	2	15	
	K	1	1910	2		2
	KO	1	3	1962	2	2
	T	34		4	590	
	Y		4	10		1095
		/	ı	ı <sub>0</sub>	ı	ı
		Tahmin Edilen				

**Grafik 4.22.** Uygulama 2'nin İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Sayıları

**Uygulama 2 - İkinci Dereceden Destek Vektör Makineleri (%)**

Beklenen	Tahmin Edilen					True Positive Rate	False Negative Rate
	/	↑	↑ <sub>0</sub>	↓	↓		
I	99%	<1%	<1%	1%		99%	1%
K	<1%	>99%	<1%		<1%	>99%	<1%
KO	<1%	<1%	>99%	<1%	<1%	>99%	<1%
T	5%		1%	94%		94%	6%
Y		<1%	1%		99%	99%	1%

**Grafik 4.23.** Uygulama 2'nin İkinci Dereceden Destek Vektör Makinelerine Göre Beklenen / Tahmin Edilen Yüzdeleri

Uygulama 2 için NBS ile en iyi tahmin edilen pirinç türü Çekilmemiş (K) pirinçler olmuştur. Başarı oranı %99'un üzerindedir. En düşük başarı oranı %89 ile bu uygulamada yine diğer modellerde olduğu gibi İkinci Kalite (T) pirinç türünde olmuştur (Grafik 4.24 ve Grafik 4.25).

**Uygulama 2 - Kernel Naive Bayes Sınıflandırıcı**

Beklenen	Tahmin Edilen				
	/	↑	↑ <sub>0</sub>	↓	↓
I	1868	2	19	11	
K		1911	2		2
KO	2	12	1934	4	18
T	58		11	559	
Y		12	12	1	1084

**Grafik 4.24.** Uygulama 2'nin Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Sayıları

Uygulama 2 - Kernel Naive Bayes Sınıflandırıcı (%)

Beklenen	Tahmin Edilen					True Positive Rate	False Negative Rate
	/	ı	ıo	ı	ı		
I	98%	<1%	1%	1%		98%	2%
K		>99%	<1%		<1%	>99%	<1%
KO	<1%	1%	98%	<1%	1%	98%	2%
T	9%		2%	89%		89%	11%
Y		1%	1%	<1%	98%	98%	2%

**Grafik 4.25.** Uygulama 2'nin Naive Bayes Sınıflandırıcıya Göre Beklenen / Tahmin Edilen Yüzdeleri

KEYK modeli ile pirinçlerin türlerine göre sınıflandırma işlemi diğer modellere benzer sonuçlar elde edilmiştir. Fakat bu modelde diğer modellere kıyasla özellikle Az Çekilmiş (Y) pirinç türündeki %97'ye düşen başarı oranı göze çarpmaktadır (Grafik 4.27). Bununla beraber pirinçlerin türüne göre sınıflandırma işlemi için KEYK modeli türler arası en az hatalı ayrımı yapan modeldir. Bu durum Grafik 4.26'daki beyaz bölümlerden görülebilir.

**Uygulama 2 - K En Yakın Komşu Algoritması**

Beklenen	I	1857			43	
	K		1894	14		7
	KO	3	9	1938	1	19
	T	54		2	572	
	Y		7	29		1073
		/	←	← <sub>0</sub>	→	→
		Tahmin Edilen				

**Grafik 4.26.** Uygulama 2'nin K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Sayıları


**Uygulama 2 - K En Yakın Komşu Algoritması (%)**

Beklenen	I	98%			2%		98%	2%
	K		99%	1%		<1%	99%	1%
	KO	<1%	<1%	98%	<1%	1%	98%	2%
	T	9%		<1%	91%		91%	9%
	Y		1%	3%		97%	97%	3%
		/	←	← <sub>0</sub>	→	→	True Positive Rate	False Negative Rate
		Tahmin Edilen						

