



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

POLİKİSTİK OVER SENDROMUNUN
FOLİKÜL SAYIMINA DAYALI TESPİTİNDE
GÖRÜNTÜ İŞLEME VE EVRİŞİMSEL SINIR
AĞLARIKULLANIMI

Perihan Gülşah GÜLHAN

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Aralık-2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Perihan Gülşah GÜLHAN tarafından hazırlanan “Polikistik Over Sendromunun Folikül Sayımına Dayalı Tespitinde Görüntü İşleme ve Evrişimsel Sinir Ağları Kullanımı” adlı tez çalışması 02/12/2021 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç. Dr. Hasan Erdiñ KOÇER

Danışman

Dr. Öğr. Üyesi Güzin ÖZMEN

Üye

Dr. Öğr. Üyesi Burak YILMAZ

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr.Sait GEZGİN
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Perihan Gülşah GÜLHAN

Tarih: 02/12/2021

ÖZET

YÜKSEK LİSANS TEZİ

POLİKİSTİK OVER SENDROMUNUN FOLİKÜL SAYIMINA DAYALI TESPİTİNDE GÖRÜNTÜ İŞLEME VE EVRİŞİMSEL SİNİR AĞLARI KULLANIMI

Perihan Gülşah GÜLHAN

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Güzin ÖZMEN

2021, 107 Sayfa

Jüri

Doç. Dr. Hasan Erdinç KOÇER
Dr. Öğr. Üyesi Güzin ÖZMEN
Dr. Öğr. Üyesi Burak YILMAZ

Polikistik over sendromu, birçok kadında görülen hormonal bir hastalıktır. Yumurtalıklarda çok sayıda küçük ve iyi huylu kistin bir araya gelmesi ile oluşur. Folikül adı verilen bu kistler, ultrason görüntüleme ile gözlenen yumurtalıklarda özel bir görüntü oluşturur. Yumurtalık hastalıklarında bu foliküllerin sayısı, yapısı ve büyüklüğü tanı için önemli bilgiler sağlamaktadır. Bu bilgilere dayanarak görüntü işleme ve yapay zeka sayesinde çeşitli hastalıkların teşhisi sağlanabilmektedir.

Bu çalışmada 54 adet yumurtalık ultrason görüntüsü kullanılmıştır. Döndürme, yatay ve dikey yansıtma, histogram eşikleme kullanılarak yapılan veri artırımı ile 200 adet normal ve 70 adet polikistik over sendromlu (PKOS) yumurtalık görüntüsü kaydedilmiştir. Tez çalışmasında PKOS için iki farklı folikül saptama yöntemi test edilmiştir. Birinci yöntem gürültü filtreleme, kontrast ayarı, binarizasyon ve morfolojik süreçlerden oluşur. Bu yöntem için gürültü azaltmada ortanca filtre, ortalama filtre, Gaussian filtresi ve Wiener filtresi kullanılmış ve daha sonra standart eşikleme ve uyarlanabilir eşikleme test edilmiştir. İkinci yöntemde gürültüyü azaltmak için Gaussian filtre ve Ayırık Dalgacık Dönüşümü seçilmiştir. Bu yöntemde folikülleri tespit etmek için k-ortalama kümeleme algoritması ve morfolojik işlemler görüntüye uygulanmıştır. Kullanılan filtrelerin performans değerlendirilmesi Ortalama Kare Hatası ve Pik Sinyal Gürültü Oranı ölçütleri kullanılarak yapılmıştır. Her iki yöntem için de gerçekleştirilen segmentasyon aşamasında Canny kenar algılama algoritması ile foliküller tespit edilmiştir. Sonuçların doğruluğunu değerlendirmek için yanlış kabul oranı (FAR) ve yanlış reddetme oranı (FRR) kullanılmıştır. En yüksek folikül tanıma başarı oranı %97,63 ile Wiener filtresi ile uyarlanabilir eşiklemenin kullanıldığı yöntem ile sağlanmıştır. Bu yöntem için FAR %33,45 ve FRR %1,61 olarak elde edilmiştir. Bu çalışma sonucunda birinci yöntemde Wiener Filtre ile uyarlanabilir eşiklemenin bir arada uygulandığı yöntem kullanılarak yüksek başarı oranı ile folikül tespiti gerçekleştirilmiştir. Folikül tespitinin ardından segmente edilmiş görüntüler ile yeni bir veri seti oluşturulmuştur. Evrişimsel Sinir Ağı (ESA) mimarisi kullanılarak “normal” ve “polikistik over sendromu” olmak üzere yumurtalık folikülleri sınıflandırılmıştır. Segmente edilmemiş görüntüler kullanılarak %65,81 veselemente edilmiş görüntüler kullanılarak % 77,81 doğruluk oranı elde edilmiştir. Hassasiyet, Duyarlılık, Kesinlik ve F1 ölçütleri kullanılarak sınıflandırma performansı değerlendirilmiştir.

Anahtar Kelimeler: Evrişimli Sinir Ağları, Folikül Tespiti, Görüntü İşleme, Polikistik Over Sendromu, Ultrasonograf

ABSTRACT

MS THESIS

USAGE OF IMAGE PROCESSING AND CONVOLUTIONAL NEURAL NETWORKS IN DETECTION OF POLYCYSTIC OVARY SYNDROME BASED ON FOLLICLE COUNT

Perihan Gülşah GÜLHAN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL ELECTRONICS ENGINEERING**

Advisor: Asst. Prof. Dr. Güzin ÖZMEN

2021,107 Pages

Jury

Assoc. Prof. Dr. Hasan Erdiñ KOÇER

Asst. Prof. Dr. Güzin ÖZMEN

Asst. Prof. Dr. Burak YILMAZ

Polycystic ovary syndrome is a hormonal disorder that occurs in many women. It is formed by the coming together of many small and benign cysts in the ovaries. These cysts, called follicles, form a special image in the ovaries observed with ultrasound imaging. The number, structure, and size of these follicles in ovarian diseases provide important information for diagnosis. Based on this information, various diseases can be diagnosed with image processing and artificial intelligence.

In this study, 54 ovarian ultrasound images were used. With data augmentation using rotation, horizontal and vertical projection, histogram thresholding, 200 normal and 70 polycystic ovarian syndrome (PCOS) ovary images were recorded. In the thesis study, two different follicle detection methods were tested for PCOS. The first method consists of noise filtering, contrast adjustment, binarization and morphological processes. For this method, median filter, average filter, Gaussian filter, and Wiener filter are used for noise reduction, and then standart thresholding and adaptive thresholding are tested. In the second method, Gaussian filter and Discrete Wavelet Transform are chosen to reduce noise. In this method, k-means clustering algorithm and morphological operations were applied to the image to detect follicles. The performance evaluation of the filters used was made using Mean Square Error and Peak Signal to Noise Ratio metrics. In the segmentation stage performed for both methods, follicles were detected with the Canny edge detection algorithm. False Acceptance Rate (FAR) and False Rejection Rate (FRR) were used to evaluate the accuracy of the results. The highest follicle recognition success rate was 97,63%, using adaptive thresholding with Wiener filter. For this method, FAR was obtained as 33,45% and FRR as 1,61%. As a result of this study, follicle detection was performed with a high success rate by using the method in which the Wiener Filter and adaptive thresholding were applied together in the first method. After the follicle detection, a new data set was created with segmented images. Ovarian follicles were classified as “normal” and “polycystic ovary syndrome” using Convolutional Neural Network (CNN) architecture and 65,81% accuracy was obtained using unsegmented images and 77,81% using segmented images. Classification performance was evaluated using the criteria of Sensitivity, Sensitivity, Precision and F1.

Keywords: Convolutional Neural Networks, Follicle Detection, Image Processing, Polycystic Ovary Syndrome, Ultrasonography.

ÖNSÖZ

Çalışmamın her aşamasında desteğini esirgemeyen, çalışmalarımın yönlendirilmesi ve sonuçlandırılmasında büyük emeği geçen, önerileri ile yol gösteren danışmanım sayın Dr.Öğr. Üyesi Güzin ÖZMEN’e teşekkür ederim.

Beni bilgileri ile donanımlandıran, yaşadığım sorunlara en kısa çözümler bulan, ellerindeki tüm imkânları sunan ve kullandıran diğer tüm üniversite hocalarıma bana kazandırdıkları her şey için minnettarım.

Verilerin değerlendirilmesi konusunda değerli görüşleri ile yardımcı olan Özel Medicana Konya Hastanesi’nde görev yapan Kadın Hastalıkları ve Doğum uzmanı Doç. Dr. Hüsnü ALPTEKİN’e tez çalışmasına katkılarından dolayı teşekkürlerimi sunarım.

Bu zorlu süreçte beni hiçbir zaman yalnız bırakmayan, maddi ve manevi desteklerini her zaman gösteren aileme, en büyük destekçim değerli eşim Recep GÜLHAN’a ve motivasyon kaynağım olan canım oğlum Mehmet Kayra’ya teşekkürlerimi sunarım.

2210-A Genel Yurt İçi Yüksek Lisans Burs Programı kapsamında çalışmalarım sırasında beni destekleyen TÜBİTAK’a teşekkür ederim.

