



**İSKENDERUN TEKNİK**

**ÜNİVERSİTESİ**

**MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK  
LİSANS  
TEZİ**

**GÜNCEL MAKİNE ÖĞRENMESİ  
TEKNİKLERİ İLE İRİS  
GÖRÜNTÜLERİNDEN CİNSİYET  
ANALİZİ**

**Tuğba AÇIL**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ  
ANABİLİM DALI**

**HAZİRAN 2019**



**GÜNCEL MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE İRİS  
GÖRÜNTÜLERİNDEN CİNSİYET ANALİZİ**

**Tuğba AÇIL**

**YÜKSEK LİSANS TEZİ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

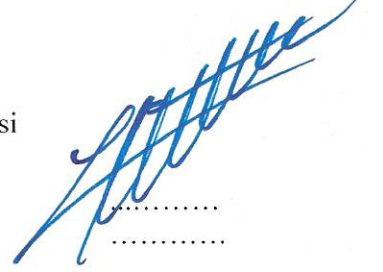
**Haziran 2019**

Tuğba AÇIL tarafından hazırlanan “GÜNCEL MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE İRİS GÖRÜNTÜLERİNDEN CİNSİYET ANALİZİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / OY ÇOKLUĞU ile İskenderun Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Doç. Dr. Yakup KUTLU

Elektrik-Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



**Başkan:** Doç. Dr. Sertan ALKAN

Elektrik-Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



**Üye:** Dr. Öğr. Üyesi Mustafa YENİAD

Bilgisayar Mühendisliği Anabilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum.



Tez Savunma  
Tarihi:

10/06/2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.



Mühendislik Fakültesi Enstitüsü Müdürü

## ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülediğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.



İmza

Tuğba AÇIL

10/06/2019

# GÜNCEL MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE İRİS GÖRÜNTÜLERİNDEN CİNSİYET ANALİZİ

(Yüksek Lisans Tezi)

Tuğba AÇIL

İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2019

## ÖZET

Son zamanlarda artan nüfus miktarından dolayı, veri tabanında arama yaparken aranılan kişinin cinsiyetinin belirlenmesi veri tabanındaki veri sayısının yarıya indirilmesi demektir bu da bize zaman açısından büyük bir kolaylık sağlayacaktır. Bunun yanısıra cinsiyet tespit sistemi cinsiyet tabanlı erişim kontrol gerektiren güvenlik uygulamalarında, sadece belirli bir cinsiyet grubuna hitap edecek olan pazarlama stratejilerinin oluşturulmasında kullanılabilir. Bunlara bakıldığında cinsiyet tespit sisteminin oldukça geniş uygulama alanına sahip olduğu görülmektedir. Kişi tanımlama sistemlerinde parmak izi, yüz, ses, imza atımı gibi birçok biyometrik özellik kullanılmaktadır. Ancak irisin eşsiz yapısından dolayı diğer biyometrik özelliklere göre daha güvenilir bir sistem olduğu düşünülmektedir. Bu nedenle bu çalışmada iris yapısı kullanılarak cinsiyet tahmini yapılmaya çalışılmıştır. 750 kadın ve 750 erkek olmak üzere her kişinin sağ ve sol iris görüntüleri kullanılarak toplamda 3000 görüntü üzerinde uygulama gerçekleştirilmiştir. İris görüntülerine öznitelik çıkarma yöntemi olarak doku analiz yöntemleri, gemoterik features çıkartma, gabor filtresi, dalgacık dönüşüm, fourier dönüşümü uygulanmıştır. Ayrıca irisin genel, bölgesel ve hücresele doku analizi yöntemi hem iris görüntüsüne hemde Daugman dönüşümü uygulanarak öznitelik çıkarılmıştır. Çıkarılan bu özniteliklere birimsel boyut farkını gidermek için max normalizasyonu ve non-linear dönüşümü uygulanmıştır. Her bir öznitelik çıkartma yöntemiyle öznitelik kümeleri oluşturulmuş ve sınıflandırma başarımları değerlendirilmiştir. İçlerinde en iyi öznitelik kümesi bulunamadığı açıktır. Bu sebeple karşılaştırma sonrasında öznitelik seçimi algoritmaları uygulanmıştır. Bireysel en iyi seçim, ileri seçim ve n-al r-bırak seçim algoritmaları kullanılarak öznitelik seçimi yapılmıştır. Seçim algoritma sonuçları birbirleriyle karşılaştırılmıştır. Sonuç olarak, %91 başarımları oranı ile en iyi öznitelik alt kümesi non-linear dönüşüm yapılmış özniteliklerden elde edilmiştir.

Anahtar Kelimeler : İris, Cinsiyet, Doku analizi, Derin Öğrenme

Sayfa Adedi : 61

Danışman : Doç. Dr. Yakup KUTLU

# GENDER ANALYSIS ON IRIS IMAGES USING NOVEL MACHINE LEARNING TECHNIQUES

(M. Sc. Thesis)

Tuğba AÇIL

ISKENDERUN TECHNICAL UNIVERSITY  
ENGINEERING AND SCIENCE INSTITUTE

June 2019

## ABSTRACT

Due to the recently increasing population, determining the gender of the person searched in the database means halving the number of data in the database, which will give us a great deal of time. In addition, the gender detection system can be used in security applications requiring gender-based access control, to organize marketing strategies that address only a specific gender group. It is shown that it is seen that the gender detection system has a wide application area. Many biometric features such as fingerprint, face, voice and signature are used in person identification systems. However, due to the unique structure of the iris, it is thought to be a more reliable system compared to other biometric properties. Therefore, in this study, it was tried to estimate the gender by using iris structure. A total of 3000 images were used by using right and left iris images of 750 women and 750 men. Texture analysis, geometric features extraction, Gabor filter, wavelet transform and fourier transform were applied to the iris images as features extraction techniques. In addition, general, regional and cellular texture analysis was performed on both the iris image and Daugman transformed images. Max normalization and non-linear transformation were applied to these extracted features for making scale invariand. Each feature set extracted each method is used to classify gender and compare echa others. It was clear that there is no best feature set of them. Therefore, after comparing all features echother according to accuracy feature selektion algorithm used to determine subset which had best classificaion accuracy. best individual selection, forward selection and n-take r-away selection algorithms are used as features selection algorithm. The selected features were compared each other. Consequently, the best feature subset was obtained nonlinear transform features with 91% accuracy rate using n-tak r away algorithm.

Key Words : Iris, Gender, Texture Analysis, Deep Learning

Page Number : 61

Supervisor : Assoc. Prof. Dr. Yakup KUTLU

## TEŞEKKÜR

Tez çalışmamın planlanmasında, araştırılmasında ve yürütülmesinde ilgi ve desteğini esirgemeyen, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren ve ayrıca engin bilgi ve tecrübelerinden yararlanırken göstermiş olduğu hoşgörü ve sabırdan dolayı danışmanım Doç. Dr. Yakup KUTLU' ya sonsuz teşekkürlerimi sunarım. Çalışmalarım boyunca belirttiği görüşlerle bana yardımcı olan Dr. Öğr. Üyesi Gökhan ALTAN'a ve Ar. Gör. Hüseyin ATASOY'a , hayatımın her aşamasında destekleriyle beni yalnız bırakmayan, bugünlere gelmemde en büyük paya sahip olan aileme, en büyük destekçim olan ablam Dr. Öğr. Üyesi Elif AÇIL'a teşekkür ederim.



## İÇİNDEKİLER

	Sayfa
ÖZET .....	iv
ABSTRACT .....	v
TEŞEKKÜR .....	vi
İÇİNDEKİLER .....	vii
ÇİZELGELERİN LİSTESİ .....	ix
ŞEKİLLERİN LİSTESİ .....	xv
SİMGELER VE KISALTMALAR .....	xvii
1. GİRİŞ .....	1
2. ÖNCEKİ ÇALIŞMALAR .....	4
3. MATERYAL VE YÖNTEM .....	7
3.1. Materyal .....	7
3.1.1. Kullanılan veri tabanı .....	7
3.2. Öznitelik Çıkarma Yöntemleri .....	7
3.2.1. Göz resimleri işlenmesi .....	8
3.2.2. Dalgacık dönüşümü .....	10
3.2.3. Gabor filtresi .....	11
3.2.4. Fourier dönüşümü .....	12
3.2.5. Doku analizi .....	12
3.2.6. Geometrik özellikler .....	13
3.3. Sınıflandırma Yöntemleri .....	14
3.3.1. K en yakın komşu sınıflandırma .....	14
3.3.2. Naive bayes .....	15
3.3.3. Karar ağacı .....	16



3.3.4. Çok katmanlı ağlar .....	18
3.3.5. Derin öğrenme .....	19
3.4. Performans Ölçüm Yöntemleri .....	21
3.4.1. Sınıflandırma başarımları ölçümleri .....	22
3.4.2. Öznitelik seçimi .....	23
<b>4. ARAŞTIRMA BULGULARI.....</b>	<b>26</b>
4.1. İris ve Gözbebeği Sınırlarının Belirlenmesi.....	27
4.2. İrisin Doku ve Geometrik Özelliklerinin Çıkarılması.....	28
4.3. Görüntülere Dalgacık Dönüşümü Uygulanarak Öznitelik Çıkarımı.....	29
4.4. Görüntülere Gabor Filtresi Uygulanarak Öznitelik Çıkarımı .....	30
4.5. Görüntülere Fourier Dönüşümü Uygulanarak Öznitelik Çıkarımı .....	30
4.6. Öznitelik Seçimi.....	31
4.7. Derin Öğrenme ile Sınıflandırma.....	35
<b>5. SONUÇ VE ÖNERİLER.....</b>	<b>38</b>
5.1. Sınıflandırma Başarımları .....	38
5.2. Sonuçların Karşılaştırılması .....	51
<b>KAYNAKLAR .....</b>	<b>54</b>
<b>ÖZGEÇMİŞ.....</b>	<b>58</b>

## ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Sınıflandırma doğruluk tablosu .....	22
Çizelge 4.1. Kullanılan yöntemlerden elde edilen öznitelik sayıları .....	32
Çizelge 4.2. Sol göz için bireysel en iyi seçim algoritmasında kullanılan öznitelik sayılarının dağılımı .....	32
Çizelge 4.3. Sağ göz için bireysel en iyi seçim algoritmasında kullanılan öznitelik sayılarının dağılımı .....	33
Çizelge 4.4. Sol göz için ileri yönlü seçim algoritmasında kullanılan öznitelik sayılarının dağılımı .....	33
Çizelge 4.5. Sağ göz için ileri yönlü seçim algoritmasında kullanılan öznitelik sayılarının dağılımı .....	34
Çizelge 4.6. Sol göz için n-al r-bırak seçim algoritmasında kullanılan öznitelik sayılarının dağılımı .....	34
Çizelge 4.7. Sağ göz için n-al r-bırak seçim algoritması ile kullanılan öznitelik sayılarının dağılımı .....	35
Çizelge 4.8. Konvolüsyonel sinir ağı ile cinsiyet sınıflandırma başarımları .....	37
Çizelge 5.1. Normalizasyon uygulanmamış sol iris verilerinin sınıflandırma başarımları .....	40
Çizelge 5.2. Normalizasyon uygulanmış sol iris verilerin sınıflandırma başarımları .....	41
Çizelge 5.3. Doğrusal olmayan dönüşüm uygulanmış sol iris verilerin sınıflandırma başarımları .....	42
Çizelge 5.4. Normalizasyon ve dönüşüm uygulanmamış sağ iris verilerinin sınıflandırma başarımları .....	43
Çizelge 5.5. Normalizasyon uygulanmış sağ iris verilerinin sınıflandırma başarımları .....	44
Çizelge 5.6. Doğrusal olmayan dönüşüm uygulanmış sağ iris verilerinin sınıflandırma başarımları .....	45

## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Dosya adı : 02463d2294 örnek bir göz resmi .....	8
Şekil 3.2. İris ve gözbebeğinin sınırlarının bulunmuş örnek görüntüler.....	9
Şekil 3.3. a) Daughman dönüşümü modeli b) örnek bir görüntüye uygulanması .....	9
Şekil 3.4. Dalgacık dönüşümü ayrışımı .....	11
Şekil 3.5. Her biri ayrı bir dokuya sahip aynı tür nesnelere .....	13
Şekil 3.6. K-NN sınıflandırıcısı .....	15
Şekil 3.7. Naive bayes.....	16
Şekil 3.8. Karar ağacı modeli.....	18
Şekil 3.9. Çok katmanlı ağ yapısı .....	19
Şekil 3.10. Evrişimsel sinir ağı (ESA) yapısı (Ergin, T. Convolutiona Neural Network nedir Web. 17 Mart 2019) .....	20
Şekil 3.11. Öznitelik seçim diyagramı a) filtreleme metodu ile b) sarmal metodu ile .....	24
Şekil 4.1. Sınıflandırma sisteminin akış diyagramı .....	26
Şekil 4.2. Dosya adı : 90340d4 yapılan işlemlerde a) Segmente edilemeyen b) Başarılı bir şekilde segmente edilen iris görüntüsü .....	27
Şekil 4.3. Kullanılan yapılar a) genel iris b) bölgesel iris c) hücrel iris bölgeleri.....	28
Şekil 4.4. Daugman dönüşüm uygulanmış görüntünün farklı boyutlara bölünmesi sırasıyla 2x2 ve 2x4 .....	29
Şekil 4.5. Dalgacık metodu uygulanarak elde edilen alt görüntüler a) DD b) YY c) YD d) DY .....	29
Şekil 4.6. Gabor filtresi uygulanan iris görüntüsü .....	30
Şekil 4.7. Gabor filtresi uygulanmış görüntünün farklı boyutlara bölünmesi sırasıyla .....	30
Şekil 4.8. Fourier dönüşümü uygulanan iris görüntüleri .....	31
Şekil 4.9. Oluşturulan konvolüsyonel sinir ağı modeli.....	37

<b>Şekil</b>	<b>Sayfa</b>
Şekil 5.1. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özniteliklerin BEİSA ile sınıflandırılma başarımları grafiği.....	46
Şekil 5.2. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özniteliklerin BEİSA ile sınıflandırılma başarımları grafiği.....	47
Şekil 5.3. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özniteliklerin ileri yönlü seçim algoritması ile sınıflandırılma başarımları grafiği .....	48
Şekil 5.4. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özniteliklerin ileri yönlü seçim algoritması ile sınıflandırılma başarımları grafiği .....	49
Şekil 5.5. a) normalizasyon ve dönüşüm uygulanmadan b) max normalizasyon uygulanmış, c) doğrusal olmayan dönüşüm uygulanmış n-al r-bırak seçim algoritması ile elde edilen başarımları grafikleri.....	50
Şekil 5.6. a) normalizasyon ve dönüşüm uygulanmadan b) max normalizasyon uygulanmış, c) doğrusal olmayan dönüşüm uygulanmış n-al r-bırak seçim algoritması ile elde edilen başarımları grafikleri.....	51

## SİMGELER VE KISALTMALAR

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

### Kısaltmalar

**ÇKA**

**DVM**

**BEİSA**

**ESA**

**KA**

**K-NN**

**NB**

**2D HFD**

### Açıklamalar

Çok Katmanlı Ağlar

Destek Vektör Makinesi

Bireysel En İyi Seçim Algoritması

Evrişimsel Sinir Ağı

Karar Ağacı

K En Yakın Komşu

Naive Bayes

2 Boyutlu Hızlı Fourier Dönüşümü

## 1. GİRİŞ

Sayısal görüntülerden anlamlı bilgiler çıkarmak bilgisayar görmesi olarak tanımlanmaktadır. Amaç görüntü işleme ve yapay zeka teknikleri kullanılarak analizler yapmak ve bilgi elde etmek ve bunu insanların görme kabiliyetini elektronik ortamda taklit etmektir. Bilgisayar görmesi, birçok alanda kullanılan otomatik görüntü analizi işlemleri için temel oluşturmaktadır. Burada temel problem görüntü verisinin bir obje veya aktivite içerip içermediğini belirlemektir. Bilgisayar görmesinden faydalanılan birçok uygulamada bilgisayarlar belirli bir görevi yerine getirmek için önceden programlanmıştır. Bu çalışmalarda bilgisayar görmesinden faydalanılarak yapılan çalışmalarında yapılandırılmış modeller kullanarak görüntü verisinden sembolik veya nümerik bilgi çözülmesi yapılabilmeye yönelik işlemler gerçekleştirilmektedir. Kamera önünde bulunan bir şahsın cinsiyet kestirimi veya bir fotoğraftakileri cinsiyetlerine göre ayrıştırılması gibi işlemler sonrası belirlenmesi.