**Grafik 4.27.** Uygulama 2'nin K En Yakın Komşu Algoritması'na Göre Beklenen / Tahmin Edilen Yüzdeleri

Tasarlanan DÖY modeli pirinçlerin türlerine göre sınıflandırma işleminde toplamda 50 devir (epoch) ile her bir devirde iterasyon sayısı 23 kez olmak üzere, toplamda 1150 iterasyonla gerçekleştirilmiş ve başarı oranı %97,05 olarak bulunmuştur (Tablo 4.5 ve Grafik 4.28). Bu orana

rağmen Uygulama 2 için en başarısız model DÖY olmuştur. Buna sebebin yine Uygulama 1’deki gibi biçimsel olarak DÖY’nin daha fazla katman ve daha ayrıntılı, uzun işlemlere –ve iterasyonlara- ihtiyaç duyması ve yine aynı şekilde daha büyük veri setlerinde daha iyi sonuçlar vermesi gösterilebilir. Yine diğer modellere kıyasla DÖY’nde bütün pirinç türlerine başarısız tahmin edilen sınıflar vardır. Bu duruma ait sayılar Tablo 4.8’de, oranlar Tablo 4.9’da görülmektedir.



**Grafik 4.28.** Derin Öğrenme Yöntemi'nin Uygulama 2 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))

**Tablo 4.8.** Uygulama 2'nin Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları

<b>Tahmin Edilen</b>	<b>I</b>	1732	37	35	49	41
	<b>T</b>	3	619	3	2	1
	<b>Y</b>	4	3	1095	6	1
	<b>K</b>	1	1	5	1902	6
	<b>KO</b>	3	2	4	9	1952
		<b>I</b>	<b>T</b>	<b>Y</b>	<b>K</b>	<b>KO</b>
<b>Beklenen</b>						

**Tablo 4.9.** Uygulama 2'nin Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri

Tahmin Edilen	<b>I</b>	91,2%	1,9%	1,8%	2,6%	2,2%	91%	9%
	<b>T</b>	0,5%	98,6%	0,5%	0,3%	0,2%	99%	1%
	<b>Y</b>	0,4%	0,3%	98,7%	0,5%	0,1%	99%	1%
	<b>K</b>	0,1%	0,1%	0,3%	99,3%	0,3%	99%	1%
	<b>KO</b>	0,2%	0,1%	0,2%	0,5%	99,1%	99%	1%
		<b>I</b>	<b>T</b>	<b>Y</b>	<b>K</b>	<b>KO</b>		
<b>Beklenen</b>								

### 4.3. Pirinçlerin Durumlarına Göre Sınıflandırılması (Uygulama 3)

Pirinçlerin durumlarına göre sınıflandırılması işleminde en başarılı yöntem İDDVM, en başarısız model DÖY olmuştur (Tablo 4.10). Bu uygulamaya ait sonuçlar, KA, DDVM, İDDVM, KEYK ve NBS için türlere ait beklenen/tahmin edilen sayıları ve yüzdeleri Tablo 4.11'de gösterilmiştir.


**Tablo 4.10.** Uygulama 3'teki Başarı Oranları

Model	Başarı Oranı (%)
İkinci Dereceden Destek Vektör Makineleri (İDDVM)	98,5
Doğrusal Destek Vektör Makineleri (DDVM)	97,5
K En Yakın Komşu Algoritması (KEYK)	96,7
Karar Ağaçları (KA)	96,6
Çekirdek (Kernel) Naive Bayes Sınıflandırıcı (NBS)	93,7
Derin Öğrenme Yöntemi (DÖY)	81,14

**Tablo 4.11.** Uygulama 3'ün Modellerdeki Tahmin Sayıları Ve Başarı Yüzdeleri

Tahmin	KA		DDVM		İDDVM		NBS		KEYK	
	Doğru	Yanlış	Doğru	Yanlış	Doğru	Yanlış	Doğru	Yanlış	Doğru	Yanlış
Kırık	3058	146	3075	129	3122	82	2860	344	3079	125
Tam	4209	109	4256	69	4279	39	4190	128	4192	126
Yüzde	95,44	4,56	95,97	4,03	97,44	2,56	89,26	10,74	96,10	3,90
	97,48	2,52	98,4	1,60	99,1	0,9	97,04	2,96	97,08	2,92