Perihan Gülşah GÜLHAN
KONYA-2021

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	iv
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
1.1. Kaynak Araştırması.....	5
2. POLİKİSTİK OVER SENDROMU.....	9
2.1. Polikistik Over Sendromunun Belirtileri	11
2.2. Polikistik Over Sendromunun Teşhisi	12
2.3. Polikistik Over Sendromunun Tedavisi	13
3. DİJİTAL GÖRÜNTÜ	14
3.1. Görüntü Türleri	14
3.1.1. Ultrason görüntüleri	16
3.2. Görüntü İşleme Aşamaları	17
3.2.1. Görüntü elde etme.....	18
3.2.2. Ön işleme	19
3.2.3. Segmentasyon	23
3.2.4. Sınıflandırma	23
4. DERİN ÖĞRENME	25
4.1. Evrişimsel Sinir Ağları	26
4.1.1. Katmanlar.....	26
4.1.2. Evrişimsel Sinir Ağının mimarileri.....	29
5. MATERYAL VE YÖNTEM.....	34
5.1 Görüntü İşleme ile Folikül Tespiti.....	34
5.1.1. Görüntü elde etme.....	35
5.1.2. Ön işleme	36
5.1.3. Segmentasyon	43
5.2. Derin Öğrenme ile Sınıflandırma	44
5.3. Performans Değerlendirme Ölçütleri.....	47
5.3.1. Filtreleme sonuçlarını değerlendirmede kullanılan ölçütler	47
5.3.2. Folikül tanıma sonuçlarını değerlendirmede kullanılan ölçütler	48
5.3.3. Sınıflandırma sonuçlarını değerlendirmede kullanılan ölçütler.....	48

6. ARAřTIRMA SONUÇLARI VE TARTIřMA.....	50
7. SONUÇLAR VE ÖNERİLER	57
7.1 Sonuçlar	57
7.2. Öneriler	60
KAYNAKLAR	62
EKLER	69
ÖZGEÇMİř	97



SİMGELER VE KISALTMALAR

Simgeler

2B	: 2 Boyutlu
a	: Görüntünün kırmızı-yeşil katmandaki yeri
b	: Görüntünün mavi-sarı katmandaki yeri
B	: Mavi renk bandı
F	: Filtre boyutu
$f(x,y)$	: 2 boyutlu görüntü
G	: Yeşil renk bandı
GB	: Gigabayt
K	: Küme sayısı
L	: Görüntünün parlaklık seviyesi
M	: Görüntünün satır sayısı
Mm	: Milimetre
N	: Görüntünün sütun sayısı
P	: Dolgu miktarı
R	: Kırmızı renk bandı
S	: Adım sayısı
W	: Giriş görüntüsünün boyutu

Kısaltmalar

ADD	: Ayrık Dalgacık Dönüşümü
AES	: Androjen Fazlalığı Toplumu (Androgen Excess Society)
AI	: Yapay Zekâ (Artificial Intelligence)
ASRM	: Amerikan Üreme Tıbbı Derneği (American Society for Reproductive Medicine)
AUC	: Eğrinin Altında Kalan Alan (Area Under The Curve)
BW	: Siyah-Beyaz (Black and White)
DL	: Derin Öğrenme (Deep Learning)
DN	: Doğru Negatif (True Negative)
DP	: Doğru Pozitif (True Positive)
DVM	: Destek Vektör Makinası (Support Vector Machine)
ESA	: Evrişimli Sinir Ağları (Convolutional Neural Network)
ESHRE	: Avrupa İnsan Üreme ve Embriyoloji Derneği (European Society of Human Reproductive and Embryology)
FAR	: Yanlış Kabul Oranı (False Accept Rate)
Faster R-CNN	: Faster Region Based Convolutional Networks
FRR	: Yanlış Reddetme Oranı (False Rejection Rate)
FSH	: Folikül Uyarıcı Hormon (Follicle Stimulating Hormone)
GUI	: Grafiksel Kullanıcı Arayüzü (Graphical User Interface)
K-NN	: K En Yakın Komşu (K-Nearest Neighbors)
LDC	: Lineer Diskriminant Sınıflandırıcı (Linear Discriminant Analysis)
LH	: Luteinleştirici Hormon (Luteinizing Hormone)
LVQ	: Öğrenmeli Vektör Kuantalama (Learning Vector Quantization)
MATLAB	: Matrix Laboratory

ML	: Makine Öğrenmesi (Machine Learning)
MSE	: Ortalama Hata Karesi (Mean Squared Error)
NIH	: Ulusal Sağlık Enstitüleri (National Institutes of Health)
OF	: Yumurtalık Folikülü (Ovarian Follicle)
PKOS	: Polikistik Over Sendromu
PMF	: Primordial Folikül (Primordial Follicle)
PSNR	: Pik Sinyal Gürültü Oranı
RBF	: Radyal Tabanlı Fonksiyon (Radial Basis Function)
RGB	: Kırmızı-Yeşil-Mavi 3 boyutlu renk uzayı (Red Green Blue)
ROC	: Alıcı İşletim Karakteristiği (Receiver Operating Characteristic)
SGDM	: Momentum ile Stokastik Gradyan İnişi (Stochastic Gradient Descent With Momentum)
TIFF	: Etiketli Görüntü Dosyası Formatı (Tagged Image File Format)
USB	: Evrensel Seri Veriyolu
USG	: Ultrasonografi
YN	: Yanlış Negatif (False Negative)
YP	: Yanlış Pozitif (False Positive)
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Yumurtalıklar yapısal özelliklerine göre normal yumurtalık, kistik yumurtalık ve polikistik yumurtalık olmak üzere üçe ayrılır (Hiremath ve Tegnoor, 2013; Adiwijaya ve ark., 2021). Normal yumurtalıklarda her ay düzenli olarak yumurta içeren kistler meydana gelir (Gougeon, 2004). Bu kistlere folikül adı verilir ve normal adet döngüsü ile her ay vücuttan atılır. Bu kistler normal döngü içerisinde vücuttan atılmazlarsa büyüyerek fonksiyonel kistlere dönüşebilirler. Fonksiyonel kistler içi su dolu keselerdir ve belli bir süre içinde kendiliğinden kaybolurlar. Kadınların yumurtlama döneminde her ay gelişerek çatlaması gereken folikül gelişemez ve yumurtalık dokusunda kalırsa zaman içinde biriken bu kistler polikistik yumurtalık yapısına sebep olur. Polikistik yumurtalıklarda birçok folikül bulunmasına rağmen foliküller olgunlaşamaz ve dolayısıyla yumurtlama gerçekleşmez. Bu durum polikistik yumurtalık ve normal yumurtalık arasındaki en temel farktır(Pache ve ark., 1992).

PKOS üreme çağındaki kadınlarda çeşitli semptomlarla kendini belli eden hormonal bir bozukluk sonucu ortaya çıkar.Üreme döneminde kadınların yaklaşık %4-12'sinde bu sendrom görülür (Knochenhauer ve ark., 1998; Hahn ve ark., 2005).

Rotterdam kriterlerine göre polikistik over sendromu tanısının koyulabilmesi için 3 temel kriter vardır(ESHRE ve Group, 2004; Broekmans ve ark., 2006).İlki kronik anovülasyon yani adet düzensizliği, ikincisi kadınlarda erkeklik hormonlarının aşırı fazla olması, üçüncüsü ise ultrason görüntüleri ile tespit edilen polikistik yumurtalık yapısıdır. Bu belirtilerden en az ikisine sahip olan kadınlarda polikistik over sendromu olduğu düşünülür(ESHRE ve Group, 2004). Ancak hastalık tanısının kesin olarak koyulabilmesi için ultrason görüntüleri ve kan testi sonuçları incelenerek karar verilir.

PKOS' da doğru ve erken teşhis oldukça önemlidir. Çünkü PKOS insülin direnci, diyabet, obezite, rahim kanseri, kalp hastalıkları gibi birçok hastalığı beraberinde getirmektedir. İnsulin direnci ve kadınlarda yumurtalamayı sağlayan luteinleştirici hormon (LH) seviyesinin yüksek olması başlıca polikistik over belirtisidir (Legro ve ark., 1999; Pfeifer, 2005; Lane, 2006). PKOS olan kadınların uzun süreli tip-2 diyabet ve kardiyovasküler riski taşıdıkları kanıtlanmıştır (Dunaif ve ark., 1987; Legro ve ark., 1999). Aynı zamanda polikistik over sendromu olan kadınlarda kısırılık görülme ihtimali çok yüksektir. Bu kadınların gebelik oluşumu için tedavi olmaları gerekir. Tüm bunlar göz önüne alındığında PKOS'un tetiklediği hastalıkları engellemek için erken tanı konulmalı ve biran önce tedaviye başlanmalıdır. PKOS genetik ve çevresel

faktörler sonucunda oluşmaktadır. Yapılan birkaç çalışmada PKOS'un genetik bir hastalık olduğu tespit edilmiştir (Lunde ve ark., 1989; Legro ve ark., 1998; Govind ve ark., 1999). Foliküllerin ortadan kalkması zor olsa da doğru teşhis ve tedavi ile semptomları en aza indirilebilir. PKOS'un doğru ve hızlı bir şekilde tanımlanmaması tedaviyi ciddi şekilde geciktirir.

Ultrasonografi (USG), vücudun iç kısımlarının ses dalgaları ile görülmesini sağlayan tıbbi bir görüntüleme yöntemidir. İnsan kulağının duyamayacağı 2-15 MHz kadar yüksek frekanslı ses dalgaları ile çalışır (Jensen, 2007). Ultrason cihazlarında siyah/beyaz ve gri renkli iki boyutlu görüntüler üretilir. Safra kesesi hastalıkları, meme tümörleri, tiroit bezi hastalıkları, prostat, genital bölge hastalıkları gibi pek çok hastalığın ön teşhisinde ultrason görüntüleri kullanılır. PKOS tanısında da ultrason görüntüleri oldukça önemlidir.

Normal ve polikistik yumurtalık ultrason görüntüleri birbirinden oldukça farklıdır. Normal yumurtalıklarda en fazla 8-10 folikül bulunur ve bu foliküllerin çapı 2-28 mm olmaktadır (Gougeon ve Lefèvre, 1983). Polikistik yumurtalığa sahip hastaların yumurtalıklarında 12 veya daha fazla kist bulunmaktadır. Bu kistlerin çapı 9mm'den küçüktür (Battaglia ve ark., 1997). Bir yumurtalığın polikistik yumurtalık olarak adlandırılması için ultrason görüntüsünde 2-9 mm çapında 12'den fazla kiste sahip olması yeterlidir (Balen ve ark., 2003). Foliküllerin sayısı ve büyüklüğü uzman kişinin ultrason muayenesi ile belirlenir. Folikülün uzmanlar tarafından manuel olarak belirlenmesi hem zahmetli hem de zaman alıcıdır. Bu nedenle uzman kişiye zaman kazandırmak ve iş yükünü azaltmak için foliküllerin sayısı, yapısı, boyutu gibi özellikleri otomatik olarak belirlenebilmektedir.