Cinsiyet tespiti yapmak birçok alanda avantaj sağlamaktadır. Bunlardan birisi veritabanında aranacak kişi sayısı cinsiyet analizi yapılarak azaltılabilir ve böylece arama süresi kısaltılır. Bir diğeri ise sosyal ortamlarda kimlik bilgisi belirtilmeden sadece cinsiyete dayalı olarak bir alana girilmede fayda sağlar. Ayrıca mağazalarda veya web sayfalarında kameradan aldıkları görüntüyü işleyerek kullanıcının cinsiyetine göre reklamların getirilmesi mümkündür (Tapia ve Aravena, 2017). Bir diğeri yönden mobil uygulamalarda cihaz kamerası kullanılarak görüntülerinin alınabilmesi ve bu görüntülerin işlenerek kullanıcıların cinsiyet bilgisi tespit edilerek cinsiyetine göre reklam ürünü sunulabilmesi mümkündür.

Literatürde yapay zeka uygulamalarına bakıldığında iris, parmak izi, yüz, avuç içi, ses gibi kişileri temsil eden biyometrik özellik olarak kullanıldıkları gibi cinsiyet belirlemede de bu özelliklerden yararlanılmış olduğu görülmektedir. Bireylerin bu biyometrik özelliklerine bakıldığında iris, gözün saydam tabakasının arkasında bulunan, göze rengini veren daire şeklinde bir kas tabakasından oluşan bölümdür. İris renk olarak kişiler arasında benzerlik gösterse bile yapı olarak her bireyde farklıdır. Hatta bir kişinin sağ ve sol gözünün iris kodları bile birbirinden farklıdır. Tek yumurta ikizleri bile aynı deoksiribo nükleik asit (DNA) yapısına sahip olmasına rağmen farklı iris yapısına sahiptirler. Ayrıca iris insan doğumunun 16. ayından sonra ölüme kadar değişiklik göstermeyen bir yapıya sahiptir. Bu nedenlerden dolayı irisin kimlik belirlemede kullanılan diğeri biyometrik özelliklere göre

daha güçlü bir biyometrik özellik olduğu düşünülmektedir (Çakır, Altıntaş ve Akbulut, 2013). Bu çalışmada Notre Dame üniversitesinin hazırladığı ve ücretsiz olarak paylaştığı ND\_GFI veritabanı kullanılmıştır (Tapia, Perez ve Bowyer, 2014).

Bu çalışmada cinsiyet analizinde biyometrik özellik olarak irisin tercih edilmesinde çalışmada kullanılacak donanımlara erişimin kolaylığı da etkili olmuştur. Örneğin parmak izi ile cinsiyet analizinde parmak izlerinin elde edilmesinde özel olarak kullanılan bir teçhizata ihtiyaç duyulmaktadır. Bu durum hem maliyet hem de teçhizatın yalnızca bu tarz çalışmalar için kullanılması sınırlılığını ifade etmektedir. Ayrıca biyometrik güvenilirlik anlamında parmak izinin değiştirilebilmesi mümkünken, irisin yapısını değiştirmek zordur ve yapıyı değiştirmeye çalışmak gözü bozabilir. Ses, yüz gibi biyometrik özellikler zaman içerisinde değişime eğilimli olan özelliklerdir, iris ise ömür boyu değişmeyen bir biyometrik özelliktir. Tüm bu nedenlerden dolayı son yıllarda iris cinsiyet analizinde, kimlik belirlemede daha güvenilir ve güncelliği artan bir yapı olma özelliğindedir (Çakır ve diğerleri 2013).

Bu tez beş bölümden oluşmaktadır. Birinci bölümde çalışmanın amacı, önemi, biyometrik özellik olarak neden irisin tercih edildiği, cinsiyet analizinin hangi tür problemlerin üstesinden gelmek için kullanılabileceği anlatılmaktadır.

İkinci bölümde yapılan çalışmayla ilgili ve bu çalışmaya paralel olarak yapılan literatürdeki çalışmalarda kullanılan metotlar, elde edilen başarımlar hakkında bilgi verilmektedir.

Üçüncü bölümde çalışmada kullanılan veri tabanı, ön işlem algoritmaları, öznitelik çıkarma yöntemleri, öznitelik seçim yöntemleri, sınıflandırma yöntemleri, sınıflandırma başarımlar ölçümleri ve çalışmada kullanılan öznitelik seçim algoritmaları anlatılmaktadır.

Dördüncü bölümde görüntülere uygulanan yöntemlerle yapılan öznitelik çıkarımı ve çıkarılan özniteliklerden seçim algoritmalarıyla öznitelik seçimi aşamaları anlatılmıştır.

Son olarak beşinci bölümde ise kullanılan bütün yöntemler sonucunda oluşan özniteliklerin tek tek kullanılmasıyla elde edilen sınıflandırma başarımlar sonuçları, bu özniteliklerin hepsinin birleştirilmesiyle oluşan öznitelik havuzunun sınıflandırılma başarımlar oranları, öznitelik havuzundan tercih edilen seçim algoritmaları kullanılarak öznitelik seçimi

yapıldıktan sonra sınıflandırma başarımlarının ve lüerätürdeki benzer çalıřmalar ile bu sonuçların karşılařtırılması yapılmıřtır.





## 2. ÖNCEKİ ÇALIŞMALAR

Bu çalışmanın amacı renk, doku, morfolojik özellikler veya dönüşüm teknikleri kullanılarak elde edilen çeşitli öznitelikleri farklı sınıflandırıcılar ile birlikte kullanarak cinsiyet sınıflandırıcı sistemler geliştirmektir. Literatürde cinsiyet sınıflandırma üzerine yapılmış çalışmalar mevcuttur. Bu çalışmalara bakıldığında birçok biyometrik özellik kullanılmıştır.

Cinsiyet sınıflandırması için parmak izi (Ceyhan, Sağıroğlu ve Akyıl, 2014; Ceyhan, Sağıroğlu ve Akyıl, 2013), yürüyüş şekli (Tunalı ve Şenyar, 2012; Yu, Tani Huang, Jia ve Wu, 2009; Chang ve Wu, 2010), yüz (Kılınç ve Uludağ, 2012; Jain, Huang ve Fang, 2005; Guo, Lin ve Nguyen, 2010; Stawska, ve Milczarski, 2017), ses (Kotti ve Kotropoulos, 2008), kalp sesi (Dal, Coşgun ve Özbek, 2015), iris (Thomas, Chawla, Bowyer ve Flynn, 2007; Bansal, Agarwal ve Sharma, 2014; Fairhurst, Erbilek ve Costa-Abreu 2015; Amrolkar ve Tugave 2015; Kuehlkamp, Becker ve Bowyer, 2017) gibi birçok biyometrik özellikler kullanılmıştır.

İrisin biyometrik özellik olarak kullanılabilmesi fikrini ilk ortaya atan kişi Fransız göz doktoru Alphonse Bertillon'dur (Tisse, Martin, Torres ve Robert, 2002). 1992 yılında ise Dr. John Daugman öncülüğünde bir grup iris tanıma sisteminin algoritmasını gerçekleştirerek ilk çalışmayı yapmışlardır (Daugman, 1992).

Bansal, Agarwal ve Sharma (2012) yaptığı çalışmada 150 kişinin 300 görüntüsü bulunan bir veritabanı kullanmışlardır. Dairesel hough dönüşümü ile lokalizasyon yapıldıktan sonra, Daughman dönüşüm modeli ile polar dönüşümü yapılmıştır. Görüntüden çıkarılan istatistiksel öznitelikler ve görüntüye dalgacık dönüşümü uygulanarak çıkarılan özniteliklerin kombinasyonu öznitelik olarak kullanılmıştır. Bu özniteliklerle destek vektör makinesi kullanılarak %83 başarı oranı ile cinsiyet sınıflandırılması yapılmıştır.

Bansal ve diğerleri (2014) yaptığı çalışmada 200 kişinin 400 iris görüntüsü üzerinde çalışılmıştır. Görüntülere segmentasyon ve normalizasyon işlemi uygulanmıştır. Daha sonra görüntülerin istatistiksel değerleri ile dalgacık dönüşümü kullanılarak oluşturulan doku özellikleri birleştirilerek bir öznitelik seti oluşturulmuştur. Son olarak bu öznitelikler destek vektör makinesi sınıflandırıcısı ile sınıflandırılarak %85,6 başarı sağlanmıştır.

Tapia, Perez ve Bowyer (2014) 1500 kişinin 3000 görüntüsüyle yaptıkları çalışmada İrisBEE uygulaması ile iris görüntüleri üzerinde polar dönüşümü yapılmıştır. Yerel ikili örüntü metodu ile öznitelik çıkarımı yapılmıştır. Destek vektör makinesi sınıflandırıcısı ile %91 başarı oranında cinsiyet sınıflandırılması yapılmıştır.

Fairhurst ve diğerleri (2015) yaptığı çalışmada 200 kişi, toplamda 1600 görüntü kullanılarak segmentasyon işlemi yapıp geometrik özellikleri çıkarılmıştır. Daha sonra görüntülere Daugman dönüşüm modeli uygulanarak polar dönüşümü yapıp gabor dalgacı uygulanıldıktan sonra doku özneliği çıkarılmıştır. Çıkarılan bu geometrik ve doku öznelikleri birleştirilerek öznitelik kombinasyonu yapılmıştır. Öznitelikler destek vektör makinesi, çok katmanlı ağlar, k en yakın komşu, karar ağaçları ve kural tabanlı sınıflandırıcılar içeren uzman sistem modeli oluşturularak başarı oranı %89,7'a ulaşmıştır.

Amrolkar ve Tugave (2015) yaptığı çalışmada 64980 görüntü bulunan veritabanı üzerinde çalışılmıştır. Görüntülere segmentasyon yapıldıktan sonra polar dönüşümü yapılmıştır. Öznitelik olarak üniform bölgesel ikili örüntü ve genelleştirilmiş ikili dönüşüm metodları ile çıkarılan öznitelikler birleştirilerek kullanılmıştır. Destek vektör makinesi ile bu öznitelikler sınıflandırılmıştır. %88,4 başarı oranı elde edilmiştir.

Tapia, Perez ve Bowyer (2016) yaptığı çalışmada farklı iki veritabanından alınan toplamda 1824 kişiye ait olan 4944 iris görüntüsü üzerinde çalışılmıştır. Görüntülerde gerekli ön işlemler yapıldıktan sonra gabor filtresi uygulanarak karşılıklı bilgi temelli öznitelik seçim yöntemi ile öznitelik seçimi yapılmıştır. Destek vektör makinesi (DVM) sınıflandırıcısı ile %89 başarı elde edilmiştir.

Anupama, Sanaj ve Asha (2017) 108 kişinin 756 görüntüsünü içeren bir veritabanı üzerinde çalışmışlardır. İris sınırları tespit edilip segmentasyon ve lokalizasyon gibi gerekli ön işlemler yapılmıştır. Daughman dönüşüm ile polar dönüşümü yapılmıştır. Dalgacık dönüşümü, gabor filtresi, gri seviye eş oluşum matrisleri yöntemleri ile öznitelik çıkarımı yapılmıştır. Destek vektör makinesi kullanılarak %90,2 başarı oranı ile sınıflandırma yapılmıştır.

Tapia ve Arevena (2017) yaptığı çalışmada 1824 kişiye ait olan 4944 iris görüntüsünün bulunduğu bir veri tabanı kullanmışlardır. Görüntülerde lokalizasyon işlemi ile iris bölgeleri

bulunduktan sonra, polar dönüşümü yapılmıştır. Evrişimsel sinir ağı modeli farklı parametreler için eğitilerek derin öğrenme uygulaması gerçekleştirilmiştir. %83 başarımla cinsiyet sınıflandırması yapılmıştır.

Tapia ve Arellano (2019) 1500 kişinin 3000 iris görüntüsü kullanılarak segmentasyon ve normalizasyon ön işlemleri yapılmıştır. Önceki çalışmasında (Tapia ve diğerleri, 2014) önerdiği yöntemde gürültüleri indirgeyen bir filtre kullanarak modifiye edilmiş ikili resim filtresi modeli önermiştir ve başarımları biraz daha arttırarak DVM sınıflandırıcısı ile %94,6 başarımla elde edilmiştir.



### 3. MATERYAL VE YÖNTEM

#### 3.1. Materyal

##### 3.1.1. Kullanılan veri tabanı

Gerekli iris görüntüleri Notre Dame üniversitesinin hazırladığı veritabanından alınmıştır. Bu veritabanından iki farklı veritabanından oluşmaktadır (GFI - UND). Veritabanı araştırmalara açık bir veritabanıdır ('The Gender from Iris Dataset (ND-GFI)') (Tapia ve diğerleri 2014). Görüntüler 480x640 boyutunda ve gri renkli olarak, LG 4000 sensör ile elde edilmiş, sağ ve sol iris resmi olarak belirtilmiş bir veritabanıdır. GFI veritabanında 750 erkek ve 750 kadın olmak üzere 1500 kişinin sağ ve sol iris görüntüleri mevcuttur. Toplamda 3000 görüntü bulunmaktadır. UND veri tabanında ise 175 erkek, 149 kadının üç sağ ve üç sol gözü olmak üzere toplamda 1944 görüntü bulunmaktadır.


Bu çalışmada iki yaklaşım yapılmıştır. Birinci yaklaşımda öznitelik bağımlı bir model oluşturulmuştur. Diğer yaklaşımda ise öznitelik bağımsız bir model oluşturulmuştur. Öznitelik bağımlı bölümde doku analizi, geometrik özelliklerin çıkarılması, dalgacık dönüşümü, gabor filtresi, fourier dönüşümü öznitelik çıkarımı yöntemlerinde ise sadece GFI veri tabanının sağ ve sol iris görüntüleri kullanılmıştır. Yani 1500 kişinin 3000 iris görüntüsü üzerinde çalışılmıştır. Öznitelik bağımsız bölümde ise derin öğrenme modeli oluşturulmuştur. Derin öğrenme için veri tabanındaki bütün veriler kullanılmıştır. Toplamda 1824 kişinin 4944 iris görüntüsü üzerinde çalışılmıştır.

#### 3.2. Öznitelik Çıkarma Yöntemleri

Öznitelik belirleme makine öğrenmesinde, kullanılan verilerden anlamlı öznitelliklerin belirlenmesi aşamasıdır ve en önemli aşamadır. Öznitelik çıkarımında alınan görüntülerin kullanılabilmesi için irisin bazı ön işlemlerden geçmesi gerekmektedir. Böylece verilerin daha anlaşılır hale gelmesi, gereksiz bilgilerin temizlenmesi, işlemsel olarak analiz aşamasına daha az ve temiz veri gitmesi sağlanmaktadır. Yapılan ön işlemlerde filtreleme, göz yapısından irisin belirlenmesi, bazı dönüşüm teknikleri kullanılmıştır. Öznitelik çıkarmak için fourier, dalgacık, gabor dönüşüm teknikleri, doku analizi algoritmaları ve geometrik morfolojik işlemler kullanılmıştır. detaylar aşağıda verilmiştir.

### 3.2.1. Göz resimleri işlenmesi

Veritabanından alınan göz resimlerinden özneliliklerin çıkarılması, anlamlı bölgelerin belirlenmesi ve doğru verilerin alınabilmesi için bu aşama önemlidir. Şekil 3.1’de veritabanından alınan örnek bir göz resmi gösterilmiştir.



Şekil 3.1. Dosya adı : 02463d2294 örnek bir göz resmi

Şekilde gösterildiği gibi göz resimlerinden iris bölgesinin doğru belirlenmesi için göz bebeği ve iris çevresinin bulunması gerekmektedir.

#### İris Bölgesinin Belirlenmesi

Cinsiyet analizi için iris segmentasyonu çok önemli bir adımdır. Bu çalışmada göz resminden gerekli olan kesit alanının elde edilmesi için Daugman algoritması (Percy ve Waqas, 2010) kullanılmıştır. Bu algorithmada irisin ve gözbebeğinin merkez koordinatları ve yarı çapları bulunarak iris dairesi elde edilir. Daugman algoritmasında merkez koordinatları ve yarı çap bilgileri aşağıdaki Eş. 3.1’de belirtilen şekilde bulunur (Percy ve Waqas, 2010).

$$\max_{(r, x_0, y_0)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r, x_0, y_0} \frac{I(x, y)}{2\pi r} ds \right| \quad (3.1)$$

$I(x, y)$  bir iris görüntüsünün  $(x, y)$  koordinatlarının piksellerinin yoğunluğu,

$r(x_0, y_0)$  merkez koordinatları ile dairesel bölgelerin yarıçapını gösterir,


$\sigma$  Gauss dağılımının standart sapması,

$G_\sigma(r)$  sigma ölçeğinin Gauss filtresini gösterir,

$(x_0, y_0)$  irisin varsayılan merkez koordinatları,

$s(r, x_0, y_0)$  parametreleri tarafından verilen çemberin konturu.