Uygulama 3 için tasarlanan DÖY modeli toplamda 50 devir (epoch) ile her bir devirde iterasyon sayısı 23 kez olmak üzere, toplamda 1150 iterasyonla gerçekleştirilmiş ve başarı oranı %81,14 olarak bulunmuştur (Grafik 4.29). Uygulama 3 için en başarısız model DÖY olmuştur. Buna sebebin diğer iki uygulamada da olduğu gibi biçimsel olarak DÖY'nin daha fazla katman ve daha ayrıntılı, uzun işlemlere –ve iterasyonlara- ihtiyaç duyması ve yine aynı şekilde daha büyük veri setlerinde daha iyi sonuçlar vermesi gösterilebilir. Bu uygulamada DÖY için en çarpıcı sonuç sınıflandırmada %70'e düşen başarı oranıdır ki diğer uygulamalarda hiçbir yöntemde başarı oranı bu kadar düşük gözlemlenmemiştir (Tablo 4.12 ve Tablo 4.13).



**Grafik 4.29.** Derin Öğrenme Yöntemi'nin Uygulama 3 İçin Eğitim Ve Kayıp Grafiği (Renkli Çizgiler Eğitim, Siyah Çizgi Doğrulama (Validation))

**Tablo 4.12.** Uygulama 3'ün Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Sayıları

<b>Tahmin Edilen</b>	<b>Tam</b>	3861	457
	<b>Kirik</b>	962	2242
		<b>Tam</b>	<b>Kirik</b>
<b>Beklenen</b>			

**Tablo 4.13.** Uygulama 3'ün Derin Öğrenme Yöntemi'ne Göre Beklenen / Tahmin Edilen Yüzdeleri

<b>Tahmin Edilen</b>	<b>Tam</b>	89,4%	10,6%
	<b>Kirik</b>	30,0%	70,0%
		<b>Tam</b>	<b>Kirik</b>
<b>Beklenen</b>			

## 5. TARTIŞMA VE ÖNERİLER

Bu tez çalışması kapsamında 5 farklı pirinç türüne ait 2 farklı durumdaki 10 farklı sınıf ilkinde, sonrasında sadece türlerine göre 5 farklı sınıf ve en son olarak da durumlarına göre 2 farklı sınıf olmak üzere toplamda üç farklı uygulamada altı farklı makine öğrenmesi yöntemi ile ele alınmış ve bu sınıflandırma işlemlerinin başarı oranları paylaşılmıştır. Bütün uygulamalarda İDDVM en başarılı makine öğrenmesi yöntemi olarak bulunmuştur. Bunda İDDVM'nin pirinçlerin tür ve durumlarına göre sınıflandırılması işleminde diğer yöntemlere kıyasla non-linear (doğrusal olmayan) ayırıcı kullanması etkili olmuştur. Zira tez çalışması kapsamında ele alınan gibi gerçek hayattaki bir problemin çözümünde de verilerin doğrusal olarak ayrılması mümkün değildir.

İDDVM hiçbir uygulamada %97 başarı oranının altına düşmemiştir. Bu durum gerçek hayatta karşılaşılabilecek pirinç gibi küçük ölçekli tarımsal ürünlerin veya cisimlerin sınıflandırılması işleminde İDDVM'nin başarılı sonuçlar vereceği yönünde bir kanıyı ortaya koymaktadır. Bunlara ek olarak İDDVM'nin uygulama alanı ve pratikliği de göz önünde bulundurulursa ilgili sektördeki sınıflandırma problemi için önemli bir çözüm yöntemi olduğu düşüncesi ağırlık kazanmıştır.

Genel olarak sonuçlar incelendiğinde DDVM'sinin bütün uygulamalarda başarı oranında ikinci sırada olduğu görülmektedir. KA, NBS, KEYK yöntemlerinin bu iki yöntemin gerisinde kalması, bahsi geçen yöntemlerin DDVM ve İDDVM'ne göre daha küçük boyutlu veri setlerinde başarılı olmalarıyla nedenlendirilebilir.

Pirinçlerin tür ve durumlarına göre sınıflandırılması (Uygulama 1) işlemi için KA, DDVM, İDDVM, KEYK ve NBS yöntemlerine ait sonuçlar ve sonuçlara ilişkin grafikler toplu olarak değerlendirildiğinde her pirinç sınıfı için aşağıdaki yargılara ulaşılmıştır;

1- Birinci Kalite Tam (IT) pirinç ile Çekilmemiş Kırık (KK), İkinci Kalite Kırık (TK), Az Çekilmiş Kırık (YK) ve Az Çekilmiş Tam (YT) pirinçler arasında sınıflandırmada hata yoktur.