Görüntü işleme, dijital görüntülerin bilgisayar ortamında iyileştirme, saklama, tanıma gibi amaçlarla çeşitli işlemlerden geçirilerek değiştirilmesidir. PKOS ile ilgili literatür incelendiğinde farklı görüntü işleme yöntemleriyle folikül tespiti yapıldığı görülmüştür (Lawrence ve ark., 2007; Hiremath ve Tegnoor, 2010; Purnama ve ark., 2015; Wisesty, 2016). Örneğin Hiremath ve Tegnoor, ön işleme aşamasında Gauss düşük geçiş filtresi ve Konturlet Dönüşümü'nü kullanmıştır. Gauss düşük geçiş filtresi ile yapılan tespitten %62,3 ve Konturlet Dönüşümü ile yapılan tespitten %75,2 başarı elde etmiştir. Lawrence ve ark. foliküllerin otomatik tespiti için bölgesel genişletme algoritması kullanmış ve %78 folikül tanıma oranı elde etmiştir.

Bu tez çalışmasında yumurtalık foliküllerinin tespiti için görüntü işleme teknikleri, tespit edilen foliküllerin "normal" ve "PKOS" ayrımı için ise derin

öğrenme tabanlı bir sınıflama algoritması kullanılmıştır. Bu amaçla halka açık veri setinden 54 adet yumurtalık ultrason görüntüsü alınmıştır. Elde edilen yumurtalık ultrason görüntülerine çeşitli görüntü işleme teknikleri uygulanmış bu sayede düşük kontrastlı ve gürültülü ultrason görüntüleri ön işleme aşamasında iki farklı yöntem kullanılarak geliştirilmiştir.

İlk yöntem için ön işleme aşamasında ortanca filtre, ortalama filtre, Gaussian filtresi ve Wiener filtresi olmak üzere 4 farklı filtreleme yöntemi kullanılmıştır. Görüntüye sırasıyla aşındırma, açma ve genişletme morfolojik işlemleri uygulanmıştır. Ardından histogram eşitleme ve standart eşikleme ile uyarlanabilir eşikleme sonuçları karşılaştırılmıştır.

İkinci yöntemde için ise ön işleme aşamasında Gaussian filtresi ve Ayrık DalgacıkDönüşümü test edilmiştir. Görüntüye k-ortalama kümeleme algoritması ile 6 farklı kümeleme yapılmıştır. Kümelerden biri seçilerek görüntüye önce boşluk doldurma sonra da sırasıyla aşındırma ve genişletme morfolojik işlemleri uygulanmıştır.

İki yöntemde de ön işleme aşamasından sonra Canny kenar bulma algoritması ile görüntüler segmente edilerek foliküllerin tespiti sağlanmıştır. Tüm yöntemlerin doğruluğuyanlış kabul oranı (FAR) ve yanlış reddetme oranı (FRR) kullanılarak karşılaştırılmıştır. Bu karşılaştırma sonucunda en iyi tespiti yapan yöntem belirlenmiştir. Folikül tespiti için önerilen yöntem sonucunda segmente edilmiş görüntüler kaydedilerek yeni bir veri seti oluşturulmuştur.

Tez çalışmasının bir diğer uygulaması da Evrişimsel Sinir Ağı (ESA) derin öğrenme mimarisi kullanılarak yumurtalıkları normal ve PKOS olarak sınıflandırmaktır. Derin öğrenme uygulamalarının iyi sonuçlar verebilmesi için veri sayısı oldukça önemlidir. Bu nedenle tez çalışmasında “normal” ve “PKOS” sınıflandırması yapmak için kısıtlı sayıda yumurtalık görüntüsüne döndürme, yatay yansıtma, dikey yansıtma ve histogram eşitleme yöntemleri uygulanarak görüntü sayısı çoğaltılmıştır. Böylece veri sayısı 5 katına çıkartılarak 200 adet normal ve 70 adet PKOS olmak üzere toplamda 270 adet görüntü elde edilmiştir. Aynı şekilde segmente edilmiş görüntülerde döndürme, yatay ve dikey yansıtma, histogram eşitleme yöntemleriyle çoğaltılmıştır. Böylece ağıın daha iyi eğitilmesi sağlanmıştır.

Derin öğrenme birden çok katmandan oluşan yapay zeka algoritmalarıdır ve makina öğrenmesinin bir alt koludur. Makine öğrenmesi e-ticaret web siteleri, kameralar, akıllı telefonlar gibi pek çok alanda yer almaktadır. Derin öğrenme, konuşma tanıma, görsel nesne tanıma, ses tanıma gibi alanlarda kullanılmaktadır(LeCun ve ark.,

2015). Aynı zamanda derin öğrenme çeşitli hastalıkların sınıflandırmasında, ön tanısında veya teşhisinde de yaygın olarak kullanılmaktadır (Liu ve ark., 2014; De Fauw ve ark., 2018; Oh ve ark., 2018). Makine öğrenmesi tek katmanda çalışırken derin öğrenme birçok katmanda çalışmaktadır. Derin öğrenme, makine öğrenmesi algoritmalarını aynı anda kullanarak sonuca ulaşır.

Bu çalışmada sınıflandırma için derin öğrenmenin bir alt kolu olan Evrişimli Sinir Ağları (ESA) kullanılmıştır. Bu uygulamada ilk önce sinir ağının görselin hangi sınıfa ait olduğunu öğrenebilmesi için defalarca benzer görsellerin ağa öğretilmesi gerekmektedir. Ağ böylece benzer görselleri “normal” ve “PKOS” şeklinde tanımlamaktadır. Bu aşamada daha fazla veri miktarı sınıflama doğruluğunu arttırmaktadır. ESA kullanılarak segmente edilmiş görüntülerden oluşturulan yeni veri seti ve ham görüntülerden oluşan veri seti ile sınıflandırma yapılmıştır. Görüntüler “normal” ve “PKOS” şeklinde sınıflandırılmıştır. Veri artırımı, görüntü işleme teknikleri ve derin öğrenme kullanılarak polikistik over sendromunun teşhisi için uygulamalar gerçekleştirilmiştir.

Bu alanla ilgili literatür incelendiğinde folikül tespiti için farklı algoritmaların denendiği görülmüş ve sonuçları bu tez çalışmasında önerilen yöntemler ile karşılaştırılmıştır. ESA kullanılarak yapılan pek çok sınıflandırma çalışmaları da bulunmaktadır. Bu tez çalışmasında diğerlerinden farklı olarak hem ham görüntüler hem de segmente edilmiş görüntülerin sınıflandırması yapılmıştır. Bu çalışmanın amacı ultrason görüntülerinden yumurtalık foliküllerini tespit edilip başarılı bir sınıflandırma sağlamaktır. Hastalık tanısının otomatik bir şekilde koyulması uzman kişi için zamandan tasarruf sağlamaktadır ve iş yükü azalmaktadır. PKOS’un erken teşhisi ile beraberinde getireceği obezite, hipertansiyon, diyabet gibi pek çok hastalık önlenmektedir.

1.1. Kaynak Araştırması

Tıp literatürü incelendiğinde polikistik over sendromu tanısı için gerekli kriterler ve bu hastalığın teşhisinin neden önemli olduğu ile ilgili pek çok çalışma bulunmaktadır.

1990 yılında Ulusal Sağlık Enstitüleri'nin (NIH) yaptığı konferansta PKOS sendromunun teşhisi için iki kriterden bahsedilmiştir. Bunlar hiperandrojenizm ve kronik anovülasyondur. Hiperandjonizm, kadınlarda erkeksi özelliklerin görülmesidir. Erkek tipi saç dökülmesi, aşırı tüylenme ve ses kalınlaşması bu belirtilerdendir. Kronik anovülasyon ise hiçbir adet döngüsünde yumurtlamanın gerçekleşmemesi durumudur. PKOS tanısı koyulabilmesi için kişinin 1990 NIH kriterlerinden ikisini de taşıması gerekmektedir(Zawadzski, 1992).

Rotterdam kriterlerine göre polikistik over sendromunun teşhisi için üç kriter vardır. Bunlar hiperandrojenizmin, anovülasyon ve polikistik over morfolojisidir. NIH kriterlerine ek olarak ultrasonda PKOS morfolojiside eklenmiştir. Rotterdam kriterlerinden en az ikisini taşıyan kişiye polikistik over sendromu tanısı koyulabilmektedir(ESHRE ve Group, 2004).

Androjen Fazlalığı Toplumu'nun tanımına göre ise PKOS tanı kriterleri hiperandrojenizm ve ultrasonda polikistik yumurtalık izlenmesidir. Bu kriterlerin her ikisinin de bulunması gerekir(Azziz ve ark., 2009).

Çizelge 1.1. PKOS için önerilen tanı kriterleri

NIH konsensüs kriterleri 1990(Zawadzski, 1992)	Rotterdam kriterleri 2003 (ESHRE ve Group, 2004)	AES tanımı 2008 (Azziz ve ark., 2009)
Oligo veya anovulasyona bağlı adet düzensizliği	Yumurtlama düzensizliği/Oligo veya anovulasyon	Yumurtlama düzensizliği/
Hiperandrojenizm	Hiperandrojenizm	Hiperandrojenizm
	Ultrasonda PKO morjolojisi	

NIH: Ulusal Sağlık Enstitüleri; AES: Androjen Fazlalığı Toplumu

Ehrmann ve ark. tarafından yapılan araştırmaya göre PKOS için üç kriter vardır. Bunlar; adet düzensizliği, erkeklik hormonunun fazla salgılanması ve obezitedir. Bu belirtilere sahip kişilerde PKOS varlığından şüphelenilmektedir. Aynı zamanda tip-2 diyabet hastalığının varlığı da PKOS tanısında büyük etkindir (Ehrmann ve ark., 1999).

Dahlgren ve ark. yaptıkları çalışmada polikistik over sendromu olan kişilerin tip-2 diyabet ve kardiyovasküler hastalık riskinin diğerlerine göre daha çok olduğunu kanıtlamışlardır (Dahlgren ve ark., 1992).

Literatürde folikül tespiti ve sınıflandırma ile ilgili bazı çalışmalar bulunmaktadır. Nazarudin ve ark., görüntü segmentasyonunda kullanılan yöntemleri bir araya getirmiş ve performans değerlendirmesi yapmışlardır. Görüntü segmentasyonu için Watershed dönüşümü, bölgesel büyütme yöntemi, kenar tabanlı yöntem, aktif kontur yöntemi, eşikleme yöntemi ve kümeleme yöntemi karşılaştırılmıştır. Otomatik folikül tanımlamada en yüksek başarı oranı 2016 yılında Padmapriya tarafından %87,5 tanıma oranı ile Canny operatörü kullanılarak kenar tabanlı yöntemle morfolojik işlemler kullanılarak yapılmıştır.(Padmapriya ve Kesavamurthy, 2016; Nazarudin ve ark., 2020).