Çalışmada Daugman algoritması kullanılarak elde edilen bu alan bilgileri kullanılarak öznelik çıkarım algoritmaları çalıştırılmıştır. Şekil 3.2’de iris ve göz bebeği sınırları belirlenmiş görüntüler gösterilmektedir.



Şekil 3.2. İris ve gözbeğinin sınırlarının bulunmuş örnek görüntüler

### Daugman Dönüşümü

Segmente edilmiş ham iris görüntülerine polar dönüşüm yaparak dikdörtgen biçime dönüştürme algoritması Daugman dönüşümü olarak adlandırılır. Bu model görüntüler arasındaki göz bebeğinin neden olduğu irisin değişik aydınlatma seviyelerinde gerilmesi, değişen görüntüleme mesafesi, başın eğilmesi gibi nedenlerden dolayı görüntüler arasındaki boyutsal tutarsızlığı minimize etmek için uygulanır (Bansal ve diğerleri, 2012). Daugman dönüşümü modelinde, irisin polardan kartezyen koordinat sistemine dönüştürülmesi Şekil 3.3’te gösterilmiştir. Dönüşüm yapılmış iris görüntüsünde ilk satır iris-gözbeğinin yanındaki halkayı, son satır ise iris-sklera yanındaki halkayı temsil eder. Daugman dönüşümü ile ilgili daha kapsamlı bilgiye (Daugman, 2009; Daugman, 1993) çalışmalarından daha detaylı bilgiye ulaşılmaktadır. Daugman dönüşüm modeli Şekil 3.3’te gösterilmiştir.



a)

b)

Şekil 3.3. a) Daugman dönüşümü modeli b) örnek bir görüntüye uygulanması

### Normalizasyon

Bu çalışmada öznitelik belirlemede birçok farklı yöntem ve değer kullanılacaktır. Makine öğrenme algoritmaları, verilerin öznitelliklerini karşılaştırarak verilerin ait olduğu sınıfı bulmaya çalışır. Ancak, öznitelliklerin önemli ölçüde farklı ölçeklerde olması büyük bir oranda başarıyı etkilemektedir. Bu aşamada normalleştirme, her veri öznitelliğinin aynı ölçü bandına gelmesini sağlayarak bu problemi ortadan kaldırmaktadır. Bu çalışmada max normalizasyon ile gerçek değerler her örnek vektörün mutlak maksimum değerine bölünerek veriler normalize edilmiştir (Eş. 3.2).

Veri aralıklarını orijinal aralıktan yeni bir aralığa dönüştürerek ölçekleme problemini ortadan kaldıran diğer bir dönüşüm tekniği ise doğrusal olmayan dönüşüm (non-linear)'dür. (Kutlu ve diğerleri, 2009). Bu çalışmada doğrusal olmayan fonksiyon olarak hiperbolik sigmoid fonksiyonu kullanılmıştır (Eş. 3.3).

$$Y^k = X^k / \text{abs}(\max(X^k)) \quad (3.2)$$

$Y^k$  normalize edilmiş veriler,  $X^k$  ise orijinal verileri ifade etmektedir.

$$Y^t = \frac{2}{1 + e^{-5Y^k}} - 1 \quad (3.3)$$

$Y^t$  dönüşüm yapılmış veriler,  $Y^k$  normalize edilmiş verilerdir.

#### **3.2.2. Dalgacık dönüşümü**


Dalgacık dönüşümü, bir zaman serisini zaman-frekans uzayında parçalarına ayırarak zaman içerisinde bu zaman serisinin nasıl değiştiğini inceler. Dalgacık dönüşümü ( $\psi(x)$ ) dalgacık fonksiyonu kullanılmaktadır. Analiz işlemi bu dalgacık fonksiyonu ölçeklendirilip zaman alanında kaydırılarak gerçekleştirilir.  $\psi(x)$  fonksiyonun integrali sifira ve  $\psi(x)$  fonksiyonunun karesinin integrali bire eşit olan her  $\psi(x)$  fonksiyonu dalgacık olarak adlandırılır. Dalgacık dönüşümünün iris görüntülerinde kullanılan en temel dalgacık fonksiyonu haar dalgacığı olarak bilinmektedir (Daouk, Esber, Kammoun ve Alaoui, 2002).

Haar dalgacığının matematiksel gösterimi Eş. 3.4'te gösterilmektedir (Abbak, 2007; Percival ve Walden, 2002).

$$\psi^{(H)}(x) \equiv \begin{cases} -\frac{1}{\sqrt{2}}, & -1 < x \leq 0; \\ \frac{1}{\sqrt{2}}, & 0 < x \leq 1; \\ 0, & \text{aksi takdirde} \end{cases} \quad (3.4)$$

MxN boyutlu bir görüntüye uygulanan dalgacık dönüşümü görüntüyü M/2 x N/2 boyutlu dört alt görüntüye ayrıştırır.

Bu görüntüler yaklaşıklık (DD), yatay (YD), dikey (DY) ve çarpraz (YY) olarak adlandırılır. YY yatay ve dikey yönde yüksek geçiren, DY dikey olarak düşük, yatay olarak yüksek geçiren, YD dikey olarak yüksek yatay olarak düşük geçiren, DD ise hem yatay hemde dikey yönde düşük geçiren filtre anlamına gelmektedir. Şekil 3.4'te dalgacık dönüşümü ayrıştırması gösterilmiştir (Bansal ve diğerleri, 2014).



Şekil 3.4. Dalgacık dönüşümü ayrışımı

### 3.2.3. Gabor filtresi

Gabor filtresi, görüntü analizinde kullanılan önemli yöntemlerden bir tanesidir. Filtre yardımıyla bir görüntü üzerinde belli bir yöne uzanan ayrıtlar tespit edilebilmektedir. Plaka tanıma, parmak izi tanıma, iris tanıma, yüz tanıma gibi pek çok yöntem için kullanılan bir yöntemdir. Filtrenin çekirdek matrisi Eş. 3.5'te verilen formülle hesaplanır.

$$g(x, y|W, \theta, \varphi, X, Y) = \exp \frac{-[(x-X)^2 + (y-Y)^2]}{2\sigma^2} x \sin(W(x \cos \theta - y \sin \theta) + \varphi) \quad (3.5)$$



Denklemden, teta filtre yönünü, sigma gauss genişliğini, W frekansı,  $\phi$  faz kaymasını, X,Y tanımlanan filtrenin merkezini temsil eder (Fogel ve Sagi, 1989).

### 3.2.4. Fourier dönüşümü

Fourier Dönüşümü bir dalga biçimini sinüs ve kosinüslerle farklı bir kombinasyon olarak ifade edilebilen bir matematiksel işlemdir. Fourier dönüşümü bir dalga formu şeklinde tanımlanabilen sinyaller üzerinde işlemler yapmak için kullanılan bir araçtır. Bu çalışmada 2 boyutlu hızlı fourier dönüşümü (2-D HFD) kullanılmıştır. 2-D HFD matris şeklinde bir girdi alıp yine matris şeklinde bir çıkış döner. MxN boyutlu bir görüntünün fourier dönüşümü Eş. 3.6'da verildiği gibi hesaplanır (Nussbaumer, 1982;80:107).

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi\left(\frac{ux}{M} + \frac{vy}{N}\right)} \quad (3.6)$$

$u = 0, 1, \dots, M - 1$  ve  $v = 0, 1, \dots, N - 1$  aralığında bir değerdir.

### 3.2.5. Doku analizi

Doku görüntüdeki renkler veya yoğunlukların nicelik olarak ölçüsüdür. Her bir nesnenin, canlılığın kendine özgü dokusu vardır. Aynı türden farklı cins canlıların bile birbirinden farklı dokuları vardır. Bu nedenle iyi bir tanımlayıcı özelliktir. Şekil.3.5'te ayrı dokulara sahip aynı tür ahşap nesnelere gösterilmiştir. Doku analizi, görüntülerin bölgelere ayrılarak bu bölgelerden sınıflandırma yapmaya yardımcı olan bir özelliktir (Shapiro ve Stockman, 2000:235,247). Bu çalışmada iris dokusunun maksimum, minimum, ortalama, standart sapma, varyans, basıklık ve çarpıklık değerleri olmak üzere yedi farklı istatistiksel değeri hesaplanmıştır.



Şekil 3.5. Her biri ayrı bir dokuya sahip aynı tür nesnelere

### 3.2.6. Geometrik özellikler

İris segmentasyon aşamasında bulunan merkez noktaları ve yarıçap bilgileri kullanılarak irisin çeşitli geometrik özellikleri çıkarılır.  $p_x, p_y$  gözbebeğinin merkez koordinatları,  $i_x, i_y$  irisin merkez koordinatları,  $i_r$  irisin yarıçapı ve  $p_r$  gözbebeğinin yarıçapını, C1 irisin merkezi, C2 gözbebeğinin merkezini ifade etmektedir. Sırayla iris ve göz bebeğinin x koordinatları arasındaki mesafe, iris ve göz bebeğinin y koordinatları arasındaki mesafe, iris ve göz bebeğinin merkezleri arasındaki uzaklık farkı, irisin alanı, gözbebeğinin alanı, gerçek iris alanı, iris ve gözbebeğinin alanları oranı, iris ve gözbebeğinin yarıçap oranı, irisin çevresi, gözbebeğinin çevresi, çevreler oranı ve çevreler arasındaki uzaklık olmak üzere toplamda 12 farklı geometrik özellik çıkarılmıştır (Fairhurst ve diğerleri, 2015). Aşağıda bu çalışma için çıkarılan özellikler detaylı olarak açıklanmıştır.

$|p_x - i_x|$  iris ve göz bebeğinin x koordinatları arasındaki mesafe,

$|p_y - i_y|$  iris ve göz bebeğinin y koordinatları arasındaki mesafe,

$A = \pi * i_r^2$  alan hesaplaması,

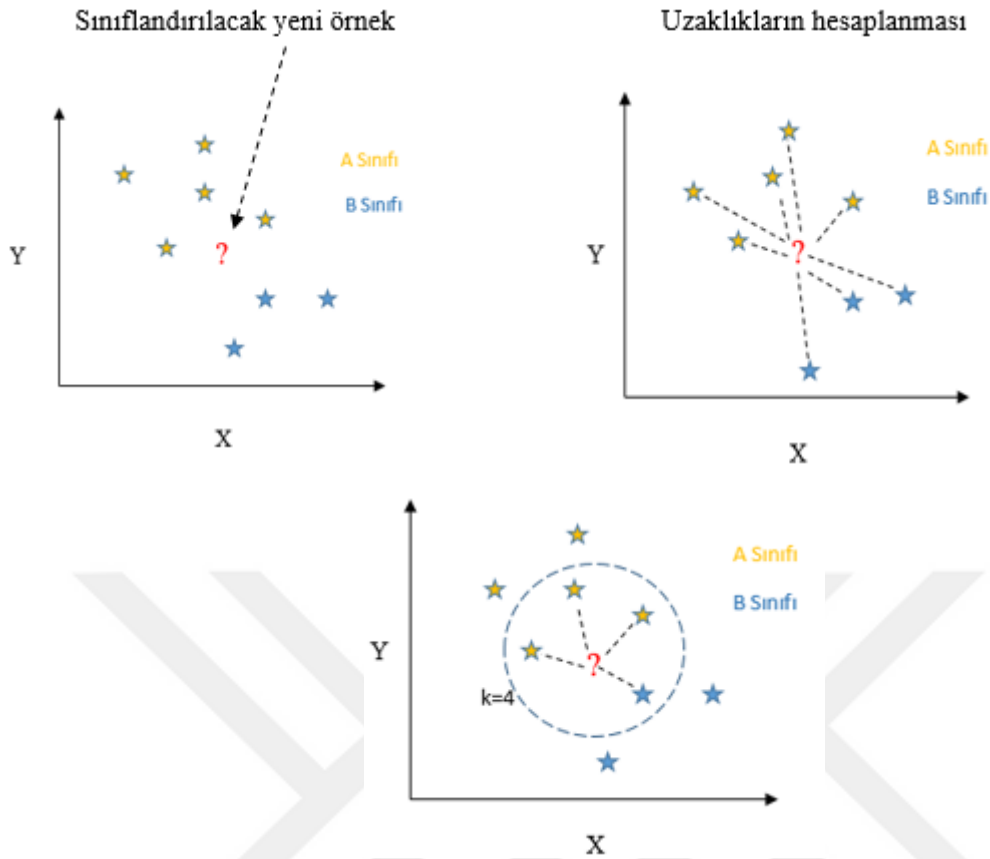
$\mathcal{C} = p_i * 2 * i_r$  çevre hesaplaması.

### 3.3. Sınıflandırma Yöntemleri

Makine öğrenmesi tekniklerinde bir çok yöntem bulunmaktadır. Bunlar arasında hesaplama yöntemlerine göre kural tabanlı, istatistiksel uzaklık tabanlı ve deterministik olması gibi farklılıklar göstermektedir. Bu sebepten dolayı bu yöntemlerden birer tane kullanılarak sınıflandırma performansları incelenmiştir. Bu çalışmada elde edilen öznelilikler için  $k$  en yakın komşu (K-NN), naive bayes (NB), karar ağaçları (KA), çok katmanlı ağlar (ÇKA) sınıflandırıcılar kullanılarak sınıflandırma modelleri incelenmiştir. Ayrıca eğitim için öznelilik gerektirmeyen algoritmanın kendi içinde bir alt modül gibi değerlendirilen derin öğrenme modeli olan Evrişimsel sinir ağı kullanılmıştır.

#### 3.3.1. $K$ en yakın komşu sınıflandırma

$K$  en yakın komşu (K-NN), algoritmasında, eğitim setinde yer alan örneklerin hepsi  $n$  boyutlu bir örnek uzayında tutulur. Yeni bir örnek geldiği zaman, eğitim setinden yeni gelen bu örneğe en yakın  $k$  tane örnek belirlenerek yeni örneğin sınıf etiketine,  $k$  tane en yakın komşusunun sınıf etiketlerinin çoğunluğuna bakılarak karar verilir. Bütün örneklerin yeni gelen örnek ile uzaklıkları hesaplanır. Bu uzaklıklar sıralanır ve en küçük  $k$  tane örnek alınır.  $K$  tane örnek içinde hangi sınıf daha fazla ise yeni örnek o sınıfa dahil edilir. Burada örnekler arası uzaklık hesaplanırken öklid uzaklığı, manhattan uzaklığı, minkowski uzaklığı gibi çeşitli mesafe ölçütleri vardır. Sınıflandırma kısmında  $k=1$  ise, örnek en yakın komşusunun sınıfına atanır (Taşcı ve Onan, 2016). Şekil.3.6'da K-NN sınıflandırıcısı  $k=4$  için yeni gelen örneğin komşularının bulunması ve etiketinin belirlenmesi gösterilmiştir.



Şekil 3.6. K-NN sınıflandırıcısı

### 3.3.2. Naive bayes

Naive Bayes (NB), sınıflandırması sisteme öğretim amacıyla sunulan veriler üzerinden yapılan işlemler ile sisteme sunulan yeni verilerin sınıfını tespit eder. NB basit bir yapıya sahiptir ve yüksek başarımlı gösteren bir sınıflandırma algoritmasıdır (Orhan ve Adem, 2012). Bayes kuralına göre bir A örneğinin B sınıfı olma olasılığı Eş. 3.7'deki gibi hesaplanmaktadır (Zhang, 2004). Bu denklemde  $p(A)$  girdi olasılığını,  $p(B)$  çıkış olasılığını,  $p(B|A)$  A olayının gerçekleştiği durumda B olayının meydana gelme olasılığını,  $p(A|B)$  B olayının gerçekleştiği durumda A olayının gerçekleşme olasılığını ifade etmektedir.