2- Birinci Kalite Kırık (IK) pirinç ile Olgunlaşmamış veya Çürümüş Tam (KOT), Çekilmemiş Tam (KT), Az Çekilmiş Kırık (YK) ve Az Çekilmiş Tam (YT) pirinçler arasında sınıflandırmada hata yoktur.

3- Çekilmemiş Kırık (KT) pirinç ile Birinci Kalite Tam (IT) ve Kırık (IK), İkinci Kalite Tam (TT) ve Kırık (TK) ve Az Çekilmiş Kırık (YT) pirinçler arasında sınıflandırmada hata yoktur.

4- Çekilmemiş Kırık (KK) pirinç ile Birinci Kalite Tam (IT), Birinci Kalite Kırık (IK), İkinci Kalite Tam (TT), İkinci Kalite Kırık (TK), ve Az Çekilmiş Tam (YT) pirinçler arasında sınıflandırmada hata yoktur.

5- Olgunlaşmamış veya Çürümüş Tam (KOT) pirinç ile Birinci Kalite Tam (IT), Birinci Kalite Kırık (IK) ve Çekilmemiş Kırık (KK) pirinçler arasında sınıflandırmada hata yoktur.

6- Olgunlaşmamış veya Çürümüş Kırık (KOK) pirinç ile Birinci Kalite Tam (IT) ve İkinci Kalite Tam (TT) pirinçler arasında sınıflandırmada hata yoktur.



7- İkinci Kalite Tam (TT) pirinç ile Çekilmemiş Tam (KT) ve Kırık (KK), Az Çekilmiş Tam (YT) ve Kırık (YK) pirinçler arasında sınıflandırmada hata yoktur.

8- İkinci Kalite Kırık (TK) pirinç ile Birinci Kalite Tam (IT), Çekilmemiş Tam (KT) ve Kırık (KK), Az Çekilmiş Tam (YT) ve Kırık (YK) pirinçler arasında sınıflandırmada hata yoktur.

9- Az Çekilmiş Kırık (YT) pirinç ile Birinci Kalite Tam (IT) ve Kırık (IK), İkinci Kalite Tam (TT) ve Kırık (TK) pirinçler arasında sınıflandırmada hata yoktur.

10- Az Çekilmiş Kırık (YK) pirinç ile Birinci Kalite Tam (IT) ve Kırık (IK), Çekilmemiş Tam (KT), İkinci Kalite Tam (TT) ve Kırık (TK) pirinçler arasında sınıflandırmada hata yoktur.

Bu sonuçlar ışığında bu sınıflandırma temel alınacak problemlerde birbirinden hatasız ayrılması muhtemel pirinç sınıflarını ortaya konulmuştur. Yine pirinçlerin tür ve durumlarına göre sınıflandırılması (Uygulama 1) işlemi için KA, DDVM, İDDVM, KEYK ve NBS yöntemlerine ait sonuçlar ve sonuçlara ilişkin grafikler toplu olarak değerlendirildiğinde ulaşılabilecek diğer bir yorum da sınıflandırma işlemindeki hata oranı yüksek pirinç sınıflarına ilişkindir. Bunlar da sırasıyla,

1- Birinci Kalite Tam (IT) ve Birinci Kalite Tam (IK) pirinç sınıflarının, İkinci Kalite Tam (TT) ve İkinci Kalite Kırık (TK) pirinç sınıfları arasında ayırmda hata oranı yüksektir.

2- Olgunlaşmamış veya Çürümüş Tam (KOT) ve Olgunlaşmamış veya Çürümüş Kırık (KOK) pirinç sınıflarının, Az Çekilmiş Kırık (YK) ve Az Çekilmiş Tam (YT) pirinç sınıfları arasında ayırmda hata oranı yüksektir.