Zeng ve Liu sığırların folikül görüntüleri ile çalışmışlardır. Görüntülerdeki benek gürültüsü ve bulanık kenarlı foliküller nedeniyle temel görüntü algılama algoritması iyi sonuçlar vermemektedir. Bu çalışmada derin öğrenmeye dayalı görüntü algılama modeli önerilmiştir. Faster R-CNN ve geliştirilmiş Faster R-CNN ile sınıflandırma yapılmış ve karşılaştırılmıştır. Faster R-CNN'in başarısı %75,4 iken geliştirilmiş Faster R-CNN'in başarısı %78,3 olmuştur. Geliştirilen Faster R-CNN'in daha yüksek doğruluğa sahip olduğu tespit edilmiştir (Zeng ve Liu, 2019).

Soni ve Vashisht folikül segmentasyonu için yeni bir yöntem denemişlerdir. Segmentasyondan sonra KNN ve CNN ile iki ayrı sınıflandırma yapmışlar. PKOS'un derecelerine göre sınıflandırma yapmışlardır. Çalışmanın sonucunda "yüksek", "orta" ve "düşük" şeklinde sınıflandırma yapılmıştır (Soni ve Vashisht, 2019).

Rao ve Kumar ultrason görüntüsünün segmentasyonu için uyarlanabilir k-ortalama kümeleme kullanarak folikül tespiti için yeni bir algoritma önermişlerdir. Önerilen algoritma görseller üzerinde test edilmiş ve görüntüler "normal yumurtalık", "kistik yumurtalık", "polikistik yumurtalık" şeklinde 3 sınıfa ayrılmıştır. Bu tip kümeleme algoritmalarında küme sayısı önemlidir. Çalışmanın sonucunda normal kümeleme yönteminin ortalama hata karesi (MSE) %95,8 ve uyarlanabilir kümelemenin

MSE değeri ise %94,5'dir. Az bir farkla normal kümeleme yönteminin uyarlanabilir kümeleme yönteminden daha iyi sonuçlar verdiğine ulaşılmıştır (Rao ve Kumar, 2019).

İnik ve ark. foliküllerin tespiti için yeni bir yöntem önermiştir. Segmentasyon ve sınıflandırma için iki ayrı ESA tasarlanmıştır. Alt görüntüler kenar, folikül ve arka plan olmak üzere üç gruba ayrılmıştır. Segmentasyondan sonra oluşan gürültüleri gidermek ve foliküllerin sınırlarını belirlemek için de yeni bir yöntem önermişlerdir. Foliküllerin sınırları belirlendikten sonra ESA'ya dayalı bir sınıflandırma yapılmıştır. Sınıflandırma için veri büyütme yapılmıştır. Önerilen yöntem, Faster R-CNN modeli ile karşılaştırılmış ve daha başarılı olduğu tespit edilmiştir. Önerilen yöntemin doğruluğu %95,35'tir (İnik ve ark., 2019).

Sonigo ve ark. farelerin yumurtalık primordial folikül (PMF) sayılarının tespiti için otomatik bir sistem sunmuşlardır. Sınıflandırıcı tasarlanırken VGG 19 mimarisinden esinlenilmiştir. Fare yumurtalıklarından 9 milyon görüntü alınarak veritabanı oluşturulmuştur. Bu görüntüler ile ağ eğitilmiş ve 3 milyon görüntü ile test edilmiştir. Çalışmada kullanılan TIFF görüntülerinin boyutu 200 GB'dır ve bunu azaltmak için çözünürlük azaltılmış ve görüntüler siyah-beyaz (BW) yapılmıştır. Folikül tespitinin doğruluğu gerçek pozitif (TP) ve yanlış pozitif (FP) değerleriyle analiz edilmiştir. Tespit edilen foliküllerin yaklaşık %89'u FP'dir. %11,32'lik keskinlik ve %99,46 geri çağırma elde edilmiştir. HNM uygulamasından sonra ise %57,38 keskinlik ile %90,40 geri çağırma elde edilmiştir ve tespit edilen foliküllerin yaklaşık %43 FP'dir. Sonuçlar iyileştirilmiştir ve %65,69 hassasiyetle %91,36 geri çağırma elde edilmiştir. Tespit edilen foliküllerin yaklaşık %19,5'i FP'dir. (Sonigo ve ark., 2018).

Wisesty ve Mutiah ultrason görüntülerine Gabor Dalgacık yöntemi uygulayarak özellik çıkarımı yapmışlardır. Özellik çıkarımı yapılan foliküllerin sınıflandırılması için Destek Vektör Makinesi (DVM) yöntemini kullanmışlardır. Çalışmalarında Gabor Dalgacık sonucu elde edilen özellikler kullanılarak en yüksek doğruluğu veren çekirdek fonksiyonu $C=160$ belirlenmiştir. Testte %78,46 ve eğitimde %75,54 doğruluk oranı elde etmişlerdir (Wisesty, 2016).

Wisesty ve ark. polikistik over sendromu hastalığını sınıflandırmak için bir yöntem geliştirmişlerdir ve Gabor dalgacık ile özellik çıkarımı yapmışlardır. Foliküllerin ortalama, entropi, basıklık, çarpıklık ve varyans özelliklerini kullanmışlardır. Normal ve polikistik over görüntüleri kullanılarak "polikistik over" ve "polikistik over olmayan" şeklinde sınıflandırma yapmışlardır. 3 farklı sınıflandırma algoritması karşılaştırılmıştır. Sınıflandırma da Sinir Ağı-LVQ, KNN-öklid mesafesi ve SVM-RBF


çekirdeği kullanılmıştır. Sonuç olarak A veritabanında SVM-RBF çekirdeği $C=40$ değeri ile %82,55 ve B veritabanında KNN-öklid mesafesi $K=5$ değeri ile %78,81 sınıflandırma doğruluğu elde edilmiştir (Purnama ve ark., 2015).

Hiremath ve Tegnoor, yumurtalıkların ultrason görüntülerinde gürültü filtreleme için ön işleme aşamasında Gauss düşük geçiş filtresi ve Konturlet Dönüşümü'nü kullanmışlardır. Filtrelemeden sonra histogram eşikleme yapmışlar ve görüntü segmentasyona hazır hale getirilmiştir. Kenar algılama için Canny, Sobel ve Prewitt kenar algılama algoritmalarını denemişlerdir ve Canny kenar algılama ile segmentasyon için en iyi sonuca ulaşmışlardır. Sonuçları uzmanın kararıyla karşılaştırmışlar. Gaussian düşük geçiş filtresi ile sınıflandırma oranı %62,3 ve Konturlet Dönüşümü ile sınıflandırma oranı %75,2 elde etmişler. Elde edilen bu başarı oranları Konturlet Dönüşümü yönteminin daha iyi sonuçlar verdiğini ifade etmişlerdir (Hiremath ve Tegnoor, 2010).


Lawrence ve ark. polikistik over sendromunu otomatik olarak algılayan yeni bir yöntem önermişler. Çeşitli segmentasyon yöntemleri kullanmışlar ve en yüksek folikül tanıma oranı %78 olarak bölgesel genişletme algoritması olduğunu ifade etmişlerdir. Ortalama ve standart sapma özelliklerini kullanmışlardır. Sınıflandırma için Doğrusal Diskriminant Sınıflandırıcı (LDC), K-en yakın komşu (KNN) ve destek vektör makinesi (SVM) olmak üzere 3 farklı yöntem kullanmışlar. Bunlardan Doğrusal Diskriminant Sınıflandırıcı'nın %92,86 ile en yüksek sınıflandırma oranını ürettiğini belirtmişlerdir (Lawrence ve ark., 2007).

2. POLİKİSTİK OVER SENDROMU

Yumurtalıklar normal yumurtalık, kistik yumurtalık ve polikistik yumurtalık olarak üç gruba ayrılır. Bir yumurtalıkta 2-28 mm çapında 8-10 adet folikül bulunması normal yumurtalık olarak kabul edilir (Gougeon ve Lefèvre, 1983). Bu kistlerin sayısı 12 veya daha fazla ise polikistik yumurtalık grubuna dahil edilir. Çok sayıdaki küçük kistler yumurtalıklara dizilişleriyle karakteristik bir özellik verir. Ultrason görüntüsünde çok özel bir görünüm oluşturur ve bu görünüm polikistik yumurtalık olarak adlandırılır. Şekil 2.1’de normal yumurtalık ultrason görüntüsü, Şekil 2.2’de polikistik yumurtalık ultrason görüntüsü görülmektedir.




Şekil 2.1. Normal yumurtalık ultrason görüntüsü



Şekil 2.2. Polikistik yumurtalık ultrason görüntüsü

PKOS, üreme çağındaki kadınlarda görülen hormonal bozukluklar sonucunda ortaya çıkan bir hastalıktır. Sağlıklı bir kadının menstrüasyon döneminde üretilen yumurtanın çatlaması ile kanama gerçekleşir. Ancak PKOS olan hastalarda bu yumurtalar çatlayamaz ve yumurtalıklarda birikir. Bu durumda yumurtalıklarda birçok

iyi huylu kist meydana gelir. Bu kistler 12 veya daha fazladır ve genellikle 2-9 mm çapındadır (Battaglia ve ark., 1997). Şekil 2.3.'te normal ve polikistik yumurtalık görünümü verilmiştir.