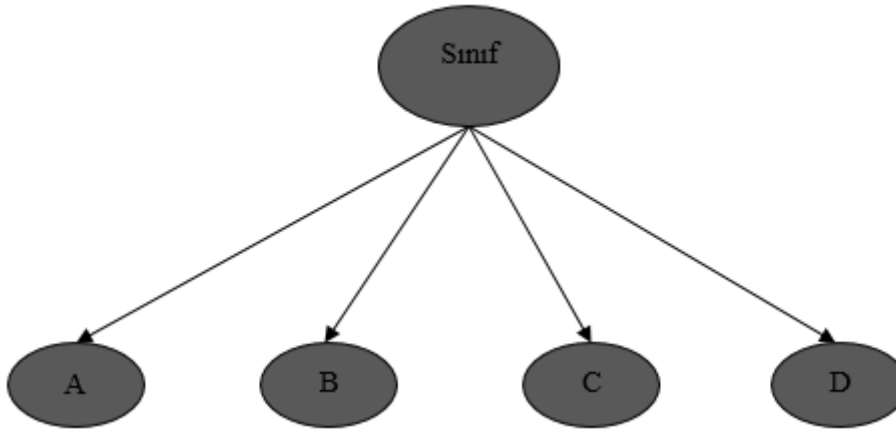
$$p(B|A) = \frac{p(A|B)p(B)}{p(A)} \quad (3.7)$$

NB sınıflandırıcısı fonksiyonu ise Eş. 3.8'deki gibi hesaplanmaktadır.

$$B' = \arg \max_{b_n \in Y} (P(B = y_n) \prod_{k=1}^l P(A = a_k | B = b_n)) \quad (3.8)$$

Bayes teoremi sınıflandırma yapılırken çıkış durumları içerisinde en büyük olasılığa sahip olan durum hedef sınıf olarak seçilir. Burada  $B'$  değişkeni hedef sınıfı,  $b_n$  ifadesi olası  $n$ . çıkış durumunu ve  $A$  değişkeni ise  $A = (a_1, a_2, \dots, a_l)$  şeklinde sınıfı belirlenecek olan giriş verisini temsil etmektedir (Orhan ve Adem, 2012).

Şekil 3.7'de NB sınıflandırıcısı örneği gösterilmiştir. NB'de her bir özellik düğümünün sınıf düğümü dışında bir üst ögesi yoktur.



Şekil 3.7. Naive bayes

### 3.3.3. Karar ağacı

Karar ağacı (KA) öznitelikler üzerinde bölünme işlemi yapılarak oluşturulur. Her bir öznitelik değeri için bir dal oluşturulur (Bramer, 2007:43-44).

Karar ağaçları kök düğümden başlar ve aşağı doğru yaprak düğümleri sonlanıncaya kadar uzanan dallar tarafından bağlantıları yapılmış karar düğümlerinden oluşur. Karar ağacı kök düğümden başlayarak her sonuca göre karar düğmesi test edilir. Her dal başka bir karar düğmesi veya sonlandırma yaprak düğmesine yol açar (Larose, 2005:107).


Karar ağacı algoritması kullanıcıların bilinmeyen verileri yorumlamasını sağlayan güçlü bir sınıflandırıcı modelidir. Karar ağacı yapısı kök düğüm, yaprak düğüm ve dallar tarafından bağlantıların yapıldığı karar düğümlerinden oluşur. Kök düğümden başlanarak karar düğümleri tek tek test edilerek yaprak düğüme kadar gidilir (Alan, 2014).

Karar ağacında kökte yer alacak öznitelik entropi formülü ile hesaplanarak bulunan bilgi kazancına göre belirlenir. Karar ağaçlarında sistem entropisi formülü;

$$H(X) = - \sum_{i=1}^n P_i \log_2(P_i) \quad (3.9)$$

ile bulunur.  $H(X)$  tüm  $i$  durumlarına ait  $P_i$  olasılıklarına bağlı bir değerdir.

Entropi belirsizliğin, beklenmeyen bir durumun ortaya çıkma olasılığını gösterir. Entropi ne kadar büyük olursa karar ağacında dallanma o kadar fazla olur. Bilgi kazancı en yüksek olan öznitelik kök olarak alınır ve bu işlem örnekleri bölecek öznitelik kalmayana kadar her düğüm için tekrarlanır. Şekil 3.8' de bir karar ağacı modeli gösterilmiştir.



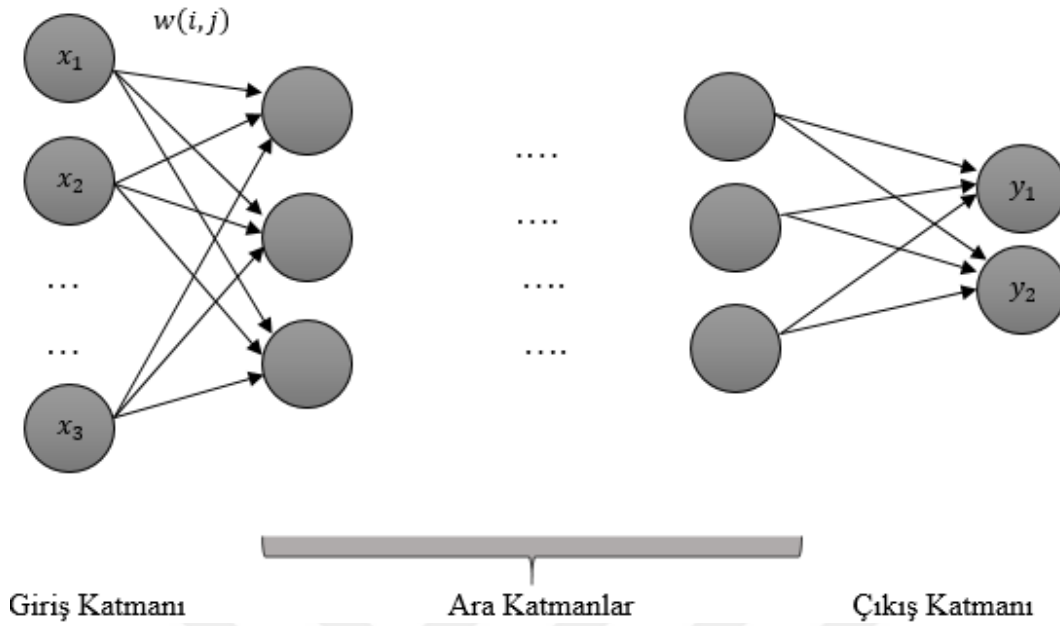
Şekil 3.8. Karar ağacı modeli

### 3.3.4. Çok katmanlı ağlar

Çok katmanlı Ağlar (ÇKA) eğitim aşamasında girdilere karşılık üretilmesi beklenen çıktıların gösterildiği modeldir. ÇKA yapısı giriş, ara ve çıktı katmanlarından oluşur. Giriş katmanında bilgiler ara katmana aktarılır. Ara katmanda giriş katmanından gelen bilgiler işlenir. Çıktı katmanında ise girişler için çıktı değerleri hesaplanır (Gör, 2016). ÇKA birbirine bağlı basit bir nöron sisteminden oluşur ve nöron hücreleri birbirine ağırlıklı bağlantılarla bağlıdır (Şekil 3.9). Her bir nöron girişlerin toplamının bir fonksiyonu olan bir çıkış sinyali üretir. Bu fonksiyon;

$$y_j = f\left(\sum x_i w_{i,j}\right) \quad (3.10)$$

şeklinde hesaplanır.  $w_{i,j}$  ağırlıkları,  $x_i$  giriş değerini  $f(.)$  aktivasyon fonksiyonunu  $y_j$  ise çıkış değerini temsil eder (Kutlu, Kuntalp M. ve Kuntalp D., 2009). Şekil.3.9'da ÇKA yapısı gösterilmiştir.



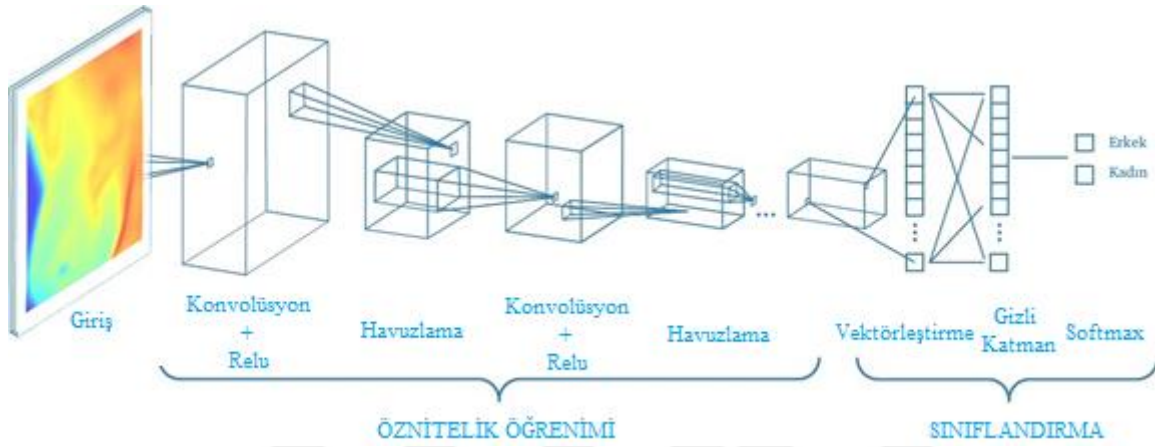
Şekil 3.9. Çok katmanlı ağ yapısı

### 3.3.5. Derin öğrenme

Derin öğrenme (DÖ), nöron boyutlarını ve değişik gizli katman sayıları denenerek girdi verilerini analiz eden yapay zeka için bir makine öğrenme tekniğidir. Her katmandaki nöron boyutunun ve gizli katman sayısının artırılması, sınıflandırma modellerinin hesaplama süresi ve eğitim hızı ile doğrudan ilgilidir (Lecun, Bengio ve Hinton, 2015). DÖ’de bilgisayar modeli ses, görüntü ya da metin aracılığı ile görüntü sınıflandırma, nesne tanımlama gibi işlemleri yapmayı öğrenir. DÖ kullanıcı tarafından giriş verilerinden çıkarılan özellikler olmadan verilen tüm resmi kullanarak kendisi öğrenme işlemi yapar (Açıl, Kutlu ve Altan, 2018). Evrişimli sinir ağları (ESA) modeli, DÖ’deki resimler üzerinde uygulanan en popüler yöntemdir. ESA bir resmi üzerinde belirli filtreler kullanarak konvolüsyon işlemi yapar. Bu sayede giriş olarak verilen görüntünün farklı yansımalarını üretir. Her konvolüsyon sonrası resme ait öznitelik çıkarımı yaparak, bu özelliklerin eğitiminin yapıldığı bir sisteme aktarır. ESA, nesne algılama, görüntünün bir bölgesinde resim türetme, zaman serisi sinyalleri, biyomedikal sinyaller kullanarak farklı hastalıkların teşhisi, yüz tanıma ve benzeri disiplinleri gerçekleştirmek için kullanılmıştır (Kutlu ve Altan, 2018). Bu mimari yapı Şekil 3.10’da gösterilmiştir.



Geliştirilen bu modelde konvolüsyon kullanılarak elde edilen en baskın özellikler çok katmanlı derin sinir ağları kullanılarak büyük miktarlarda etiketlenmiş eğitim verilerinden sınıflandırma yapabilme kapasitesine sahiptir. Bu bağlamda DÖ'yu yapay sinir ağlarından ayıran en önemli özellik resimlerin doğrudan giriş olarak verilerek modeldeki optimize edilmesi gereken parametre sayısını artırmak yerine; en baskın özelliklerini kullanarak giriş sayısını dolayısıyla da eğitim sırasındaki parametre sayısını azaltmaktır.



Şekil 3.10. Evrişimsel sinir ağı (ESA) yapısı (Ergin, T. Convolutiona Neural Network nedir Web. 17 Mart 2019)

ESA giriş katmanı, konvolüsyon katmanı (convolution) ve havuzlama (Pooling) katmanları olmak üzere ard arda yerleştirilmiş eğitilebilir birden fazla katmandan oluşmaktadır. Giriş katmanında veri ham olarak ağına verilir. Bu katmanda kullanılan görüntü boyutu eğitim süresi ve bellek ihtiyacı açısından önemlidir. Ancak boyutun küçük olması performansı düşürebilir. ESA için kullanılan resim boyutları bilgisayarların hesaplama kapasiteleri göz önünde bulundurularak küçültülür. Ayrıca renkli resimler gri tonlamaya dönüştürülerek analizler bu kanal üzerinden yapılır. Konvolüsyon katmanında görüntüdeki düşük ve yüksek seviyeli özellikleri çıkarmak için resme filtreler uygulanır. Farklı boyutlarda olabilen bu filtreler görüntü üzerinde dolaştırılarak tüm resme uygulanır. Bu işlem sonucunda her filtreye özgü özelliklerin bulunduğu bir özellik haritası (aktivasyon haritası) oluşur. Böylece ağ verinin özelliklerinin belirlenmesinde hangi bölgelerin önemli olduğunu belirler. Konvolüsyon katmanından sonra relu aktivasyon fonksiyonu kullanılır. Matematiksel ifadesi Eş. 3.11'deki gibidir. Giriş verilerinde negatif değerleri sıfır değerine çeker. Konvolüsyon ağ katmanı doğrusal bir yapıdadır. Relu aktivasyon fonksiyonu ise bu doğrusal ağ yapısını doğrusal olmayan bir yapıya sokmak için uygulanır.

$$f(a) = \begin{cases} 0, & a < 0 \\ a, & a \geq 0 \end{cases} \quad (3.11)$$

Havuzlama katmanının amacı, yüksek çözünürlükteki resimleri algılamaya çalışırken hafızaya düşen bilgi sayısını azaltmak için baskın özellik kaybetmeden boyut düşürmektir. Burada resim çözünürlüğü ne kadar büyük olursa eğitim o kadar zaman alır ve hafızada fazla yer tutar. Havuzlama işleminin amaçlarından biri de eğitim için kullanılan görüntünün yapay sinir ağları modeline küçük boyutlarda da en baskın özelliklerin aktarılmasını sağlamaktır. Bu nedenle havuzlama katmanında sonraki konvolüsyonel katman için giriş boyutu azaltılır. Boyut azaltmayı görüntünün yükseklik ve genişliğini düşürerek yapar derinlik aynı kalır. Bu işlem sonucunda kullanılan havuzlama işlemine bağlı olarak resimdeki baskın olmayan bilgiler elimine edilmiş olur. Birçok havuzlama yöntemi bulunmaktadır. Bu çalışmada maksimum havuzlama yöntemi kullanılmıştır. Bu yöntemde havuzlama boyutu dikkate alınarak resmin her bölgesindeki maksimum değer alınarak resmin boyutu küçültülür. Böylelikle işlemciye daha az yük bindirerek, daha hızlı işlem yapılmasını sağlar.

Boyut azaltma işlemi sonucunda bilgi kaybı oluşur. Havuzlama katmanında da belli boyutlarda kullanımı mevcuttur. Bu filtreler görüntü üzerinde gezdirilip, pixellerin maksimum değerlerini veya değerlerin ortalamasını alır. Bu işlem, konvolüsyon katmanı sonucu oluşan tüm yansımalar için gerçekleştirilir (İnik ve Ülker, 2017).

Derin öğrenmede doğruluk oranının %100'e yakın ya da hata oranının sıfıra yakın olması, ağın verisetindeki herşeyi ezberlemiş olduğu anlamına gelebilir bu da makine öğrenmesi algoritmaları için istenmeyen bir durumdur. Buna engel olmak için aynı katman içerisinde nöronların ağırlıklarının birbirine benzerlik oranına göre bazılarının modelden kaldırılarak optimize edilecek parametre sayısını azaltır. Bu işleme seyreltme (dropout) denir. Bu şekilde ezberleme yönteminden kaçılır.

### 3.4. Performans Ölçüm Yöntemleri

İş süreçlerinin daha iyi anlaşılmasına, süreçteki sorunların belirlenmesine ve süreçlerin iyileştirilmesine yardımcı olmak için yapılan bir işlemdir. Bu çalışmada sınıflandırma başarımları olarak hassasiyet, özgüllük, seçicilik ve doğruluk değerleri hesaplanmıştır.

Çıkarılan öznitelikler için ise bireysel en iyi seçim, ileri yönlü seçim ve n-al r bırak yöntemleri kullanılarak öznitelik seçimi yapılmıştır.