Pirinçlerin türlerine göre sınıflandırılması (Uygulama 2) işleminde bütün yöntemler diğer bütün uygulamalardaki başarı oranlarının üzerinde sonuç vermişlerdir. Bu uygulamadaki başarı oranını düşüren ana etken Birinci Kalite (I) pirinçler ile İkinci Kalite (T) pirinçler arasındaki benzerlik olmuştur. Yine de bu uygulama için başarı oranı hiçbir yöntemde %97'nin altına düşmediğinden pirinçlerin sınıflandırılması probleminin en iyi çözümünün pirinçlerin türlerine göre sınıflandırılması işlemi olduğu ortaya konulmuştur. Pirinçlerin türlerine göre sınıflandırılması işlemi için KA, DDVM, İDDVM, KEYK ve NBS yöntemlerine ait sonuçlar ve sonuçlara ilişkin grafikler toplu olarak değerlendirildiğinde pirinç türü sınıflandırılması işlemi için aşağıdaki yargılara ulaşılmıştır;

1- Birinci Kalite (I) pirinç türü ile Az Çekilmiş (Y) pirinç türü arasında sınıflandırmada hata yoktur.

2- İkinci Kalite Tam (T) pirinç türü ile Çekilmemiş (K) ve Az Çekilmiş (Y) pirinç türleri arasında sınıflandırmada hata yoktur.

3- Az Çekilmiş (Y) pirinç türü ile Birinci Kalite (I) pirinç türü arasında sınıflandırmada hata yoktur.

Gerek pirinçlerin tür ve durumlarına göre sınıflandırılması (Uygulama 1) işleminde, gerekse pirinçlerin türlerine göre sınıflandırılması (Uygulama 2) işleminde Çekilmemiş (K) pirinç türü sınıflandırılması en başarılı pirinç türü olmuştur. Bu türün sınıflandırılmasında başarı oranının yüksek olması pirinç kabuğunun diğerlerinden bariz şekilde farklı bir renge (Kırmızı) sahip olmasıdır ki ilgili sektörde çekilmeyen pirinçlerin yeniden işleme tabi tutulduğu göz önünde bulundurulursa mevcut çeltik

çekme makinelerinin geliştirilmesi için gerçekleştirilecek bir projede ilk adım olarak bu pirinç türünün ayrımı ele alınabilir.

Pirinçlerin durumlarına göre sınıflandırılması (Uygulama 3) işleminde iki sınıf üzerinden işlemin gerçekleştirilmesi her ne kadar problemin basite indirildiğini gösterse de pirinç boyutunun ve şeklinin daha önem kazandığı bu uygulamada veri setinin bazı yönleriyle kırılarak (en, boy ve muhtemel pirinç boyutu vb. özellikler) işlenmemiş olması başarı oranının düşmesinde temel etkidir. Yine aynı şekilde kırık pirinçlerin tam pirinçlere kıyasla şeklen farklı bir yapıda olması ve çalışmada işlenen veri setinde bunu belirtir bir özelliğin yer almamış olması bu uygulamadaki başarı oranını düşüren sebeplerdendir.

DÖY'nin diğer bütün makine öğrenmesi yöntemlerinden daha yeni ve daha gelişmiş sonuçlar almaya olanak sağladığı bilinmesine rağmen tezde ele alınan sınıflandırma işlemlerine ilişkin uygulamalardan hepsinde diğer yöntemlerin gerisinde kalması başarısız olduğu anlamına gelmez. Bu duruma birinci etkenin DÖY'nin daha büyük veri setlerinin işlenmesinde kullanıldığı göz önünde bulundurulmalıdır. Tezde ele alınan veri seti 7000'in üzerinde veriyi içerirken, DÖY ile ele alınan temel problemlerde bu sayı çoğu zaman tek bir sınıfa ait örnek sayısını gösterir ki bu açıdan DÖY'nin bu çalışmada diğer yöntemlere kıyasla başarısız olması veri seti ile alakalıdır denebilir. İkinci bir etken DÖY'nin verileri ele alırken biçimsel özellikleri gibi bir takım özellikler üzerinden de eğitildiği hususudur. Bu çalışmada bu durum ele alınmamıştır. DÖY'nin başarı oranının düşmesinde göz önünde bulundurulması gereken üçüncü etken de DÖY ile çözülecek problemlerde, problemin temel unsurlarının ele alınarak ayrı ayrı modellerin geliştirilmesi gerekliliğidir. Bununla beraber daha fazla katman, daha fazla evrişim ve daha fazla devir sayısı ile ağın eğitimi gerekliliği bulunurken bu çalışmada bu hususlar da veri setinin küçüklüğü nedeniyle ihmal edilmek zorunda kalmıştır. Bütün bunlara rağmen DÖY bu çalışmada kullanılarak küçük veri setleriyle ve az katmanlı, düşük devir sayılı DÖY modellerinin eğitimleriyle de hatırı sayılabilecek sonuçlar elde edilmesine imkân sağladığı ortaya konmuştur.