Şekil 2.3. Normal yumurtalık ve polikistik yumurtalık görüntüsü(Philip ve ark., 2007)

PKOS kadınlarda en sık görülen hormonal bozukluktur ve kadınların yaklaşık %6-7'sinde görülür (Dunaif ve ark., 1987; Zawadzski, 1992; Knochenhauer ve ark., 1998; Asunción ve ark., 2000). Genellikle 30 yaşın altında tanı koyulur. PKOS teşhisi için folikül uyarıcı hormon (FSH) ve luteinleştirici hormon (LH) değerlerine bakılmalıdır (FAUSER ve ark., 1991; Taylor ve ark., 1997). FSH ve LH yumurtlamayı kontrol eden hormonlardır. FSH, yumurtalığı folikül üretmesi için uyarır, LH ise yumurtalığın olgun bir yumurta bırakmasını sağlar. PKOS'a sahip hastalarda LH anormal şekilde fazla üretilirken FSH ise düşüktür. İnsülin direnci ve LH hormonunun yüksekliği PKOS şüphesi için bakılacak kriterlerin başındadır. Bu hormonal bozukluk kadınlarda düzenli yumurtlama olmasına engel olur. Yumurtlamanın düzensizliği sonucunda kadında erkeklik hormonu olan testosteron hormonunu artırır. Kadınlarda erkeksi özelliklerin görülmesi durumu hiperandjonizm olarak adlandırılır. Bu kadınlarda aşırı tüylenme, erkek tipi saç dökülmesi, ses kalınlaşması gibi özellikler öne çıkmaktadır.

Bu hastalık kalıtsaldır ve anne karnında başlar. Kişi üreme çağına geldiğinde bu hastalık çeşitli belirtilerle kendini gösterir. İlk ve en önemli belirtisi hiç adet görmeme ya da düzensiz şekilde adet görülmesidir. Daha birçok belirtiyeye sahip olan PKOS beraberinde başka hastalıkları da getirmektedir.

2.1. Polikistik Over Sendromunun Belirtileri

Polikistik over sendromunun tespit edilebilmesini kolaylaştıran pek çok belirtisi vardır. Rotterdam kriterlerine göre bu hastalığın teşhisi için yeterli olan 3 temel kriter vardır. İlki adet düzensizliği olarak bilinen anovulasyon, ikincisi hiperandrojenizm, sonuncusu ise ultrasonda polikistik yumurtalık morfolojisine sahip olunmasıdır (ESHRE ve Group, 2004). Anovulasyon normal adet döngüsü içerisinde hiç yumurtlama olmamasıdır. Hiperandrojenizm ise kadınlarda androjen yani erkeklik hormonlarının çok fazla üretilmesidir. Androjen fazlalığı kadınların %7'sinde görülmektedir(Knochenhauer ve ark ., 1998; Diamanti-Kandarakis ve ark ., 1999; Asunción ve ark ., 2000) ve androjen fazlalığı olan kadınların çoğunda PKOS vardır(Azziz ve ark., 2004). Hiperandrojenizmin başlıca klinik belirtileri akne, erkek tipi saç dökülmesi ve vücudun aşırı kıllanması olarak tanımlanan hirsutizmdir (Huang ve ark., 2010).

PKOS tanısı için bu üç kriterden en az iki tanesine sahip olmak gerekir. Örneğin ultrasonda polikistik over morfolojisine sahip ve adet düzensizliği ile uzman kişiye başvuran kadınlara PKOS tanısı koyulabilmektedir.

Bu sendrom, klinik muayene ve ultrasonografi kullanılarak tanımlanabilir(Lujan ve ark., 2008). PKOS'un klinik belirtileri arasında adet düzensizlikleri, androjen fazlalığı, obezite ve hirsutizm bulunur.

Bunların dışında da birçok belirti mevcuttur:

- Akne problemi
- Cildin çok yağlanması
- Vücutta aşırı tüylenme
- Ellerde lekelenmeler
- Aşırı saç dökülmesi
- Erkek tipi kellik
- Ses kalınlaşması
- Göğüs ölçülerindeki değişiklik
- Hızlı kilo artışı
- Depresyon ve anksiyete
- Düzenli baş ağrısı
- Uyku apnesi

- Kısırlılık
- Ağır geçen kanamalar

PKOS kronik anovulason ve iinfertilitenin en sık nedenidir(Wood ve ark., 2007; Dumont ve ark., 2015). Bu durum bebek sahibi olmak isteyen kadınları olumsuz etkilemektedir. Bu nedenle PKOS'un erken teşhis edilip bebek sahibi olmak isteyen kadınların da çeşitli tedaviler görmesi gerekmektedir.

2.2. Polikistik Over Sendromunun Teşhisi

Polikistik over sendromunun teşhisi klinik muayene ve ultrasonografi ile yapılmaktadır. Polikistik over sendromunun teşhisinde ultrason görüntülerinin önemioldukça fazladır. Kişi çeşitli semptomlar ile uzmana başvurur. Uzman kişi ultrason görüntülerine ve beraberinde kan testine bakarak bu hastalığın tanısını koyabilmektedir. Ultrasonda yumurtalıklardaki kistlerin görünümü bize PKOS hakkında net bir bilgi vermektedir. Her yumurtalıkta 12veya daha fazla kist bulunmalıdır ve bu kistlerin çapı 2-9 mm olmalıdır (Battaglia ve ark., 1997; Balen ve ark., 2003).

PKOS oluşumunda genetik faktörlerde rol oynamaktadır. Bu nedenle PKOS olan kişinin ailesinde de olup olmadığına bakılır (Legro ve ark., 1998; Gonzalez ve ark., 2003). Kalıtsal bir hastalık olduğundan yumurtalıklardaki kistlerin yok olması mümkün değildir. Ancak erken teşhis ve tedavi yöntemleri ile hastalığın semptomlarının hastayı ileri derecede etkilememesi ve en aza indirilmesi sağlanmaktadır.

PKOS sadece yumurtalıklarda oluşan kistler olarak bilinse de vücuttaki tüm organları etkileyen anormal bir durumdur. Polikistik over sendromu obezite, hipertansiyon, insülin direnci, diyabet, kalp damar hastalıkları, rahim kanseri gibi pek çok hastalığa da yol açmaktadır. PKOS olan kadınların uzun vadede tip-2 diyabet riski taşıdıkları kanıtlanmış bir gerçektir(Dunaif ve ark., 1987; Dahlgren ve ark., 1992; Ehrmann ve ark., 1999; Legro ve ark., 1999; Wild ve ark., 2000). PKOS olan kadınlarda diğerlerine göre tip-2 diyabet riski 10 kat daha fazladır. Aynı zamanda bu kişilerde kardiyovasküler hastalık riski de oldukça yüksektir (Dahlgren ve ark., 1992).

Hastalığın erken teşhis edilmesi bu noktada çok önemlidir. Çünkü PKOS ileride daha büyük hastalıklara yol açabilmektedir. Bu çalışmada hastalığın daha hızlı ve doğru bir şekilde tespit edilmesi hedeflenmektedir. Bu uzman kişiler için büyük bir kolaylık sağlayacaktır.

2.3. Polikistik Over Sendromunun Tedavisi


PKOS teşhisi ileride karşılaşılabilecek başka hastalıkları önlemek için oldukça önemlidir ve erken teşhis edilip bir an önce tedaviye başlanmalıdır. Polikistik over sendromunun tedavisi hastanın isteklerine ve beklentilerine göre değişmektedir. Genellikle bu durum bebek sahibi olmak isteyenler ve istemeyenler olarak ikiye ayrılmaktadır. İki durum içinde ilk yapılması gereken insülin direncine bağlı olarak artış gösteren kilonun kontrol altına alınmasıdır. Bebek sahibi olmak isteyen hastalarda menstrüasyon döneminde oluşan yumurtanın çeşitli yöntemlerle döllendirilmesi sağlanırken bebek sahibi olmak istemeyen hastalarda ise ilk önce doğum kontrol hapları ile adet düzensizliği ortadan kaldırılır. Hormon tedavisi uygulanarak hormon seviyeleri normal değerlere çekilir. Böylece PKOS'un başka hastalıkları tetiklemesi önlenabilmektedir.

Tedavinin planlanabilmesi için yumurtalık ultrason görüntüleri üzerinden folikül tespitinin yapılması oldukça önemlidir. Bu amaçla bu tez çalışmasında otomatik folikül tespitinin en iyi şekilde sağlanması için 10 farklı yöntem test edilmiştir. Önerilen yöntemler uzman kişinin görüşleri ile karşılaştırılmış ve folikül tanıma iyi bir başarı oranı ile gerçekleştirilmiştir.

3. DİJİTAL GÖRÜNTÜ

Görüntü, x ve y koordinat düzleminde $f(x,y)$ şeklindeki 2 boyutlu ışık yoğunluğudur ve f değeri o andaki parlaklık değeridir (Gonzalez ve Woods, 2006; Petrou ve Petrou, 2010). Dijital görüntü ise ayrıklaştırılmış bir $f(x,y)$ görüntüsüdür (Petrou ve Petrou, 2010).

Dijital görüntü yeryüzünde var olan renkli resmin sayısal bilgisayar verisine dönüştürülmüş şeklidir. Bir dijital görüntü iki boyutlu görüntünün piksel adı verilen dijital değerler ile gösterilir. Her piksel bir sayıya karşılık gelmektedir. Dijital görüntüye sayısal görüntü de denilmektedir. Piksellerden oluşan satır ve sütunlar sayısal görüntüyü oluşturur (Gonzalez ve Woods, 2006) Sayısallaştırılmış parlaklık değeri gri seviye olarak adlandırılır. (Gonzalez ve Woods, 2006; Petrou ve Petrou, 2010) Şekil 3.1’ de dijital görüntülerin sistematığı görülmektedir.