### 3.4.1. Sınıflandırma başarımları ölçümleri

Sınıflandırma bir veri kümesinin tanımlı olan çeşitli sınıflar arasında dağıtılmasıdır. Makine öğrenmesinde kullanılan sınıflandırma modellerinin hassasiyet, özgüllük, seçicilik, başarımları değerlerinin tanımlanması için gerçek verilerin bulunduğu bir test verisi üzerinde doğruluk tablosu kullanılır (Çizelge 3.1).

Sınıflandırma tahminleri ise aşağıda ifade edilen dört değerlendirmeden birine sahip olmak zorundadır (Açıl ve Kutlu, 2018).

Çizelge 3.1. Sınıflandırma doğruluk tablosu

	Tahmin Edilen Değer		
		Pozitif	Negatif
Gerçek Değer	Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
	Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

1. Gerçek Pozitif (TP), Var olan bir durumu doğru tahmin etme durumu,
2. Gerçek Negatif (TN), Var olmayan bir durumu doğru tahmin etme durumu,
3. Yanlış Negatifler (FN), Var olan bir durumu yanlış tahmin etme durumu,
4. Yanlış Pozitifler (FP), Var olmayan bir durumu yanlış tahmin etme durumudur.

Bu bilgiler kullanılarak hassasiyet Eş. 3.12, özgüllük Eş. 3.13, seçicilik Eş. 3.14 ve doğruluk değeri Eş. 3.15'te verildiği gibi hesaplanır.

$$\text{Hassasiyet} = \frac{TP}{TP+FN} \times 100 \quad (3.12)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \times 100 \quad (3.13)$$

$$\text{Seçicilik} = \frac{TP}{TP+FP} \times 100 \quad (3.14)$$

$$\text{Başarım} = \frac{TP+TN}{\text{Toplam}} \times 100 \quad (3.15)$$

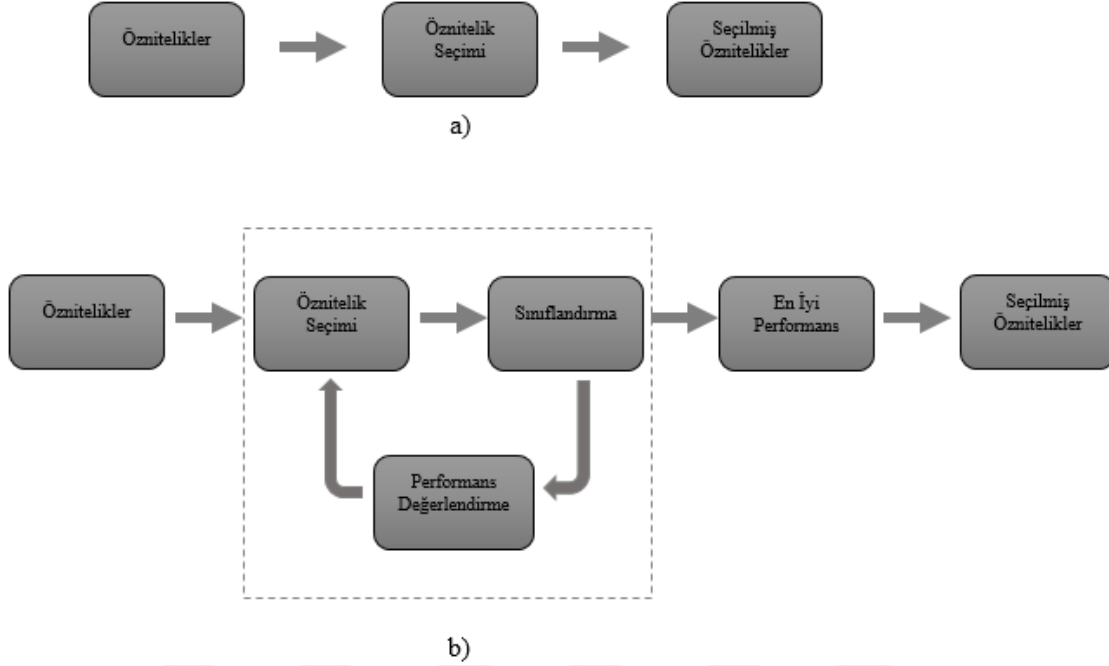
### 3.4.2. Öznitelik seçimi

Görüntüler üzerinde ışık yansımaları, makyaj, kirpik, göz kapağı düşmesi gibi nedenlerden dolayı irisin her bir pixel i aynı başarımlarına sahip olmayacağından dolayı görüntüdeki her bir pixel sınıflandırma başarımlarına farklı etki etmektedir. Ayrıca görüntülere uygulanan farklı analiz teknikleri de farklı başarımlarını gösterebilir (Tapia ve diğerleri, 2016). Bu nedenle öznitelikler arasında seçim yapmak bizi daha başarılı sonuçlara götürür.

Şekil 3.11’de filtreleme metodu ve sarmal metodu ile öznitelik seçim diyagramı verilmiştir. Sarmal metotta sınıflandırıcı performansı kullanılarak öznitelik seçimi yapılırken, filtreleme metodunda öznitelik seçimi istatistiksel ölçüler kullanılarak bulunur ve seçim aşamasında sınıflandırıcı kullanılmaz (Hall, 1999).

Bir diğer yöntem ise sarmal (wrapper method) metottur. Bu yöntemde öznitelik seçiminde, belirtilen bir sınıflandırıcının sınıflandırma performansını en üst düzeye çıkararak alt küme bulunur. Sarmal metot en iyi alt öznitelik kümesi oluşturmada filtreleme metodlarına kıyasla daha başarılıdır. Ancak başarımların hesaplanması daha uzun zaman almaktadır (Budak, 2018).

Bu çalışmada öznitelik seçimi için bireysel en iyi seçim algoritması, ileri yönlü seçim ve n-al r-bırak yöntemleri kullanılmıştır (Jain, Duin ve Mao, 2000). Bu seçim algoritmaları ile elde edilen öznitelikler k-nn sınıflandırıcısı ile sınıflandırılmıştır.



Şekil 3.11. Öznitelik seçim diyagramı a) filtreleme metodu ile b) sarmal metodu ile

Bireysel en iyi seçim algoritması (BEİSA), yönteminde, tüm özniteliklerin tek tek başarımı hesaplanır ve sıralanır. Bu sıralanmış başarımlarına göre sırayla belli bir kritere göre alt küme oluşturulur. Bu kriter alt küme sayısı olabilir veya sırayla en iyi başarımların elde edilenlerin alt küme eklenmesidir (Baker, 1985).

İleri yönlü seçim algoritmasında (Whitney, 1971) boş bir özellik kümesiyle başlanıp her defasında alt küme eklenen özniteliklerle beraber sınıflandırma başarımlarını en çok yükseltmeyi sağlayan yeni öznitelik ekleyerek başarımları hep daha iyiye götüren bir alt küme oluşturulur. Bu algoritmada alt küme eklenen öznitelikler çıkartılamamaktadır (Budak, 2018).


Bir diğer yöntem ise n-al r-bırak seçim yöntemidir. Bu yöntem iki ana kategoriye sahiptir: ileri yönlü seçim araması ve geri yönlü seçim araması. İleri yönlü seçim algoritması bir boş öznitelik alt kümesiyle başlar. Her adımda en iyi öznitelik mevcut özellik alt kümesine eklenir, bu işlem n kez tekrarlanır ve en iyi kriter değerine sahip en iyi alt küme seçilir. Geriye doğru arama algoritması tüm özniteliklerle başlar, her adım için en kötü öznitelik alt kümeden çıkarılır ve bu işlem n defa tekrarlanır. İleri yönlü seçim araması, özniteliklerin sayısını dinamik olarak artırır ve geriye doğru arama, istenen öznitelik boyutuna ulaşılan veya ölçüt işlevi azalmaya başlayana kadar özniteliklerin sayısını azaltır (Kutlu, 2010).

n-al r-bırak seim yntemi, kmeye seilen bir zniteliĐin kmeden ıkartılmaması ve kmeden ıkarılan bir zniteliĐin kmeye tekrar alınmaması problemini zmeĐ amacıyla yapılan bir algoritmadır (Stearns, 1976).



#### 4. ARAŞTIRMA BULGULARI


Bu çalışmada GFI veri tabanındaki veriler kullanılmıştır. 1500 kişinin sol ve sağ göz görüntüleri üzerinde çalışılmıştır. Bu görüntülere Daugman algoritması kullanılarak sınıflandırma için kullanılacak olan iris bölgesi elde edilmiştir. Bu iris bölgesi üzerinde öznitelik çıkarım yöntemleri kullanılarak farklı öznitelik alt kümeleri oluşturulmuştur. Oluşturulan öznitelikler seçim algoritmalarından geçirilerek yeni bir öznitelik alt kümesi oluşturulmuştur. Bu yöntemlerle elde edilen öznitelikler ayrı ayrı sınıflandırılarak başarımları karşılaştırılmıştır. Sistemin akış diyagramı Şekil 4.1’de gösterilmiştir. Bu bölümde iris bölgesinin belirlenmesi, sınıflandırma için kullanılacak olan özniteliklerin çıkarımı ve seçimi aşamalarında neler yapıldığı anlatılmıştır.




Şekil 4.1. Sınıflandırma sisteminin akış diyagramı

#### 4.1. İris ve Gözbebeği Sınırlarının Belirlenmesi

Bu aşamada çalışma için kullanılacak giriş verileri gerekli ön işlemlerden geçirilerek iris ve gözbebeğinin sınırları bulunmuştur. Böylece öznitelik çıkarımı için gerekli olan kesit alanı elde edilmiştir. Ancak ışık yansıması, göz kapağı, kirpik gibi nedenlerden dolayı iris ve gözbebeği sınırları bütün resimler için doğru bulunamamıştır. Toplamda 3000 iris görüntüsünün yaklaşık %5'lik kısmı yanlış bulunmuştur. Yanlış bulunan görüntüler üzerinde farklı görüntü işleme teknikleri kullanılarak iris ve gözbebeği sınırlarının bulunabilmesinde iyileştirme yapılmıştır. Bu şekilde hatalı bulunma oranı sıfır olmuştur. Şekil 4.2'de iris ve gözbebeği sınırı bulunamayan ve filtre uygulandıktan sonra sınırları doğru bir şekilde bulunan örnek bir iris görüntüsü ( dosya adı: 90340d4 ) verilmiştir.



a)




b)

Şekil 4.2. Dosya adı : 90340d4 yapılan ön işlemlerde a) Segmente edilemeyen b) Başarılı bir şekilde segmente edilen iris görüntüsü




## 4.2. İrisin Doku ve Geometrik Özelliklerinin Çıkarılması

İris görüntülerinden doku analizi yapılarak genel iris, bölgesel iris, hücresel iris bölgelerinden öznitelik çıkarımı yapılmıştır. İlk olarak tüm irisin görüntüsünden genel doku analizi yapılarak her bir görüntü için yedi tane istatistiksel öznitelik çıkarılmıştır. Daha sonra her bir iris dört parçaya bölünerek bölünen her parça için yedi tane olmak üzere toplamda 28 tane öznitelik çıkarımı yapılarak bölgesel doku analizi yapılmıştır. Son olarak iris görüntüsü 16 parçaya bölünerek toplamda 112 öznitelik ile hücresel doku analizi yapılmıştır. Her bölge için bulunan bu yedi öznitelik irisin maksimum, minimum, ortalama, standart sapma, varyans, basıklık ve çarpıklık değerleridir. Çalışmada kullanılan genel, bölgesel ve hücresel iris bölgeleri Şekil 4.3'te gösterilmiştir.



Şekil 4.3. Kullanılan yapılar a) genel iris b) bölgesel iris c) hücresel iris bölgeleri

Ayrıca görüntüleri Daugman dönüşümü uygulandıktan sonra elde edilen dikdörtgenel şeklin yedi tane istatistiksel değeri hesaplanmıştır. Bu dikdörtgenel alan 100x720 boyutundadır. Bu alan 2x2, 2x4, 4x4, 4x8, 4x16'lık alanlara bölünerek değişik sayıda hücresel iris bölgeleri elde edilmiştir. Şekil 4.4'te 2x2 ve 2x4'lük alanlara bölünen iris görüntülerine örnek verilmiştir. Her hücresel iris bölgesi için yedi tane istatistiksel öznitelik çıkarımı yapılmıştır. Bu bölgelerden sırası ile 28, 56, 112, 224 ve 448 öznitelik çıkarımı yapılmıştır. Daugman dönüşümü sonucunda elde edilen dikdörtgenel şekle farklı boyutlarda bölme işlemi uygulanarak çıkarılan bu öznitelikler, ayrı ayrı sınıflandırma işlemine tabi tutulmuştur ve başarımları karşılaştırılmıştır.




Şekil 4.4. Daugman dönüşüm uygulanmış görüntünün farklı boyutlara bölünmesi sırasıyla 2x2 ve 2x4

Görüntülere segmentasyon yapılarak iris bölgesinin elde edilmesi aşamasında bulunan merkez ve yarıçap koordinat bilgileri kullanılarak her görüntü için 12 tane geometrik öznitelik elde edilmiştir. Bunlar iris ve gözbebeğinin x koordinatları arasındaki mesafe, iris ve gözbebeğinin y koordinatları arasındaki mesafe, iris ve gözbebeğinin merkezleri arasındaki mesafe, irisin alanı, gözbebeğinin alanı, gerçek iris alanı, iris ve gözbebeğinin alanları oranı, iris ve gözbebeğinin yarıçap oranı, irisin çevresi, gözbebeğinin çevresi, iris ve gözbebeğinin çevrelerinin oranı, iris ve gözbebeğinin çevreleri farkıdır.

#### 4.3. Görüntülere Dalgacık Dönüşümü Uygulanarak Öznitelik Çıkarımı

Ham iris görüntülerine 'haar' dalgacık metodu uygulanarak görüntü dört alt görüntüye ayrıştırılmıştır. Şekil 4.5'te dalgacık dönüşümü sonrasında oluşan görüntüler gösterilmiştir.



Şekil 4.5. Dalgacık metodu uygulanarak elde edilen alt görüntüler a) DD b) YY c) YD d) DY


Görüntüler 286x460 boyutundadır, dönüşüm sonucunda oluşan dört alt görüntü (DD-YD-DY-YY) ise 143x230 boyutundadırlar. Bu dört alt görüntü derin öğrenme ile sınıflandırılarak başarımları karşılaştırılmıştır. Ayrıca DD görüntüsü kullanılarak 250 öznitelik çıkarımı yapılmıştır. Çıkarılan özniteliklerin sınıflandırma başarımları hesaplanmıştır.

#### 4.4. Görüntülere Gabor Filtresi Uygulanarak Öznitelik Çıkarımı

Bütün ön işlemlerden önce ham iris görüntülerine gabor filtresi uygulanmıştır. Dalga boyu 4, yönelim açısı 90 derece olarak belirlenmiştir. Filtreli görüntüler gerekli ön işlemlerden geçirilip elde edilen iris bölgesi üzerinde Daugman dönüşümü yapıldıktan sonra görüntüler 2x2, 2x4, 4x4, 4x8, 4x16'lık alanlara bölünerek her alandan 28, 56, 112, 224 ve 448 tane öznitelik çıkarımı yapılmıştır. Farklı boyutlar uygulanarak elde edilen öznitelikler sınıflandırılarak başarımları karşılaştırılmıştır. Şekil 4.6'da sol tarafta Daugman dönüşümü uygulanmış ham iris görüntüsü, sağ tarafta ise gabor filtresi uygulanan iris görüntüsü gösterilmiştir. Şekil 4.7'de ise Daugman dönüşümü uygulandıktan sonra elde edilen şeklin 2x2 ve 2x4 'lük alanlara bölünmesi bir örnek üzerinde gösterilmiştir.



Şekil 4.6. Gabor filtresi uygulanan iris görüntüsü




Şekil 4.7. Gabor filtresi uygulanmış görüntünün farklı boyutlara bölünmesi sırasıyla 2x2 ve 2x4

#### 4.5. Görüntülere Fourier Dönüşümü Uygulanarak Öznitelik Çıkarımı

Görüntüler üzerinde gerekli ön işlemler yapıldıktan sonra iris bölgesi elde edildikten sonra iki boyutlu hızlı fourier dönüşümü (2D HFD) uygulanmıştır. Dönüşüm sonucu oluşan görüntü 480x640 boyutundadır Görüntüler Şekil 4.5'te görüldüğü gibi simetrik bir yapıda olduğu için ilk 240

satır alınarak her bir satır için yedi tane istatistiksel öznitelik çıkarımı yapılarak toplamda 1680 öznitelik ile sınıflandırma yapılmıştır. Şekil 4.8’de fourier dönüşümü uygulandıktan sonra elde edilen görüntüler gösterilmektedir.