Bu yapılan çalışma sonucunda gelecekte çalışmalar için konu problemin çözümünde kullanılmak üzere geliştirilecek bir yazılım için çalışmaya konu makine öğrenmesi yöntemlerinden hangisi kullanılırsa kullanılsın, daha yüksek başarı oranı için doğru algoritma, pirinçlerin durumları (Uygulama 3) ve ardından pirinçlerin türleri (Uygulama 2) şeklinde hiyerarşik bir sıralamayı takip etmelidir. Zira ilk olarak pirinçlerin durumlarına göre kırık, tam şeklinde sınıflandırılması ardından türlerine göre ayrımının en yüksek başarı oranını vermesi muhtemeldir. Bununla birlikte önce ön bir işlem olarak Çekilmemiş (K) pirinç türünün en başta harmandan ayrılmasının yine başarı oranını yükseltmesi beklenir. Fakat bu ön işlemin zaman kısmını etkileyeceği de göz önünde bulundurulmalıdır.

## KAYNAKLAR

- [1]. Akpınar, H. (2014). *Data - Veri Madenciliği Veri Analizi*. Papatya Bilim.
- [2]. Kubat, C. (2014). *Matlab Yapay Zeka ve Mühendislik Uygulamaları*. İstanbul, Türkiye: Pusula Yayıncılık Ve İletişim.
- [3]. Savakar, D., Anami, B. (2009). Recognition and Classification of Food Grains, Fruits and Flowers Using Machine Vision. *International Journal of Food Engineering*, 5(4), pp.
- [4]. Hayıt, T., Erbay, H., Hayıt, F. (2018). Gıda Sektöründe Uygulanan Görüntü İşleme Çalışmalarının ve Tekniklerinin İncelenmesi. *Electronic Letters on Science and Engineering*, 14 (1), 12-22. 16 Temmuz 2019 tarihinde <https://dergipark.org.tr/tr/pub/else/issue/38882/424360> adresinden erişildi.
- [5]. Sofu, M., Er, O., Kayacan, M.C., Cetişli, B. (2013). “Elmaların görüntü işleme yöntemi ile sınıflandırılması ve leke tespiti”. *Gıda Teknolojileri Elektronik Dergisi*, vol. 8, no. 1, pp:12-25.
- [6]. Sabancı, K. C. (2012). Görüntü İşleme ve Yapay Sinir Ağları Yardımıyla Patates Sınıflandırma Parametrelerinin Belirlenmesi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2.2 Sp: A*, s 59-62.
- [7]. Zhang Y., Wu L. (2012). Classification of Fruits Using Computer Vision and a Multiclass Support Vector Machine. *Sensors 2012*, 12, 12489-12505; doi:10.3390/s120912489.
- [8]. Ataş, M. (2016). Fıstık sınıflandırma sistemi için Siirt fıstığı imgelerinden gürbüz özneliklerin çıkarılması. Siirt, Türkiye.
- [9]. Balcı, M. A. (2016). Görüntü İşleme Teknikleri Kullanılarak Napolyon Tipi Kirazların Sınıflandırılması. *Selçuk Teknik Dergisi 15.3*, s 221-237.
- [10]. Solak, S. A. (2018). Görüntü işleme teknikleri ve kümeleme yöntemleri kullanılarak fındık meyvesinin tespit ve sınıflandırılması. *Sakarya University Journal of Science 22.1*, s 56-65.
- [11]. Bul E., Gelen G., Altun H. (2015). Görüntü İşlemeye Dayalı Tarımsal Ürün Sınıflandırma. [http://www.emo.org.tr/ekler/3287fccc194dbd9\\_ek.pdf](http://www.emo.org.tr/ekler/3287fccc194dbd9_ek.pdf) adresinde 5 Ağustos 2019 tarihinde erişildi.
- [12]. Ishikawa T., Hayashi A., Nagamatsu S., Kyutoku Y., Dan I., Wada T., Oku K., Saeki Y., Uto T., Tanabata T., Isobe S., Kochi N. (2018). Classification Of Strawberry Fruit Shape By Machine Learning. *ISPRS TC II Mid-term Symposium “Towards Photogrammetry 2020”, 4–7 June 2018, Riva del Garda, Italy*