Şekil 3.1. Dijital görüntülerin sistematığı(Gonzalez ve Woods, 2006)

3.1. Görüntü Türleri

Sayısal görüntüler 2 boyutlu matrisler şeklindedir. M görüntünün satır sayısını, N ise sütun sayısını verir. Satır ve sütunların kesiştiği her nokta piksel olarak adlandırılır. Bir görüntüde $M \times N$ adet piksel bulunur. Matrisin her elemanı o piksele

denk gelen rengin sayısal değeridir. Bu sayısal değer görüntünün türüyle ilgilidir. Görüntü siyah-beyaz ise her piksel 0 ya da 1 değerini alabilir. 0 değeri beyaz noktaları belirtirken 1 değeri de siyah noktaları belirtmektedir. 0 ve 1'lerden oluşan bu tür resimlere ikilik resim denir. Gri seviye görüntülerde siyah ve beyaz olmak üzere iki renk vardır. Bu iki renk arasındaki görüntüler gri tonlamalı görüntülerdir. Görüntü gri tonlarında ise pikseller 0-255 arasındaki değerleri alabilir. 0'a daha yakın olan değerler siyah, 255'e daha yakın değerler beyaz tonlarındadır. Bir görüntüde 2^n adet renk tonu vardır ve n sayısı görüntünün kaç bittten oluştuğunu ifade eder (Gonzalez ve Woods, 2006). Örneğin 1 bit görüntüde siyah ve beyaz olmak üzere $2^1=2$ adet renk bulunur. 4 bit bir görüntüde ise $2^4=16$ adet farklı renk tonu bulunmaktadır. Renkli görüntüler ise R (Kırmızı), G (Yeşil), B (Mavi) olmak üzere üç renk bandından oluşur (Petrou ve Petrou, 2010). Üç farklı renk bandına sahip olması her biri farklı hassasiyete sahip üç ayrı sensör ile algılandığını ifade eder. Sensöre gelen ışığın spektrumu o sensörün hassasiyet fonksiyonu ile çarpılır ve kaydedilir. Kaydedilen her değer o sensör bandındaki görüntünün parlaklığını ifade eder (Petrou ve Petrou, 2010). Gri seviye görüntülere uygulanan çoğu işlem her bir banda ayrı ayrı uygulanarak renkli görüntülere de rahatlıkla uyarlanabilmektedir. Bu sayede renkli görüntülerin kullanımı çoğalmıştır (Petrou ve Petrou, 2010). Şekil 3.2.'de R, G, B sensörlerinin hassasiyet grafiği verilmiştir.



Şekil 3.2. R, G, B sensörlerinin hassasiyet grafiği

Her bir piksel dünyada var olan 3 boyutlu nesnelerin bir parçasıdır ve bu nesneler yansıyan ışıkla aydınlatılır. Yansıyan ışığın bir kısmı sensörlere ulaşır ve kaydedilir.

Kaydedilen bu deęer Şekil 3.2.’deki hassasiyet eęrisine baęlıdır. Bir foton sensöre ulařınca o dalga boyundaki hassasiyet deęeri ile arpılır ve toplanır. Toplam enerji ile bu sensöre karřılık gelen gri deęeri hesaplanır (Petrou ve Petrou, 2010).

RGB renk uzayında her bir renk 0-255 aralıęındaki deęerlerle ifade edilmektedir. R kırmızı, G yeřil, B mavi rengi ifade etmektedir. Örneęin kırmızı bir görüntüde yeřil ve mavi bant deęerleri 0, kırmızı bant deęeri 255’tir. Mavi görüntüde kırmızı ve yeřil bant deęerleri 0, mavi bant deęeri 255’dir(Friedman-Berg ve ark., 2008).

Dijital görüntü iřlemenin uygulama alanı oldukça geniřtir. Görüntüler ultrason, elektron mikroskopu ve bilgisayarlar tarafından da elde edilebilmektedir. Bu alıřmada ultrasonografi görüntüleri kullanılmaktadır.


3.1.1. Ultrason görüntüleri

USG, ses dalgaları aracılıęıyla vücutun iç kısımlarının görülebilmesini saęlayan tıbbi görüntüleme yöntemidir. 2-15 MHz frekansa sahip ses dalgaları ile alıřmaktadır (Jensen, 2007). Ultrason görüntüleri iřlemin yapıldıęı bölgeye göre farklılık göstermektedir. Ultrason cihazları iki boyutlu görüntü üretir. Bu görüntüler siyah-beyaz ve gri renklidir. Vücutta kolayca erişilemeyecek kısımlar görüntülenerek bu bölgede meydana gelen deęiřimler ve geliřimler takip edilebilmekte, hastalıklarda ön tanı konulabilmekte ve bazı hastalıklar teřhis edilebilmektedir. Bu tez alıřmasında da yumurtalık foliküllerinin tespiti ve yumurtalık sınıflandırılması için iki boyutlu ultrason görüntüleri kullanılmıřtır.


Ultrasonun kullanıldıęı bařlıca alanlar:

- Gebelik takibi
- Kist oluřumları
- Safra kesesi hastalıkları
- Meme tümörleri
- Tiroit bezi hastalıkları
- Prostat
- Genital bölge hastalıkları

Şekil 3.3.’de meme ultrason görüntüsü ve Şekil 3.4’ de ise yumurtalık ultrason görüntüsü verilmiřtir.



Şekil 3.3. Meme ultrason görüntüsü (Shi ve ark., 2010)



Şekil 3.4. Yumurtalık ultrason görüntüsü

3.2. Görüntü İşleme Aşamaları

Görüntü işleme, dijital ortamda bulunan görseller üzerinde gereksinime göre bilgisayar aracılığıyla yapılan çeşitli işlemlerdir. İhtiyaca göre farklı teknikler kullanılmaktadır. Kaydedilen görüntülerin renk, ışık, zıtlık, netlik, bulanıklık, kontrast gibi özellikleri değiştirilebilmekte ya da istenmeyen gürültü ve bozukluklar giderilebilmektedir. Görüntü üzerinde iyileştirme yapılır ve görüntü kalitesi artırılır. Görüntü işleme teknikleri ile bu görüntülere ait farklı özellikler de belirlenebilmektedir. Görüntü işleme sayesinde resimleri yorumlamak daha kolaylaşmaktadır. Resimlerin iletilmesini, basılmasını ve saklanmasını kolaylaştırmak için görüntüler işlenmektedir (Petrrou ve Petrrou, 2010).

Görüntü işleme ile neler yapılabilir:

- İyileştirme
- Onarma
- Aktarım
- Saklama
- Şifreleme
- Anlama ve yorumlama
- Sıkıştırma
- Teşhis
- Tanıma
- Sınıflandırma

Görüntü işlemenin en çok kullanıldığı alanlar:

- Resim ve video çekme (uygun renk ve ışık kalitesi)
- Görüntü saklama ve iletilmesi
- Tıp (ultrasonografi, tomografi gibi biyomedikal görüntüler)
- Biyoloji (hücre görüntüleri)
- Kimya (mineral tanıma)
- Coğrafya (nüfus yoğunluğu, çevre kirliliği)
- Tarım (kalite tayini, ürün sınıflandırma)
- Endüstri (ürün sınıflandırma)
- Savunma sanayi (insansız hava araçları)
- Hayvancılık (et kalite tayini)
- Güvenlik sistemleri (yüz tanıma, plaka tanıma)
- Sanal gerçeklik uygulamaları (3 boyutlu görüntü elde etme)
- Duygu analizi
- Sualtı görüntüleme
- Radar sistemleri

3.2.1. Görüntü elde etme

Görüntü işlemenin ilk adım görüntülerin elde edilmesidir. Sayısal görüntüler kamera ile elde edildiği gibi ultrason, MR, röntgen gibi cihazlar aracılığıyla elde edilmektedir. Ayrıca uzman kişilerce hazırlanmış veritabanlarındaki görüntüler de

kullanılabilmektedir. Görüntü işlemede kullanılacak olan veri bir video kesiti ya da resimdir. Bu çalışmada ultrason görüntüleri kullanılmıştır. Ultrason görüntüleri ise yatay veya dikey problemler ile elde edilmektedir. Problemlerin temas yüzeyinde bulunan kristaller sayesinde gri seviye ekran görüntüsü kaydedilmektedir. Ultrason cihazlarında uygun prob seçimi izlenecek olan bölgeye göre seçilmektedir. Yumurtalık ultrason görüntülerinin elde edilmesinde genellikle dikey problemler kullanılmaktadır.

3.2.2. Ön işleme

Bu bölümde bu tez çalışmasının ön işleme aşamasında kullanılan yöntemlerden bahsedilecektir. Görüntü elde edildikten sonraki aşama ön işlemedir. Bu aşamaya düşük seviyeli görüntü işleme de denilmektedir. Böylece görüntü kalitesi iyileşmektedir. Bu aşamada filtreleme, kontrast eşitleme, morfolojik işlemler gibi pek çok işlem yapılmaktadır (Pratt, 2007). Ön işleme aşamasında görüntülerin iyileştirilmesi ve gürültülerin giderilmesi amaçlanmaktadır. Görüntüdeki gürültü ve parazitleri ortadan kaldırmak ve görüntüyü iyileştirmek için filtreleme yapılmaktadır (Gonzalez ve Woods, 2006; Petrou ve Petrou, 2010).

Görüntüler sayısallaştırılırken ve bilgisayarlara aktarılırken çeşitli gürültülere maruz kalırlar. Gürültünün oluşmasında birçok etken vardır. Bu gürültüler görüntünün kalitesinde bozulmalara neden olurlar. Gürültü ve parazitleri önlemek için görsellere filtreleme uygulanmaktadır (Gonzalez ve Woods, 2006; Sun, 2016). Filtreleme belirli kısımları vurgulamak, görüntüyü yumuşatmak ve gereksiz olan gürültüleri ortadan kaldırmak için kullanılan bir tekniktir. Görüntü değişmeden istenilen bölgeler ön plana çıkarılır. Filtrelerin boyutu arttıkça zaman hesaplamalar daha karmaşıklaşır ve uzar. Bu nedenle filtrelerin boyutu genellikle 3x3'lük matris şeklinde seçilir. Bu çalışmada kullanılan filtreler: Ortalama filtre, Ortanca filtre, Gaussian filtresi ve Wiener filtresidir.

Ortalama filtrenin yapısı basit ve uygulaması da oldukça kolaydır. Bir piksel ve sonraki piksel arasındaki yoğunluk farkını azaltır. Genellikle 3x3 boyutunda matris kullanılır. Görüntüde daha fazla yumuşatma sağlamak için 5x5'lik matris de kullanılmaktadır (Gonzalez ve Woods, 2006). Ortalama filtre yakında bulunan tüm piksellerin ortalamasını aldığı için keskin kenarların yumuşamasına ve resmin değişmesine neden olmaktadır. Görüntüdeki belirgin farklılıklar yok edilir ve bu durum bazen dezavantaj oluşturmaktadır. Bu problemi ortadan kaldırmak için ortanca filtre geliştirilmiştir.