Şekil 4.8. Fourier dönüşümü uygulanan iris görüntüleri

#### 4.6. Öznitelik Seçimi

Bu aşamada bütün denenen metotlarda çıkarılan öznitelikler birleştirilmiştir ve bunlar arasında öznitelik seçimi yapılarak daha iyi başarımlar elde edilmeye çalışılmıştır. Toplamda 3832 iris özniteliği üzerinde çalışılmıştır. Bu öznitelikler bireysel en iyi seçim, ileri yönlü seçim ve n-al r-birak seçim algoritmaları kullanılarak bir öznitelik alt kümesi oluşturulmuştur. Daha sonra sonuçlar karşılaştırılmıştır.

Çalışmada kullanılan seçim algoritmaları sonucunda oluşan öznitelikler k-nn sınıflandırıcısı kullanılarak sınıflandırılmıştır. Hem kullanım kolaylığı hem de kararlı yapısından dolayı k-nn sınıflandırıcısı tercih edilmiştir (Gümüşçü, Aydılek ve Taşaltın, 2016).

İris göz yapısının eşsizliği ve hatta sağ ve sol iris birbirinden farklı olmasından dolayı seçim algoritmalarında sağ ve sol göz olmak üzere ayrı ayrı değerlendirilmiştir. Sol göz resmi kullanılarak öznitelik seçim algoritmalarıyla hangi özniteliklerin seçildiği aşağıdaki çizelgelerde gösterilmiştir. Burada GO geometrik öznitelikler, TD transform uygulanmış iris görüntüsünden çıkarılan doku öznitelikleri, G gabor filtresi uygulandıktan sonra çıkarılan öznitelikler, F fourier dönüşümü uygulandıktan sonra çıkarılan öznitelikler, W dalgacık analizi uygulandıktan sonra ve D transform yapılmadan iris görüntülerinden çıkarılan doku öznitelikleri ifade etmektedir. Çizelge 4.1’de, yöntemlerden elde edilen öznitelik sayıları ayrı ayrı gösterilmiştir. Bu öznitelikler normalizasyon ve dönüşüm yapılmadan,

normalizasyon yapıldıktan sonra ve doğrusal olmayan dönüşüm yapıldıktan sonra incelenmiştir.

Çizelge 4.1. Kullanılan yöntemlerden elde edilen öznitelik sayıları

Öznitelikler	Öznitelik Sayıları
GO	12
TD	875
G	868
F	1680
W	250
D	147
<b>Toplam</b>	<b>3832</b>

Bireysel en iyi seçim algoritması kullanılarak çıkarılan özniteliklerde en yüksek başarımın yakalandığı noktada sol göz için hangi gruptan kaçar tane öznitelik kullanıldığı Çizelge 4.2'de sağ göz için ise Çizelge 4.3'te verilmiştir.

Çizelge 4.2. Sol göz için bireysel en iyi seçim algoritmasında kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	0	2	1
TD	0	0	0
G	5	1	5
F	0	0	0
W	3	2	3
D	0	1	1
<b>Toplam</b>	<b>8</b>	<b>6</b>	<b>10</b>

Çizelge 4.3. Sağ göz için bireysel en iyi seçim algoritmasında kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	0	0	0
TD	6	1	1
G	0	3	2
F	0	0	3
W	1	0	0
D	2	0	0
Toplam	9	4	6

İleri yönlü seçim algoritması kullanılarak sol göz kullanılarak başarımlarının en yüksek olduğu yerde çıkarılan öznitelik sayıları ve bunların öznitelik çıkarım metotları arasındaki dağılımı Çizelge 4.4'te, sağ göz kullanılarak çıkarılan özniteliklerin gruplar arası dağılımı ise Çizelge 4.5'te gösterilmiştir.

Çizelge 4.4. Sol göz için ileri yönlü seçim algoritmasında kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	0	0	1
TD	0	302	195
G	40	422	136
F	0	7	492
W	1	18	0
D	1	52	61
Toplam	42	801	885

Çizelge 4.5. Sağ göz için ileri yönlü seçim algoritmasında kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	5	5	5
TD	460	425	461
G	458	381	425
F	5	8	7
W	0	0	1
D	0	0	1
Toplam	928	819	900

N-al r-bırak seçim algoritması kullanılarak sol göz için yapılan sınıflandırmada seçilen öznitelikler ve bu özniteliklerin hangi öznitelik çıkarım metoduyla çıkarılan öznitelikler olduğu Çizelge 4.6'da, sağ göz için ise Çizelge 4.7'de gösterilmiştir.

Çizelge 4.6. Sol göz için n-al r-bırak seçim algoritmasında kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	0	0	1
TD	44	79	93
G	105	325	75
F	376	0	289
W	0	12	1
D	296	157	395
Toplam	821	573	854

Çizelge 4.7. Sağ göz için n-al r-bırak seçim algoritması ile kullanılan öznitelik sayılarının dağılımı

	Normal	Max_norm	Doğrusal Olmayan Dönüşüm
GO	0	0	0
TD	5	2	8
G	10	11	19
F	241	322	219
W	1	1	1
D	0	0	215
Toplam	257	336	462

Öznitelik seçim algoritmalarında kullanılan özniteliklere bakıldığında daha çok Daugman dönüşümü uygulanarak yapılan doku analizi, gabor filtresi ve fourier dönüşümü sonucunda elde edilen öznitelikler bu çalışma için daha anlamlı olmuştur.

#### 4.7. Derin Öğrenme ile Sınıflandırma

Bu çalışmada alternatif metot olarak derin öğrenme (DÖ) ile sınıflandırma yapılmıştır. Makine öğrenmesinde, verilerden öznitelik çıkarımı yapılarak sınıflandırma işlemi yapılırken, derin öğrenmede ham veri ağı verilir ve giriş olarak verilen tüm resimler kullanılarak hem öznitelik çıkarma hem de öğrenme işlemi yapar. Yani derin öğrenmede öznitelik çıkarım aşaması yoktur. Öğrenme için ne kadar çok veri kullanılırsa başarı oranı o kadar iyileşmektedir. Ancak kullanılan verinin büyüklüğü eğitim süresini uzatmaktadır. Bu nedenle bilgisayarların, işlem süresini azaltmak için grafik işlemcili birimi kullanılmaktadır.

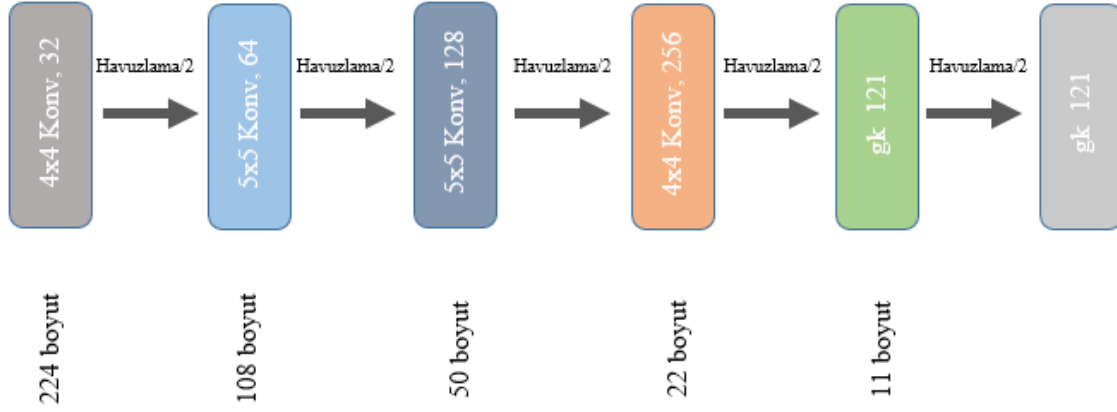
LeNET, AlexNet, VGGNet, GoogLeNet, ZFNet gibi çeşitli ESA yapıları vardır. Bu çalışmada ESA modelimizi belirli nöron sayısı ve filtre büyüklükleri aralıklarında deneyerek kendimiz gerçekleştirdik. Bu model oluşturulurken keras kütüphanesi kullanılmıştır (Keros-Team, 2019). Bu sayede en optimum ve yüksek sınıflama performansına sahip modeli belirleyerek Şekil 4.9' da paylaşılmıştır.



Bu çalışmada derin ağ yapısında birçok parametre ve katman denenmiştir. Katmanlarda kullanılan filtre boyutları sırasıyla 4x4, 5x5, 5x5, 4x4 olarak belirlenmiştir. Evrişim katmanından sonra gelen 2x2 boyutunda dört havuzlama katmanı kullanılmıştır. Ayrıca evrişim katmanında kullanılan filtre sayıları 32, 64, 128 ve 256'dır. Sonrasında 0,5 oranında seyreltme uygulanarak yapay sinir ağı modelimize giriş olarak verilmiştir. Belirlenen ağ modelinde iki gizli katman bulunmaktadır ve her gizli katmanda 121 nöron olacak şekilde ayarlanıp eğitim başlatılmıştır. Döngü sayısı 100, öğrenme katsayısı  $0,70e-5$  ve her eğitimde kullanılan veri kümesi büyüklüğü 20 olarak belirlenmiştir. En iyi başarı oranı bu parametreler kullanılarak elde edilmiştir. Elde edilen sonuçlar Çizelge 4.8'de gösterilmiştir.

Ağ için kullanılan görüntüler 227x227 boyutunda ve gri renklidir ve oluşturulan model Şekil 4.9'da gösterilmiştir. Eldeki verilerin %70'i eğitim ve %30'u test olacak şekilde ayrılmıştır. Toplamda oluşturulan dört konvolüsyonel katmanlar aşağıdaki gibi tanımlanmıştır:

- Birinci konvolüsyonel katmana 4x4 boyutunda 32 filtre uygulanmıştır. Daha sonra düzeltilmiş doğrusal birim (relu) uygulanır ve 2x2 boyutunda maksimum havuzlama katmanı uygulanır.
- İkinci konvolüsyonel katmana 5x5 boyutunda 64 filtre uygulandıktan sonra düzeltilmiş doğrusal birim uygulanır ve 2x2 boyutunda maksimum havuzlama katmanı uygulanır.
- Üçüncü konvolüsyonel katmana ise 5x5 boyutunda 128 filtre uygulanmıştır. düzeltilmiş doğrusal birim uygulandıktan sonra 2x2 boyutunda maksimum havuzlama katmanı uygulanmıştır.
- Son olarak dördüncü katmanda ise 4x4 boyutunda 256 filtre uygulanmıştır. Filtre uygulandıktan sonra düzeltilmiş doğrusal birim uygulanır ve 2x2 boyutunda maksimum havuzlama katmanı uygulanmıştır.
- İlk gizli katmanda 121 nöron vardır ve 0,5 oranında seyreltme (dropout) yapılmıştır.
- İkinci gizli katmanda 121 nöron vardır.
- Son olarak çıkış katmanında iki nöron değeri vardır ve her çıkışın değerini hesaplarken kullanılan aktivasyon fonksiyonu olarak softmax bulunur.



Şekil 4.9. Oluşturulan konvolüsyonel sinir ağı modeli

Çizelge 4.8’de farklı parametreler denenerek bulunan sonuçlar gösterilmiştir. Burada küme büyüklüğü (batch size) 20 olarak belirlenmiştir. En yüksek başarımlar 0.80e-5 öğrenme katsayısıyla elde edilmiştir (%81,45).

Çizelge 4.8. Konvolüsyonel sinir ağı ile cinsiyet sınıflandırma başarımlar oranı

ÖK	Döngü Sayısı	Doğruluk (%)
0. 70e-5	50	68,41
0. 80e-5	50	71,72
0. 90e-5	50	72,48
1 e-5	50	75,15
0. 70e-5	100	74,49
0. 80e-5	100	<b>81,45</b>
0. 90e-5	100	72,44
1 e-5	100	78,45
0. 70e-5	150	75,76
0. 80e-5	150	72,23
0. 90e-5	150	78,41
1 e-5	150	68,28

## 5. SONUÇ VE ÖNERİLER

Bu çalışmada üçüncü bölümde açıklanan çeşitli yöntemler ile çıkarılan öznitelikler kullanılarak her yöntemin sınıflandırma başarımlarına bakılmıştır. Bu öznitelikler normalize edilmeden, normalize edildikten sonra ve doğrusal olmayan dönüşüm yapıldıktan sonraki öznitelikler ayrı ayrı sınıflandırılarak başarımları karşılaştırılmıştır. Ayrıca çıkarılan bütün öznitelikler birleştirilerek bir öznitelik havuzu oluşturulmuştur. Bu öznitelik havuzu da normalize işlemi yapılmadan, normalize edildikten sonra ve doğrusal olmayan dönüşüm yapıldıktan sonra bireysel en iyi seçim, ileri yönlü seçim ve n-al r-bırak seçim algoritmalarından geçirilerek sınıflandırma için daha anlamlı öznitelikler seçilip başarımları yükseltilmiştir ve değişik üç tür veri için başarımları karşılaştırılmıştır. Öznitelik seçim aşamasında hangi öznitelik çıkarım yöntemine ait özniteliklerin kullanıldığına bakılarak yöntem başarımları incelenmiştir. Sınıflandırma aşamasında ağ eğitiminde 1000 kişi eğitim için, 500 kişi ise test için kullanılmıştır. Elde edilen sonuçlar ve literatürdeki sonuçlarla karşılaştırılması aşağıdaki alt başlıklarda detaylı olarak anlatılmıştır.

### 5.1. Sınıflandırma Başarımları

Bu bölümde farklı öznitelik çıkarım metotlarıyla oluşturulan öznitelikler ve verilerin istatistiksel, geometrik öznitelikleri ayrı ayrı sınıflandırılarak başarımları karşılaştırılmıştır. Burada GO, üçüncü bölümde detaylı olarak açıklanan şekilde irisin toplamda 12 tane geometrik özneliğini göstermektedir. D iris görüntüsüne Daugman dönüşümü uygulandıktan sonra çıkarılan yedi tane özneliği, D1, D2, D3, D4 ve D5 Daugman dönüşümü uygulandıktan sonra oluşan 100x720 boyutundaki görüntü sırasıyla 2x2, 2x4, 4x4, 4x8, 4x16 boyutlarına bölünerek oluşan her bir pencere için yedi tane istatistiksel değer hesaplanarak bulunan 28, 56, 112, 448 tane özneliği ifade etmektedir. G1, G2, G3, G4 ve G5 ise Daugman dönüşümü yapıldıktan sonra görüntülere gabor filtresi uygulanarak yine aynı şekilde 2x2, 2x4, 4x4, 4x8 ve 4x16'lık boyutlara bölünerek elde edilen her pencere için yedi tane istatistiksel öznitelik çıkarımı yapılarak sırasıyla 28, 56, 112, 224, 448 öznitelik değerlerini ifade etmektedir. F 480x640 boyutundaki görüntülere fourier dönüşümü uygulandıktan sonra görüntünün ilk 240 satırının herbir satırından çıkarılan yedi tane istatistiksel değer çıkarılarak toplamda 1680 tane öznitelik değeri bulunan öznitelikleri, W ise görüntüye dalgacık dönüşümü uygulandıktan sonra bulunan 250 özneliği ifade etmektedir. DT, sadece ön işlemler yapılarak elde edilen iris görüntüsünden

elde edilen yedi tane istatistiksel özniteliği, bu iris görüntüsünün dört eşit bölgeye bölünerek her bir bölgesinden çıkarılan yedi tane istatistiksel öznitelik sırasıyla DT1, DT2, DT3 ve DT4'de tutulmaktadır. DT5 ise iris görüntüsünün 16 eşit parçaya bölünerek her bir bölgeden çıkarılan istatistiksel özellikler olmak üzere toplamda 112 öznitelik değerini göstermektedir. Bu değerler hiçbir işlem yapılmadan, normalizasyon uygulanarak ve doğrusal olmayan dönüşüm yapılarak üç farklı aşamada k-nn, naive bayes, karar ağacı ve çok katmanlı ağlar sınıflandırıcıları ile sınıflandırılıp başarımları karşılaştırılmıştır.

Çizelge 5.1'de sol iris görüntüleri kullanılarak bulunan özniteliklere normalizasyon ve doğrusal olmayan dönüşüm uygulanmadan yapılan sınıflandırılma başarımları gösterilmiştir. Sonuçlara bakıldığında sınıflandırma başarımları en yüksek olan sonuç, naive bayes sınıflandırıcısı kullanılarak dalgacık analizi ile oluşturulan özniteliklerden elde edilmiştir (%68,33). Ayrıca doku analizinde Daugman dönüşümü yapılarak elde edilen başarımları, dönüşüm uygulanmadan yapılan doku analizine göre daha yüksektir.