- [13]. Claesson, L. H. (2015). *Classification of Traffic Signs and Detection of Alzheimer’s Disease from Images*. Master’s thesis in Communication Engineering and Biomedical Engineering. Gothenburg, Sweden: Chalmers University of Technology.
- [14]. Sa I., Ge Z., Dayoub F., Upcroft B., Perez T., McCool C. (2016). DeepFruits: A Fruit Detection System Using Deep Neural Networks. *Sensors*, ISSN 1424-8220.
- [15]. Şeker, A. Y. (2017). Stacked Autoencoder Method for Fabric Defect Detection. Sivas, Türkiye.
- [16]. Razavi S., Yalcin H. (2017) Using convolutional neural networks for plant classification *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya, 2017, pp. 1-4.
- [17]. Food and Agriculture Organization of the United Nations. 1 Temmuz 2019 tarihinde <http://www.fao.org/faostat/en/#data/QC> adresinden erişildi.
- [18]. Smith, B. D. (1998). *The Emergence of Agriculture*. *Scientific American Library*. New York: ISBN 0-7167-6030-4.
- [19]. Nutrient data laboratory. United States Department of Agriculture 5 Mayıs 2019 tarihinde <https://fdc.nal.usda.gov/> adresinden erişildi.
- [20]. Jose, J. (2016). *Oryza sativa. Kadavoor, Kerala, India*. 7 Haziran 2019 tarihinde <https://zoomsoc.com/about/5bb636977bba220016bfb64e/oryza-sativa> adresinden erişildi.
- [21]. Gelişim Laboratuvar. 18 Temmuz 2019 tarihinde <http://www.gelisimlaboratuvar.com/celtik-pirinc-isleme-makineleri/> adresinden erişildi.
- [22]. Gupta, S. M. (2013). Sobel Edge Detection Algorithm. Bhillai, India .
- [23]. The Persistence Of Vision Raytracer (POV-Ray). (2008). 8 Ocak 2019 tarihinde <http://lib.povray.org/searchcollection/index2.php> adresinden erişildi.
- [24]. Stokes Michael, M. A. (1993). *A Standard Default Color Space for the Internet – sRGB*. 6 Ocak 2019 tarihinde <https://www.w3.org/Graphics/Color/sRGB> adresinden erişildi.
- [25]. Agoston, M. K. (2010). *Computer Graphics and Geometric Modelling*. Springer Science & Business Media
- [26]. Paulschou. (2009). *A CIE-1931 diagram in L\*A\*B\* color space for accurate matching calibrated displays or printers*. 7 Eylül 2018 tarihinde [https://www.123rf.com/photo\\_62145891\\_stock-vector-cie-](https://www.123rf.com/photo_62145891_stock-vector-cie-)

chromaticity-diagram-describes-color-as-seen-by-the-human-eye-in-full-daylight-two-dimensional-d.html adresinden eriřildi.

[27]. Consortium, I. C. (2004). *Specification ICC.1:2004-10 (Profile version 4.2.0.0) Image technology colour management — Architecture, profile format, and data structure [REVISION of ICC.1:2003-09]*. 30 Ocak 2019 tarihinde [http://www.color.org/ICC1v42\\_2006-05.pdf](http://www.color.org/ICC1v42_2006-05.pdf) adresinden eriřildi.

[28]. Haralick Robert M., S. K. (1973). Textural Features For Image Classification. *IEEE Transactions On Systems, Man And Cybernetics*, pp. 610-621.

[29]. Mryka Hall-Beyer, P. (2017). *GlcM Texture: A Tutorial v. 3.0*. Calgary, Alberta, Canada: Department of Geography University of Calgary.

[30]. Albregtsen, F. (2008). Statistical Texture Measures Computed from Gray Level Coocurrence Matrices. *Image Processing Laboratory Department of Informatics University of Oslo*.