Ortanca filtre Tukey tarafından 1971 yılında geliştirilmiş bir sinyal işleme tekniğidir. Sıralama filtreleri içinde en yaygın olanı ortanca filtredir(Tukey, 1977). Ortanca filtre gürültü gidermeyi ve resimdeki detayların daha az kaybolmasını sağlamaktadır(Zhu ve Huang, 2012). Bu filtre ortalama filtreden daha yavaş çalışmaktadır (Tukey, 1977). Bu çalışmada medyan filtresi olarak 3x3'lük bir matris kullanılmıştır ve artan sırayla sıralandığında 9 adet gri değere sahiptir. Bu durumda ortanca değer beşinci değerdir.

Wiener filtresinin amacı hata karelerinin ortalamasını (MSE) en aza indirmektir. Giriş sinyaline göre tahmini bir çıkış sinyali üretmektedir. Bozuk sinyalden gelen gürültüyü bilinen sinyalden ayırarak filtreleme yapmaktadır.

Gaussian filtresi de gürültüyü ortadan kaldırmak için bulanıklaştırma yapan lineer bir filtredir. Gaussian filtresi beyaz gürültüleri giderirken kenar keskinliklerini korumada oldukça başarılıdır. Gaussian filtresi her pikeldeki renk değerinin belirlenen penceredeki elemanlarla çarpılması şeklinde çalışır.


Filtrelemeden sonra görüntüyü iyileştirmek için kontrast ayarı yapılmalıdır. Kontrast görüntünün en parlak ve en karanlık bölümü arasındaki farktır. Bu fark ne kadar fazla olursa görüntü o kadar iyi olur. Bu nedenle görüntülerde kontrast ayarı da oldukça önemlidir. Bu çalışmada filtrelemeden sonra histogram eşitleme ile standart eşikleme ve uyarlanabilir eşikleme olmak üzere iki farklı kontrast ayarlama yöntemi uygulanmıştır. Filtrelenmiş resme kontrast eşitsizliklerini dengelemek için ilk önce histogram eşitlemesi uygulanmıştır Bir görüntünün histogramı o görüntüye ait gri değerlerdeki piksellerinin oluşturduğu grafikdir. Histogram grafiği görüntü hakkında bilgi vermektedir. Görüntü düşük kontrasta sahip ise histogramı dardır. Bir görüntüde çok fazla detay yoksa bu görüntüyü ayrıntılandırmak için histogram eşitleme yapılmaktadır. Özellikle karanlıkta detaylar genellikle belli olmaz ve bu durumda piksellerin gri seviyelerini yaymak gerekir. Histogram eşitleme ile görüntüdeki gri seviyeler birbirine yaklaşmaktadır (Pratt, 2007). Bir görüntüdeki gri seviyeleri g_{min} - g_{max} arasındadır. $G - 1 > g_{min} - g_{max}$ olmak üzere $[0, G - 1]$ aralığına yayılmak istenen gri seviye aşağıdaki formül kullanılarak hesaplanmaktadır. g_{min} görüntüdeki minimum gri seviyesi değerini, g_{max} ise görüntüdeki maksimum gri seviyesi değerini ifade etmektedir. Görüntüyü etkilemeden gri değerleri yayma işlemine histogram eşikleme denir. Eşitlik (5.1)' de gri seviye yayma işlemi verilmiştir. (Petrou ve Petrou, 2010)

$$g_{new} = \left[\left(\frac{gold - g_{min}}{g_{max} - g_{min}} \right) * G + 0.5 \right] \quad (5.1)$$

Ön işleme aşamasında görüntüyü iyileştirmek için kullanılan yöntemlerden biri de morfolojik işlemlerdir. Morfoloji şekillerin yapısını kullanarak nesnelerin ayırt edilmesini sağlayan görüntü işleme tekniğidir (Soille, 2013). Morfolojik işlemler genellikle siyah-beyaz görüntülere uygulanmaktadır. Morfolojik işlemler genişletme, aşındırma, açma ve kapama işlemleridir (Efford, 2000). Genişletme görüntüdeki nesneyi büyötmeye yarayan bir işlemdir. Görüntüdeki delikler ve boşluklar doldurulur. Aşındırma işlemi görüntüdeki nesneleri küçöltür. (Gonzalez ve Woods, 2006; Russ, 2006)Görselde birbirine bağılı nesneler varsa küçöölerek birbirinden ayrılır. Açma ve kapama işlemleri genişletme ve aşındırma işlemlerinin birleşiminden elde edilmiştir. Görüntüye önce genişletme ve hemen ardından aşındırma işlemi uygulandığında bu işleme açma denir. Açma işleminde görüntünün içindeki boşluklar ve gereksiz yerler temizlenir. Görüntüye önce aşındırma ve arkasından genişletme işlemi uygulanırsa bu işleme kapama denir. Kapama işleminde ise görüntü içindeki nesnelerin dolgunlaşması sağlanır. (Gonzalez ve Woods, 2006)

Ön işleme aşamasında sinyalleri ve görüntöleri filtrelemede, ayrıştırmada, sıkıştırmada kullanılan yöntemlerden biri de Ayrık Dalgacık Dönüşümü (ADD)'dür(Chervyakov ve ark., 2018).Dalgacık Dönüşümü yöntemi sürekli ve ayrık olmak üzere iki farklı şekilde uygulanmaktadır. Görüntüler sabit deęerler içerdii için görüntü işlemede Ayrık Dalgacık Dönüşümü kullanılmaktadır. Ultrason görüntülerinde parazitler çok fazladır ve ADD görüntüye pürüzsüzlük sağlayarak görüntöleri gidermektedir. ADD'de önce görüntüye $L*a*b$ renk uzayı dönüşümü yapılmaktadır. L görüntünün parlaklık seviyesini, a kırmızı-yeşil katmandaki yerini, b ise mavi-sarı katmandaki yerini ifade etmektedir(Kiruthika ve Ramya, 2014). Temel olarak, L *parlaklık, a * kırmızılık-yeşillik ve b * sarılık-mavilik ile ilişkilidir (Pratt, 2007).

ADD ile görüntüler dalgacık katsayıları kullanılarak alt uzaylara ayrıştırılır. Şekil 3.5.'te 2 boyutlu bir ADD'nin tek seviyeli dönüşümü verilmiştir. $M \times N$ boyutlarında bir $F(x,y)$ görüntüsü x boyutunca filtrelenmektedir. $g(x)$ yüksek geçiş filtresini $h(x)$ ise düşük geçiş filtresini ifade etmektedir. Dönüşüm sonucunda yaklaşık katsayılar $FLL(x,y)$, yatay katsayılar $FLH(x,y)$, dikey katsayılar $FHL(x,y)$ ve diyagonal katayılar ise $FHH(x,y)$ olarak adlandırılmıştır(Krishna ve Kaliaperumal, 2013)



Şekil 3.5. 2B ADD'nin tek seviyeli ayrışımı (Krishna ve Kaliaperumal, 2013)

ADD'de yatay detay, dikey detay, diyagonal detay katsayıları bulunmaktadır. Eşitlik (5.3)'de (ψ_H) yatay, (5.4)'te (ψ_V) dikey ve (5.5)'te (ψ_D) diyagonal detay katasayısı değerini ifade etmektedir (Gonzalez ve Woods, 2006; Krishna ve Kaliaperumal, 2013).

$$\varphi(x,y) = \varphi(x)\varphi(y) \quad (5.2)$$

$$\psi_H(x,y) = \psi(x)\varphi(y) \quad (5.3)$$

$$\psi_V(x,y) = \varphi(x)\psi(y) \quad (5.4)$$

$$\psi_D(x,y) = \varphi(x)\varphi(y) \quad (5.5)$$

Folikül tespitinde kullanılan bir başka yaklaşım da kümeleme algoritmalarıdır. Bunlardan en yaygın kullanılanı k-ortalama kümeleme algoritmasıdır. K-ortalama kümeleme algoritmasındaki k değeri küme sayısını belirler ve bu değer parametre olarak alınması gerekir. (Gupta, 2011). K değeri belirlendikten sonra algorithmada rastgele k tane merkez noktası seçilir. Her veri ile rastgele belirlenen merkez noktaları

arasındaki uzaklık hesaplanarak veri en yakın merkez noktasına göre bir kümeye atılır. Daha sonra her küme için yeniden bir merkez noktası seçilir ve yeni merkez noktalarına göre kümeleme işlemi yapılır. Bu durum sistem kararlı hale gelene kadar devam eder. Burada önemli olan nokta kümelerin içindeki değerler birbirine benzemeli ancak kümeler birbirlerinden mümkün olduğunca farklı olmalıdır. Oluşturulan kümelerden biri seçilir ve diğer işlemlere devam edilir.

K-ortalama kümeleme algoritmasının küme merkez noktalarının belirlenmesi aşağıda verilmiştir (Khan ve Ahmad, 2004):

1. K değeri belirlenir ve rastgele bir merkez seçilir.
2. Merkez noktaları ile diğer verilerin arasındaki en yakın mesafeye göre kümeleme yapılır.
3. Kümeleme sonucu yeni merkezler belirlenir.
4. Sistem kararlı hale gelene kadar 2. ve 3. adımlar tekrar edilir.

3.2.3. Segmentasyon

Segmentasyona bölümleme, bölütlemeye, parçalara ayırma veya segmentasyon aşaması denilmektedir. Bu aşama görüntü işlemenin en zor kısmıdır. Görüntüdeki nesne ve arka planın birbirinden ayrıştırılması sağlanır. Segmentasyon ile bir görüntüdeki nesnelerin sınırları ve alanları belirlenir. Segmentasyon ile görüntüdeki benzer bölgeler diğer bölgelerden ayrıştırılır. Segmentasyon görüntüdeki nesnelerin kenarları, köşeleri, alanları, renkleri hakkında bilgi verir.

Görüntü segmentasyonu için gri seviyeli görsellerde temel kriter parlaklıktır. Renkli görüntülerde ise temel kriter renk bileşenleridir (Pratt, 2007). Segmentasyon işlemi kenar algılama, eşikleme, büyütme gibi pek çok farklı yöntem kullanılarak yapılabilmektedir. Kenar algılamaya dayalı segmentasyon Canny, Sobel, Prewitt gibi kenar algılama operatörleri kullanılarak yapılır. Kenar algılama operatörleri renk, doku gibi özellikleri algılar. (Brosnan ve Sun, 2004)

3.2.4. Sınıflandırma

Yapay zekâ algoritmaları gibi çeşitli karar verme mekanizmaları ile görüntülerdeki nesneler etiketlenir ve sınıflandırılır. Sınıflandırma makine öğrenmesi veya derin öğrenme ile yapılabilmektedir. Derin öğrenme algoritmaları görüntü işleme,

sınıflandırma, segmentasyon, regresyon ve tanımlamada oldukça yaygın kullanılmaktadır. Derin öğrenmenin özellik çıkarımına gerek kalmadan nesneleri yüksek performans ile sınıflandırma yapabilmesi avantajından dolayı bu tez çalışmasında sınıflandırma için derin öğrenme seçilmiştir. Derin öğrenme foliküle ait boyutu, şekli gibi özellikleri tespit ederek benzer özelliklere sahip olanlar aynı sınıf içinde sınıflandırılmıştır.