Çizelge 5.2'de sol iris görüntüleri kullanılarak bulunan özniteliklere maksimum normalizasyon işlemi uygulandıktan sonra elde edilen sınıflandırma başarımları verilmiştir. Genel olarak özniteliklerin normalize edilmiş hali ile daha iyi sonuçlar elde edilmiştir. Bu sonuçlar arasında da en yüksek başarımları dalgacık dönüşümü ile çıkarılan özniteliklerin naive bayes ile sınıflandırılmasıyla elde edilmiştir (%67,67).

Çizelge 5.1. Normalizasyon uygulanmamış sol iris verilerinin sınıflandırma başarımları

	K-NN	Naive Bayes	Karar Ağacı	Çok Katmanlı Ağlar
GO	<b>57,25</b>	53,12	54,06	53,02
D	<b>58,85</b>	57,28	56,45	58,23
D1	63,74	55,23	58,14	<b>64,85</b>
D2	61,58	59,65	<b>63,46</b>	63,02
D3	61,02	60,56	61,25	<b>66,58</b>
D4	48,45	55,01	<b>62,75</b>	59,47
D5	46,58	58,65	<b>64,55</b>	62,46
G1	<b>60,42</b>	54,96	53,85	55,75
G2	57,65	55,12	54,05	<b>58,91</b>
G3	<b>60,89</b>	56,36	59,57	58,44
G4	53,33	56,45	<b>58,03</b>	55,08
G5	54,75	56,48	<b>59,65</b>	55,56
F	<b>60,53</b>	59,04	59,45	58,23
W	51,21	<b>68,33</b>	66,47	64,58
DT1	<b>52,48</b>	49,93	50,65	49,08
DT2	<b>52,45</b>	49,95	50,36	49,58
DT3	50,53	51,65	<b>52,86</b>	49,58
DT4	49,65	<b>51,75</b>	50,58	50,47
DT	50,74	51,54	52,03	<b>51,93</b>
DT5	58,09	54,85	57,54	<b>59,03</b>

Çizelge 5.2. Normalizasyon uygulanmış sol iris verilerin sınıflandırma başarımları

	K-NN	Naive Bayes	Karar Ağacı	Çok Katmanlı Ağlar
GO	56,45	53,21	55,34	52,69
D	60,15	57,91	57,78	58,54
D1	63,79	55,84	60,19	63,23
D2	64,23	59,45	61,18	62,54
D3	46,15	60,82	64,15	67,48
D4	64,37	55,48	60,11	65,58
D5	61,59	58,45	57,81	62,13
G1	58,91	54,23	52,46	56,68
G2	57,62	55,54	56,18	58,25
G3	43,54	55,14	57,53	60,41
G4	61,13	55,62	59,32	55,12
G5	56,18	57,71	61,53	55,41
F	61,83	59,55	59,46	63,68
W	60,45	67,67	65,84	62,91
DT1	64,58	64,35	65,22	65,74
DT2	63,71	61,22	62,33	63,44
DT3	57,25	53,69	52,38	53,91
DT4	57,18	50,33	49,75	51,82
DT	60,51	63,23	61,34	62,98
DT5	58,55	53,62	58,43	59,31

Son olarak sol iris görüntüleri kullanılarak bulunan özneliklere doğrusal olmayan dönüşüm uygulandıktan sonra elde edilen başarımlar oranları karşılaştırılmıştır (Çizelge 5.3). Bu yöntemle de en yüksek başarımlar oranı dalgacık analizi kullanılarak özneliklerin naive bayes sınıflandırıcısı kullanılmasıyla elde edilmiştir (%67,81).

Çizelge 5.3. Doğrusal olmayan dönüşüm uygulanmış sol iris verilerin sınıflandırma başarımları

	K-NN	Naive Bayes	Karar Ağaçları	Çok Katmanlı Ağlar
GO	52,60	53,66	<b>53,73</b>	52,93
D	<b>58,20</b>	56,60	55,20	55,73
D1	<b>60,86</b>	57,23	60,01	59,53
D2	61,06	57,26	<b>62,01</b>	61,86
D3	60,33	58,66	60,46	<b>67,01</b>
D4	60,06	56,01	58,26	<b>60,73</b>
D5	59,80	58,06	57,06	<b>61,93</b>
G1	58,71	56,03	56,12	<b>59,03</b>
G2	<b>57,86</b>	54,73	55,80	56,26
G3	57,06	54,93	56,66	<b>59,46</b>
G4	58,20	56,33	<b>58,66</b>	53,86
G5	58,53	55,33	<b>56,81</b>	55,2
F	60,53	59,73	60,53	<b>61,25</b>
W	60,46	<b>67,81</b>	65,80	64,41
DT1	59,73	64,33	62,86	<b>66,01</b>
DT2	60,93	61,06	<b>63,20</b>	61,20
DT3	<b>55,80</b>	51,73	52,53	54,6
DT4	<b>55,41</b>	50,93	50,41	51,82
DT	58,53	62,42	<b>63,13</b>	62,26
DT5	57,53	54,81	59,26	<b>58,61</b>

Sağ iris görüntülerinden elde edilen özniteliklere normalizasyon ve doğrusal olmayan dönüşüm uygulanmadan ham veriler kullanılarak K-NN, NB, KA ve ÇKA sınıflandırıcıları ile sınıflandırılıp başarımları karşılaştırılmıştır (Çizelge 5.4).

Sağ iris görüntülerinden elde edilen özniteliklere normalizasyon işlemi uygulandıktan sonra sınıflandırma başarımları Çizelge 5.5’te verilmiştir.

Sağ iris görüntülerinden elde edilen özniteliklere doğrusal olmayan dönüşüm uygulandıktan sonra K-NN, NB, KA ve ÇKA sınıflandırıcıları ile sınıflandırılıp başarımları karşılaştırılmıştır (Çizelge 5.6).

Çizelge 5.4. Normalizasyon ve dönüşüm uygulanmamış sağ iris verilerinin sınıflandırma başarımları

	K-NN	Naive Bayes	Karar Ağaçları	Çok Katmanlı Ağlar
GO	46,63	55,46	47,41	55,74
D	50,67	56,60	53,17	54,45
D1	53,63	55,33	48,35	58,74
D2	47,71	56,45	48,86	62,45
D3	50,43	59,47	50,69	<b>65,14</b>
D4	48,78	57,74	48,94	<b>59,43</b>
D5	47,43	59,25	47,75	<b>62,93</b>
G1	53,09	57,05	49,45	<b>60,23</b>
G2	51,75	<b>55,92</b>	51,34	55,74
G3	48,51	55,75	48,79	<b>58,85</b>
G4	52,02	<b>58,13</b>	50,32	52,25
G5	53,92	54,45	52,05	<b>56,20</b>
F	51,48	58,74	49,01	<b>62,15</b>
W	62,63	<b>68,21</b>	61,92	65,52
DT1	52,02	63,75	49,59	<b>64,25</b>
DT2	50,67	<b>62,95</b>	48,86	62,18
DT3	45,01	52,54	50,13	55,62
DT4	52,29	49,95	48,06	52,45
DT	<b>64,63</b>	63,22	47,99	61,15
DT5	50,45	53,14	51,78	<b>59,54</b>



Çizelge 5.5. Normalizasyon uygulanmış sağ iris verilerinin sınıflandırma başarımları

	K-NN	Naive Bayes	Karar Ağaçları	Çok Katmanlı Ağlar
GO	<b>53,12</b>	51,64	50,98	51,93
D	43,12	53,55	50,98	<b>54,61</b>
D1	42,58	<b>60,33</b>	50,62	58,23
D2	43,39	57,16	50,83	<b>61,75</b>
D3	43,12	53,66	51,49	<b>65,05</b>
D4	42,85	55,25	51,13	<b>59,35</b>
D5	42,58	57,06	50,98	<b>60,43</b>
G1	42,58	53,03	50,76	<b>58,25</b>
G2	43,39	51,45	49,38	<b>57,04</b>
G3	45,28	56,93	50,25	<b>58,36</b>
G4	44,47	<b>55,33</b>	50,91	51,75
G5	43,93	51,73	50,98	<b>54,04</b>
F	43,12	57,52	50,98	<b>60,36</b>
W	50,67	<b>66,75</b>	49,01	63,75
DT1	49,05	63,25	50,91	<b>64,01</b>
DT2	43,66	61,06	50,91	61,20
DT3	43,93	51,73	51,71	54,6
DT4	44,47	50,93	52,88	51,82
DT	42,85	62,42	50,54	62,26
DT5	42,85	54,81	50,25	<b>58,61</b>

Çizelge 5.6. Doğrusal olmayan dönüşüm uygulanmış sağ iris verilerinin sınıflandırma başarımları


	K-NN	Naive Bayes	Karar Ağaçları	Çok Katmanlı Ağlar
GO	49,86	51,45	49,08	<b>55,73</b>
D	46,36	<b>57,65</b>	49,89	54,44
D1	52,29	55,33	48,65	<b>60,63</b>
D2	46,36	58,16	48,14	<b>62,75</b>
D3	52,83	55,46	50,32	<b>66,11</b>
D4	54,44	55,11	48,86	<b>59,63</b>
D5	46,09	59,16	49,74	<b>61,04</b>
G1	50,67	58,23	50,47	<b>59,54</b>
G2	47,97	54,73	48,06	<b>55,16</b>
G3	51,21	55,53	49,81	<b>60,36</b>
G4	50,13	<b>57,23</b>	49,59	55,45
G5	49,86	54,46	48,57	54,02
F	52,02	58,65	47,62	<b>62,25</b>
W	45,82	<b>68,01</b>	48,94	63,21
DT1	<b>49,32</b>	65,37	49,74	<b>66,41</b>
DT2	51,48	<b>62,09</b>	51,2	60,05
DT3	<b>53,91</b>	52,43	48,14	53,55
DT4	50,13	<b>55,83</b>	53,02	52,72
DT	50,13	61,52	52,88	<b>62,16</b>
DT5	52,29	55,92	50,41	<b>59,74</b>

Genel olarak tüm sonuçlar karşılaştırıldığında başarımları birbirine yakın olmuştur, az da olsa hiçbir işlem uygulanmadan ham iris verilerinden daha yüksek sonuçlar elde edilmiştir. Doku analizi ile yapılan öznitelikler daha başarılı sonuçlar vermiştir. En yüksek başarımlar bütün yöntemlerde dalgacık analiziyle çıkarılan özniteliklerin naive bayes sınıflandırıcısı kullanılarak elde edilmiştir. Geometrik öznitelikler ve gabor filtresi sonucu oluşan özniteliklerle diğer özniteliklere kıyasla daha az başarımları elde edilmiştir.

Bu aşamada öznitelik seçim işlemi yapılmadan elde edilen bütün öznitelikler kullanılmaktadır. Bu öznitelikler arasında kirpik, göz kapağı, yansıma gibi nedenlerden


dolayı işe yaramayan, başarı oranını düşüren bilgiler de yer almaktadır. Bu gereksiz bilgiler atılmadan sınıflandırma işlemi yapıldığı için başarı oranı %70'lere yakın çıkmıştır. Başarı oranını yükseltmek için bireysel en iyi seçim, ileri yönlü seçim ve n-al r-bırak seçim algoritmaları kullanılmıştır. Bu yöntemler sonucunda elde edilen başarı grafikleri aşağıda gösterilmiştir.

Bireysel en iyi seçim algoritmasında öznelikler arasında tek tek en yüksek başarımlı öznelikler bulunarak sırayla öznelik havuzuna eklenmektedir. Burada iris görüntülerinden çıkarılan ham öznelikler, bu özneliklere normalizasyon işlemi uygulandıktan sonraki öznelikler ve doğrusal olmayan dönüşüm uygulanan özneliklerin kullanılmasıyla elde edilen başarımlar gösterilmiştir (Şekil 5.1).



a)


b)



c)

Şekil 5.1. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özneliklerin BEİSA ile sınıflandırılma başarımları grafiği


Bireysel en iyi seçim algoritmasında sol iris görüntüleri üzerinde elde edilen başarımlar birbirine çok yakın çıkmıştır. Aynı şekilde sağ iris görüntüsünden elde edilen başarımlar da birbirine çok yakın çıkmıştır (Şekil 5.2). Bireysel en iyi seçim algoritmasında özneliklerin birlikte uyumuna bakılmaması dezavantajından dolayı çok iyi başarımlar elde edilememiştir. Bu başarımların yükseltmek için bir sonraki adımda ileri yönlü seçim algoritması denenmiştir.




Şekil 5.2. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özneliklerin BEİSA ile sınıflandırılma başarımlar grafiği

İleri yönlü seçim algoritmasında, bireysel en iyi seçim algoritmasına oranla daha iyi sonuçlar alınmıştır. Bu algorithmada sol iris görüntüleri kullanılarak boş bir öznelik kümesiyle başlayıp en iyi başarımlarına sahip öznelik kümeye alındıktan sonra sırayla kümede


bulunan öznitelik ile birlikte hangi özneliğin daha yüksek başarımları verdiği kontrol edilir ve başarımlarını en çok yükselten öznitelik kümeyle alınır. Bu seçim işlemi başarımlarını yükseltecek öznelik kalmayana kadar devam eder. Şekil 5.3'te sol iris görüntüleri ve Şekil 5.4'te ise sağ iris görüntüleri kullanılarak elde edilen başarımlar verilmektedir. İki grafikte de en yüksek başarımları doğrusal olmayan dönüşüm sonucu elde edilen özneliklerden elde edilmiştir.



a)




b)




c)


Şekil 5.3. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özneliklerin ileri yönlü seçim algoritması ile sınıflandırılma başarımları grafiği



a)




b)




c)

Şekil 5.4. a) normalizasyon ve dönüşüm yapılmamış b) normalizasyon yapılmış c) doğrusal olmayan dönüşüm uygulanmış özniteliklerin ileri yönlü seçim algoritması ile sınıflandırılma başarım grafiği


Son olarak n-al r-bırak seçim algoritması ile sol iris görüntüleri kullanılarak (Şekil 5.5) ve sağ iris görüntüleri kullanılarak (Şekil 5.6) sınıflandırma işlemi yapılmıştır. En yüksek başarım oranı bu seçim algoritmasıyla elde edilmiştir. Burada görüntüleri normalizasyon uygulanmış, doğrusal olmayan dönüşüm uygulanmış ve hiçbir işlem uygulanmadan elde edilen özniteliklerin ile sınıflandırma yapılarak karşılaştırılmıştır. Bu seçim algoritması ile de en yüksek başarım doğrusal olmayan dönüşüm sonucu elde edilmiştir.



a)




b)




c)


Şekil 5.5. a) normalizasyon ve dönüşüm uygulanmadan b) max normalizasyon uygulanmış, c) doğrusal olmayan dönüşüm uygulanmış n-al r-bırak seçim algoritması ile elde edilen başarımlar grafikleri



a)



b)



c)

Şekil 5.6. a) normalizasyon ve dönüşüm uygulanmadan b) max normalizasyon uygulanmış, c) doğrusal olmayan dönüşüm uygulanmış n-al r-bırak seçim algoritması ile elde edilen başarımlar grafikleri

## 5.2. Sonuçların karşılaştırma

Bu çalışmada ND\_GFI veritabanının 1500 tane sol 1500 tane sağ iris görüntüsü kullanılmıştır. Toplamda 1500 kişinin 3000 iris görüntüsü üzerinde çalışılmıştır. Görüntüler üzerinde gerekli ön işlemler yapıldıktan sonra irisin doku özneliği, geometrik özneliği ve görüntülere gabor filtresi, dalgacık analizi, fourier dönüşümü uygulandıktan sonra çıkarılan öznelikler kullanılarak k- en yakın komşu, Naive bayes, karar ağacı ve çok katmanlı ağlar ile sınıflandırma işlemi yapılarak elde edilen başarımları bir önceki adımda gösterilmiştir. Sonuç olarak çıkarılan bütün özneliklerin birleşimi ile oluşturulan öznelik



havuzunda bireysel en iyi seçim, ileri doğru seçim ve n-al r-bırak seçim algoritmaları ile öznitelik seçimi yapılarak k-nn sınıflandırıcısı ile seçim işlemleri gerçekleştirilmiştir.

Öznitelik bağımsız yöntem olarak derin öğrenme algoritması kullanılarak yapılan ham resimler ile farklı parametreler denenmiş yaklaşık %81,45 başarımları ile sınıflandırılma yapılmıştır.