[31]. Clausi, D. A. (2002). An analysis of co-occurrence texture statistics as a function of grey level quantization. *Journal canadien de télédetection Volume 28, 2002 - Issue 1*.

[32]. Chauhan, P. K.-N.-V.-D. (2011). Performans Evaluation of Decision Tree versus Artificial Neural Network Based Classifiers in Diversity of Datasets. *World Congress on Information and Communication Technologies (WICT 2011)*, (s. pp. 799). Mumbai.

[33]. Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*. pp. 144-152.

[34]. Kavzođlu T., Çölkesen İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi Temmuz 2010 Sayı 144*. ss 73-82.

[35]. Kubat, C. (2014). *Matlab Yapay Zeka ve Mühendislik Uygulamaları*. İstanbul, Türkiye: Pusula Yayıncılık Ve İletişim Yayınları.

[36]. Dahl George E., J. N. (2012). *Multi-task Neural Networks for QSAR Predictions*. Toronto, Ontario, Canada: Department of Computer Science, University of Toronto.

[37]. The Microsoft Cognitive Toolkit. (2019). 30 Haziran 2019 tarihinde [https://www.cntk.ai/pythondocs/CNTK\\_201B\\_CIFAR-10\\_ImageHandsOn.html](https://www.cntk.ai/pythondocs/CNTK_201B_CIFAR-10_ImageHandsOn.html) adresinden eriřildi.

[38]. Convolutional Neural Networks. (2019). 30 Haziran 2019 tarihinde <https://mzhaoshuai.github.io/2017/12/30/2017-12-30-Convolutional-Neural-Networks/> adresinden eriřildi.

[39]. AtomNet. (2019). 1 Temmuz 2019 tarihinde <https://www.atomwise.com/our-technology/> adresinden eriřildi.

[40]. CS231n Convolutional Neural Networks for Visual Recognition. (2019). 3 Temmuz 2019 tarihinde <http://cs231n.github.io/convolutional-networks/> adresinden eriřildi.

[41]. Ba, Jimmy, Kiros, J., Hinton, G. (2016). Layer Normalization. arXiv:1607.06450.

[42]. Salimans T., D. P. (2016). Weight Normalization: A Simple Reparameterization to Accelerate Training of Deep Neural Networks.

[43]. Weight Normalization and Layer Normalization Explained. (2019). 1 Ağustos 2019 tarihinde <https://mlexplained.com/2018/01/13/weight-normalization-and-layer-normalization-explained-normalization-in-deep-learning-part-2/> adresinden eriřildi.

[44]. Multi-Class Neural Networks: Softmax. (2019). 1 Temmuz 2019 tarihinde <https://developers.google.com/machine-learning/crash-course/multi-class-neural-networks/softmax> adresinden eriřildi.

## ÖZGEÇMİŞ

**Adı ve Soyadı** : Kıvanç ERMEYDAN

**Doğum Tarihi** : 13.01.1986

**E-mail** : kivancermeydan@gmail.com

**Öğrenim Durumu** :

Derece	Bölüm/Program	Üniversite	Yıl
Ön Lisans	Bilgisayar Programcılığı	Çukurova Üniversitesi	2004-2006
Lisans	Bilgisayar Ve Öğretim Teknolojileri Eğitimi	Çukurova Üniversitesi	2007-2009
Yüksek Lisans	Bilgisayar Mühendisliği (Tezsiz)	Hoca Ahmet Yesevi Üniversitesi	2012-2014
Yüksek Lisans	İmalat Mühendisliği	Tarsus Üniversitesi	2015-

**Görevler** :

Görev Ünvanı	Görev Yeri	Yıl
Yönetici	Ekidne Bilgisayar Ticareti, Yazılım Ve Reklam	2011 - 2013
Öğretim Görevlisi	Avrasya Üniversitesi	2013 - 2014
Öğretim Görevlisi	Osmaniye Korkut Ata Üniversitesi	2014 -

### ESERLER (Makaleler ve Bildiriler)

1. Ermeydan K., Ersöz Kaya İ., İş Kazası Geçirme Riskinin Cinsiyet Ve Yaş Gruplarına Göre Sayısal Yöntemlerle Analizi: Türkiye Örnek Çalışması, 2016, 1st International Mediterranean Science and Engineering Congress