Aynı veritabanı kullanılarak literatürde Tapia ve diğerleri (2016) 1824 kişiye ait olan 4944 iris görüntüsü kullanılarak gabor filtresi ile öznitelik seçimi ve karşılıklı bilgi seçim yöntemi ile öznitelik seçimi yapıldıktan sonra destek vektör makinesi ile %89 başarımları elde edilmiştir. Bir diğer çalışmada Tapia ve Arevena (2017) 1824 kişiye ait olan 4944 görüntü üzerinde çalışılmıştır. Derin öğrenmenin evrişimsel sinir ağı modeli ile %83 başarımları elde edilmiştir.

Amrolkar ve Tugave (2015) 64980 iris görüntüsü kullanarak üniform bölgesel ikili örüntü ve geliştirilmiş ikili dönüşüm metodları ile öznitelik çıkarımı yapıp, bu öznitelikler birleştirilerek kullanılmıştır. Destek vektör makinesi sınıflandırıcısı ile %88,4 başarımları ile cinsiyet sınıflandırılması yapılmıştır.

Benzer şekilde literatürde yapılan çalışmaya paralel olarak; Bansal ve diğerleri (2014) yaptıkları çalışmada 200 kişinin 400 iris görüntüsünü kullanarak görüntülerin istatistiksel öznitelikleri ve görüntülere dalgacık analizi uygulandıktan sonra çıkarılan doku öznitelikleri birleştirilip, destek vektör makinesi sınıflandırıcısı kullanılarak %85,6 başarımlarıyla sınıflandırma işlemi yapılmıştır.

Bu tezde yapılan çalışma literatürdeki benzer çalışmalarla karşılaştırıldığında genel olarak daha iyi sonuçlar alınmıştır. Tapia ve diğerleri (2016) ve Amrolkar ve Tugave (2015) tarafından yapılan çalışmalarla kıyaslandığında ise daha az sayıda veri kullanılarak daha yüksek başarımları elde edilmiştir. Kullanılan veri sayısı artırılarak daha yüksek başarımları edilebileceği düşünülmektedir.

Sonuç olarak, iris kullanılarak yapılan araştırmamızda 6 farklı yöntem ve itirasyonları ile öznitelik setleri oluşturulmuş ve bu öznitelik kümelerinin başarımlarına bakılmıştır. Her bir öznitelik kümesinden elde edilen sonuçlara bakıldığında hepsinde de vasat bir başarımları

olduđu grlmřtr. Sonuta, yapılan alıřmayla cinsiyet sınıflandırmada, iris resimlerini belirli bir yntemle znelik ıkarılmadıđını gstermiřtir. znelik seim algoritmalarında kullanılan zneliklere bakıldıđında daha ok Daugman dnřm uygulanarak yapılan doku analizi, gabor filtresi ve fourier dnřm sonucunda elde edilen znelikler bu alıřma iin daha anlamlı olmuřtur. Ayrıca sonulara bakıldıđında sol iris verilerinden elde edilen zneliklerle sađ iris verilerine oranla daha yksek bařarım elde edilmiřtir.

Sou olarak ıkarılan btn zneliklerin birleřimi ile oluřturulan znelik havuzunda n-al r-bırak seim algoritmaları ile znelik seimi yapılarak k-nn sınıflandırıcısı ile %91,80'e bařarım oranı elde edilmiřtir.



## KAYNAKLAR

- Abbak, A. (2007). Jeodezide Zaman Dizilerinin Dalgacık (Wavelet) Analizi. *Selçuk Üniversitesi* 7-17.
- Açıl, T., Kutlu, Y. ve Altan, G. (2018). İris Görüntülerinden Derin Öğrenme ile Cinsiyet Sınıflandırma *World Symposium of Multidisciplinary Research (WOSMUR2018)*, At Mersin, Turkey, Volume: 2(2), 25-31.
- Açıl, T., Kutlu, Y. (2018). Gender Estimation from Iris Images Using Tissue Analysis Techniques; *International Conference on Artificial Intelligence towards Industry 4.0*
- Alan, M. A. (2014). Karar ağaçlarıyla öğrenci verilerinin sınıflandırılması. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 28(4), 101-112.
- Altan, G. ve Kutlu, Y. (2018). Superiorities of Deep Extreme Learning Machines against Convolutional Neural Networks. *Natural End Engineering Sciences*.
- Amrolkar, K. & Tugave, A.S. (2015). Gender Classification from Iris Using Machine Learning Techniques. *University of Florida Biometric and Pattern Recognition*.
- Anupama, B. L. (2017). A Novel Classifier for Gender Classification from Iris Code Used for Recognition. *Central Library*.
- Baker, J. E. (1985). Adaptive selection methods for genetic algorithms. In *Proceedings of an International Conference on Genetic Algorithms and their applications* (101-111).
- Bansal, A., Agarwal, R., & Sharma, R. K. (2012). SVM based gender classification using iris images. In *2012 Fourth International Conference on Computational Intelligence and Communication Networks* (425-429). IEEE.
- Bansal, A., Agarwal, R., & Sharma, R. K. (2014). Predicting gender using iris images. *Research Journal of Recent Sciences*, 3(4), 20-26.
- Bramer, M. (2007). Principles of data mining 180. *London: Springer*.
- Budak, H. (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(Özel), 21.
- Ceyhan, E. B., Sağiroğlu, Ş., & Akyıl, E. (2014). Parmak İzi Öznitelik Vektörleri Kullanılarak YSA Tabanlı Cinsiyet Sınıflandırma. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29(1).
- Ceyhan, E. B., Sağiroğlu, Ş., ve Akyıl, M. E. (2013). Statistical gender analysis based on fingerprint ridge density. In *2013 21st Signal Processing and Communications Applications Conference (SIU)* (1-4). IEEE.

- Chang, C. Y., ve Wu, T. H. (2010). Using gait information for gender recognition. In *2010 10th International Conference on Intelligent Systems Design and Applications* (1388-1393) IEEE.
- Çakır, A., Altıntaş, V., ve Akbulut, F. T. (2013). İris Tanıma Sistemleri ve Uygulama Alanları. *Akademik Bilişim Konferansları*, 13.
- Da Costa-Abreu, M., Fairhurst, M., & Erbilek, M. (2015). Exploring gender prediction from iris biometrics. In *2015 International Conference of the Biometrics Special Interest Group (BIOSIG)* (1-11). IEEE.
- Dal, F., Coşgun, S., ve Özbek, İ. Y. (2015). Gender detection with heart sound. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (2362-2365). IEEE.
- Daouk, C. H., El-Esber, L. A., Kammoun, F. D., & Al Alaoui, M. A. (2002, May). Iris recognition. In *IEEE ISSPIT* (pp. 558-562).
- Daugman, J. (1992). High confidence personal identification by rapid video analysis of iris texture. In *Proceedings 1992 International Carnahan Conference on Security Technology: Crime Countermeasures* (50-60). IEEE.
- Daugman, J. G. (1993). High confidence visual recognition of persons by a test of statistical independence. *IEEE transactions on pattern analysis and machine intelligence*, 15(11), 1148-1161.
- Daugman, J. (2009). How iris recognition works. In *The essential guide to image processing* (715-739). Academic Press.
- Ergin, T. (2018). Convolutional Neural Network (ConvNet yada CNN) nedir? Erişim: <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>
- Fogel, I., ve Sagi, D. (1989). Gabor filters as texture discriminator. *Biological cybernetics*, 61(2), 103-113.
- Gör, İ. (2016). Çok Katmanlı Algılayıcı Yapay Sinir Ağı ile Lineer Diferansiyel Denklem Sisteminin Çözümü. *XVIII. Akademik Bilişim Konferansı - AB*.
- Guo, J. M., Lin, C. C., ve Nguyen, H. S. (2010). Face gender recognition using improved appearance-based average face difference and support vector machine. In *2010 International Conference on System Science and Engineering* 637-640.
- Gümüştü, A., Aydılek, B.İ. ve Taştaltın, R. (2016). 3 Farklı Filtre Modelli Öznitelik Seçme Algoritmalarının Kombine Edilerek İyileştirilmesi; *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*
- Hall, M. A. (1999). Correlation-based feature selection for machine learning. *Diss. The University of Waikato* (doi.org/10.1.1.149.3848).

- İnternet: Keros-Team, Keras: The Python Deep Learning library, <https://keras.io>, Son Erişim Tarihi: 26.06.2019.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436.
- Jain, A. K., Duin, R. P. W., & Mao, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1), 4-37.
- Jain, A., Huang, J., ve Fang, S. (2005). Gender identification using frontal facial images. In *2005 IEEE International Conference on Multimedia and Expo 2005*, 1082-1085.
- Kilinç, M., ve Uludağ, U. (2012). Gender identification from face images. In *2012 20th Signal Processing and Communications Applications Conference (SIU)* 1-4.
- Kotti, M., ve Kotropoulos, C. (2008). Gender classification in two emotional speech databases. In *2008 19th International Conference on Pattern Recognition* 1-4.
- Kuehlkamp, A., Becker, B., ve Bowyer, K. (2017). Gender-from-iris or gender-from-mascara?. In *2017 IEEE Winter Conference on Applications of Computer Vision (WACV)* 1151-1159.
- Kutlu, Y. (2010). Multi-stage classification of abnormal patterns in EEG and e-ECG using model-free methods (*Doctoral dissertation, DEÜ Fen Bilimleri Enstitüsü*).
- Kutlu, Y., Kuntalp, M., & Kuntalp, D. (2009). Optimizing the performance of an MLP classifier for the automatic detection of epileptic spikes. *Expert Systems with Applications*, 36(4), 7567-7575.
- Larose, D. T., & Larose, D. T. (2006). Data mining methods and models, 12. *Hoboken (NJ): Wiley-Interscience*.
- Nussbaumer, H. J. (2012). Fast Fourier transform and convolution algorithms, 2. *Springer Science & Business Media*.
- Nussbaumer, J., H., (1982) Fast Fourier Transform and Convolution Algorithms; Springer.
- Orhan, U., & Adem, K. (2012). Naive bayes yönteminde olasılık çarpanlarının etkileri. *ElektrikElektronik ve Bilgisayar Mühendisliği Sempozyumu*, 723.
- Percival, D. W., & Walden, A. (2002). A (2000). Wavelet Methods for Time Series Analysis. *Cambridge University*.
- Percy, O., & Waqas, A. (2010). Iris localization using Daugman's algorithm. *BSc. Disserrtation, Blekinge Institute of Technology, School of Engineerng, Sweden*.
- Polat, H. A. G. Sınıflandırma problemlerinde sınıflandırıcı performanslarının karşılaştırılması: Eleştiri ve Öneriler On the comparison of classifiers' performance in classification problems: Critiques and Suggestions.
- Shapiro, L. ve Stockman, G. (2000), Computer Vision, *Springer*.

- Stawska, Z., & Milczarski, P. (2017). Support vector machine in gender recognition. *Information Systems in Management*, 6.
- Stearns, S. (1976). On selecting features for pattern recognition. In *International Conference*.
- Tapia, J. E., Perez, C. A., & Bowyer, K. W. (2014). Gender classification from iris images using fusion of uniform local binary patterns. In *European Conference on Computer Vision*, 751-763. Springer, Cham.
- Tapia, J. E., Perez, C. A., & Bowyer, K. W. (2016). Gender classification from the same iris code used for recognition. *IEEE Transactions on Information Forensics and Security*, 11(8), 1760-1770.
- Tapia, J., & Aravena, C. (2017). Gender classification from NIR iris images using deep learning. In *Deep Learning for Biometrics*, 219-239.
- Tapia, J., & Arellano, C. (2019). Gender Classification from Iris Texture Images Using a New Set of Binary Statistical Image Features. *arXiv preprint arXiv:1905.00372*.
- Taşcı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*.
- Thomas, V., Chawla, N. V., Bowyer, K. W., & Flynn, P. J. (2007, September). Learning to predict gender from iris images. In *2007 First IEEE International Conference on Biometrics: Theory, Applications, and Systems*, 1-5.
- Tisse, C. L., Martin, L., Torres, L., & Robert, M. (2002). Person identification technique using human iris recognition. In *Proc. Vision Interface*, 294, (299), 294-299.
- Tunalı, İ., & Şenyer, N. (2012). Gender recognition from gait using RIT and CIT approaches. In *2012 20th Signal Processing and Communications Applications Conference (SIU)*, 1-4.
- Ülker, E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Whitney, A. W. (1971). A direct method of nonparametric measurement selection. *IEEE Transactions on Computers*, 100(9), 1100-1103.
- Yu, S., Tan, T., Huang, K., Jia, K., & Wu, X. (2009). A study on gait-based gender classification. *IEEE Transactions on image processing*, 18(8), 1905-1910.
- Zhang, H. (2004). The optimality of naive Bayes. *AA*, 1(2), 3.



## ÖZGEÇMİŞ

### Kişisel Bilgiler

Soyadı, adı : AÇIL, Tuğba  
 Uyuğu : T.C.  
 Doğum tarihi ve yeri : 17.03.1992, Hatay  
 Medeni hali : Bekar  
 Telefon : 0 (534) 344 51 81  
 e-mail : tugbaacil.mfbel6@iste.edu.tr

### Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / Elektrik-Elektronik Mühendisliği	Devam ediyor
Lisans	Çukurova Üniversitesi / Bilgisayar Mühendisliği	2016
Lise	Fevzi Çakmak Anadolu Lisesi	2010

### Yabancı Dil

İngilizce

### Yayımlar

- Açıl, T., ve Kutlu, Y. (2018), Gender Estimation from Iris Images Using Tissue Analysis Techniques, International Conference on Artificial Intelligence towards Industry 4.0.
- Açıl, T., Kutlu, Y. ve Altan, G. (2018), İris görüntülerinden derin öğrenme ile cinsiyet Sınıflandırma , 1. International Mersin Symposium, Cilt 2, 25-30.

### Hobiler

Kitap okumak, Spor yapmak, Film izlemek



## DİZİN

---

### B

başarım · 2, 4, 5, 30, 37, 38, 39, 42, 45, 46, 47, 48, 49, 52  
başarım ölçümleri · 2, 22  
bireysel en iyi seçim algoritması · 23  
biyometrik · iv, 1, 2, 4

---

### C

Cinsiyet · iv, 1, 4, 8, 54  
Cinsiyet tespiti · 1

---

### Ç

çok katmanlı ağlar · 5

---

### D

dalgacık dönüşümü · 4  
Daughman dönüşüm · 4  
Daugman algoritması · 8  
destek vektör makinesi · 4  
doğrusal olmayan dönüşüm · 10, 38  
doku · 4, 5, 7  
doku analizi · 7, 28  
Doku analizi · 12  
dönüşüm teknikleri · 4, 7

---

### E

Evrişimsel sinir ağı · 6

---

### F

filtreleme · 7, 23, 24

fourier dönüşümü · 7, 31  
Fourier dönüşümü · 12, 31

---

### G

gabor filtresi · 5, 30  
geometrik öznitelik · 13  
gizli katman · 19, 35  
görüntü işleme · 1, 27

---

### H

Havuzlama katmanı · 21

---

### i

ileri yönlü seçim · 22  
iris · 1, 2, 5, 7, 8, 9, 10, 13, 26, 27, 28, 29, 30, 31, 38, 47, 48, 49, 51  
istatistiksel öznitelikler · 4

---

### K

k en yakın komşu · 5  
karar ağaçları · 5  
konvolüsyon · 19, 20

---

### M

makine öğrenmesi · 21  
morfolojik · 4, 7

---

### N

naive bayes · 14, 39, 41, 45, 51  
Naive Bayes · 15

n-al r-brak seçim yöntemi · 25

ND\_GFI · 2

normalizasyon · 4, 6, 10, 31, 39, 42, 46, 47, 48, 49, 50,  
51

---

## Ö

özellik haritası · 20

öznitelik · 2, 4, 5, 7, 10, 17, 23, 26, 28, 31, 33, 35, 38,  
47, 52, 53

---

## P

polar dönüşümü · 4

---

## R

relu · 20

---

## S

Sarmal metot · 23

seçim algoritmaları · 2, 31

segmentasyon · 4

seyreltme · 21

sınıflandırma · 2, 3, 12, 14, 19, 26, 35, 38

---

## U

uzman sistem · 5

---

## Y

yapay zeka · 1



**TEKNOVERSİTE**



teknoversite **AYRICALIĞINDASINIZ**

**İSTE**