4. DERİN ÖĞRENME

Derin öğrenme, doğrusal olmayan işlem birimleri içeren giriş ve çıkış arasında birden çok katman kullanan bir makine öğrenimi algoritmasıdır(Schmidhuber, 2015). Derin öğrenmenin temel amacı birçok katman kullanarak büyük verilerin analizini yapmaktır. Girdi ve çıktı arasındaki katmanlar özellik tanımlama yaparlar ve tekrar özellik çıkarımı yapılmasına gerek yoktur. Bu nedenle derin öğrenme oldukça avantajlıdır çünkü manuel olarak çıkarılan özellikler eksiktir ve ağıın öğrenmesi uzun sürer. Ancak öğrenilen özelliklerin uyarlanması kolaydır ve öğrenmesi hızlıdır. Ayrıca derin öğrenme büyük verilerle çalışabilmektedir. Modeller, çok sayıda etiketli veri seti ve birçok katman içeren sinir ağı mimarileri kullanılarak eğitilir.

Öğrenme denetimli ve denetimsiz olmak üzere iki gruba ayrılmaktadır. Denetimli öğrenme kanıta dayalı tahminler yapar. Bilinen bir girdi veri seti ile model eğitilir ve yeni verilerle tahminler oluşturulur. Denetimli öğrenme genellikle sınıflandırma ve regresyonda kullanılır. Sınıflandırma eğitim verilerine dayanarak yeni verilerin hangi sınıfa ait olduğunu tahmin ederken regresyon ise sürekli bir veriyi tahmin eder. Denetimsiz öğrenmede ağı verilerle eğitmeye gerek yoktur ve model özelliklere bakarak kendisi öğrenir. Kümeleme denetimsiz öğrenmeye bir örnektir (Li ve ark., 2015).

Yapay zekâ teknolojinin gelişmesiyle pek çok alanda karşımıza çıkmaktadır. Resim tanıma, nesne tanıma, nesne segmentasyonu, dil çevirisi, konuşma tanıma, plaka tanıma, yüz tanıma gibi alanlarda yaygın olarak kullanılmaktadır. Yapay zekâ öğrenebilen ve karar verebilen sistemlerdir. Makine öğrenmesi ise veriden bilgi çıkarımı yapan yapay zekânın bir alt koludur. Makine öğrenmesinde verilerden özellik çıkarımı yapılmalı ve algoritmaya verilmelidir ancak derin öğrenme de özellik çıkarımını sistem kendisi yapmaktadır. Derin öğrenme (DL), makine öğrenmesinin bir alt dalıdır.

DL kendi kendine öğrenebilen sistemlerdir. Genellikle nesne sınıflama ve tanımlamada kullanılmaktadır. Büyük verilerle çalışmak zordur ancak derin öğrenme ile bu mümkündür. DL’de sinir ağının eğitilmesi ve test edilmesi için veri miktarı önemlidir. Bundan dolayı bu tez çalışmasında kullanılan veri setindeki görseller çoğaltılmıştır. Derin öğrenmenin özellik çıkarımına gerek olmadan kendi içerisinde özellik çıkarımı yaparak sınıflandırma yapması avantajlarından dolayı bu çalışmada derin öğrenme tercih edilmiştir.

4.1. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (ESA), bir derin öğrenme mimarisidir. Aynı zamanda görüntü bölütleme ve sınıflandırma yapılabilen resim ve videolar üzerinde çalışan bir derin öğrenme algoritmasıdır. ESA resim veya videoyu girdi olarak alır ve nesneleri ayırt edebilir. Birbirine benzeyen görüntüleri kümeleyebilir ve görüntüleri sınıflandırabilir.

ESA'nın çalışma mantığına göre giriş olarak alınacak resim matris formatında olmalıdır. Resimlerden özellik çıkarımı yapılmaktadır ve aynı özellikler diğer görsellerde de aranmaktadır. Benzer resimler defalarca ağa tanıtılır ve ağın öğrenmesi sağlanır. ESA çeşitli mimariler kullanan ve birçok katmandan oluşan bir sınıflandırma algoritmasıdır.

4.1.1. Katmanlar

ESA'da giriş katmanı, evrişim katmanı, toplu normalleştirme katmanı, ReLu katmanı, havuzlama katmanı, düzleştirme katmanı, tam bağlantılı katman, softmax katmanı ve sınıflandırma katmanı yer almaktadır.


Giriş Katmanı: Bu katmanda görüntüler 3 kanallı RGB ya da tek kanallı siyah-beyaz olabilir. Bu tez çalışmasında kullanılan giriş verilerinin boyutu $200 \times 200 \times 3$ 'dür. 200×200 resim boyutunu, 3 ise renkli olduğunu ifade eder. Sinir ağını eğitebilmek için girdi olarak resim veya video verilmelidir.

Evrişim Katmanı: Bu katman evrişimli sinir ağının temelidir. Görüntüden özellik çıkarmak için çeşitli filtreler uygular. Bu filtrelerin boyutu görüntü boyutuna göre hesaplanmaktadır. Bu tez çalışmasında 11×11 , 10×10 ve 4×4 filtreler kullanılmıştır. Belirlenen filtre görüntünün sol üst köşesinden başlayarak sağa bir matris ilerleyerek kaydırılır. Satır bitince alt satıra geçilir ve aynı işlemler tekrarlanır. Filtre resim üzerinde gezdirilir. Tüm işlemler bitince çıktı matrisi oluşturulur. Birden fazla özelliği tespit etmek için daha fazla filtre kullanılır. Adım sayısı 1 olarak seçildiğinde filtre resim üzerinde dolaşma işlemini birer adım kayarak yapmaktadır. Özellik haritası orijinal resimden daha küçük boyuttadır bu nedenle dolgu kullanılır. Görüntünün boyutunu korumak için küçülen resmin dışındaki değerleri 0 yapar. Böylece görüntü eski boyutuna ulaşır.

Toplu Normalleştirme Katmanı:Bu katman girdileri yeniden ölçeklendirerek normalleştirme yapar. Sinir ağının daha hızlı ve daha kararlı sonuç vermesine yardımcı olur.

ReLu Katmanı: Rectified Linear Unit (ReLu) bir aktivasyon fonksiyonudur. Sinir ağlarında aktivasyon fonksiyonunun amacı giriş hızını çıkış hızına dönüştürmektir (Doorn, 2014).Sinir ağının eğitilmesinde diğerlerinden daha hızlı olduğu ReLu fonksiyonu kullanılmaktadır. ReLu fonksiyonu uygulandıktan sonra özellik haritasındaki siyah pikseller 0 yapılır. Böylece tüm negatif değerler ortadan kaldırılır.

Bir sinir ağında doğrusal, sigmoid, tanh ve ReLu aktivasyon fonksiyonları ile yapılan aktivasyon işlemi girişi normalleştirir ve sonraki katman için bir çıktı üretir. ReLu aktivasyon fonksiyonu diğerlerine göre daha hızlıdır ve daha çok tercih edilmektedir. Şekil 4.1.'deTanh, ReLu, Sigmoid ve Linear aktivasyon fonkiyonları görülmektedir.



Şekil 4.1. Aktivasyon fonksiyonları(Wiki, 2021)

Havuzlama Katmanı: Arka arkaya gelen evrişim katmanlarının arasına eklenmektedir. Bu katmanın amacı mevcut resmin özelliklerini kaybetmeden daha küçük boyuta dönüştürmektir. Burada da filtre belirlemede olduğu gibi bir pencere belirlenir. Bu pencere resim üzerinde soldan sağa doğru gezdirilir. En büyük sayıları içeren daha küçük çıktılar oluşturur. Böylece sinir ağının daha doğru karar vermesi

sağlanır. Maksimum havuzlama, ortalama havuzlama, L2-norm havuzlama şeklinde farklı algoritmalar bulunmaktadır. Bunlardan en çok kullanılanı maksimum havuzlamadır. Maksimum havuzlama belirli bir alandaki değerlerin maksimumunu alarak girdi olarak döndürmektedir. Maksimum havuzlamadan farklı olarak ortalama havuzlama girdi verilerinin ortalama değerini döndürür ve düşük değerler nedeniyle aktivasyonu düşürür(Doorn, 2014).

Düzleştirme Katmanı: Bu katmanın görevi son katmana eğitim için verileri hazırlamaktır. Girdileri tek boyutlu bir diziye çevirir.

Tam Bağlantılı Katman:Bu katman evrişimli sinir ağının son katmanıdır. En önemli katmandır. Düzleştirme katmanından verileri alır ve sinir ağına öğretir. Böylece eğitim başlamış olur.

Çıktının uzaysal boyutu girdi boyutunun bir fonksiyonu şeklindedir. Elde edilmek istenilen çıkış görüntüsünün büyüklüğüne göre filtre boyutu belirlenmektedir. Çıkış görüntüsünün büyüklüğü Eşitlik (4.1)'de verilen formül ile hesaplanmaktadır. Giriş görüntüsünün boyutu (W), filtre boyutu (F) adım sayısı (S), kullanılan dolgu miktarı (P) ile gösterilmektedir. P değeri sıfırdır. Amacımız çıkış görüntünün boyutunu 1x1'lik matris boyutuna getirmektir. Örneğin 64x64'lük bir giriş görüntüsüne, 5x5 filtre uygulanacak olsun. Adım sayısı (S) 1 ve dolgu miktarı (P) 0 alınırsa çıkış değeri 60x60 olur. Çıkış görüntüsünün boyutu 1x1'lik matris olana kadar bu işlemlere devam edilir. Evrişim katmanı için adım sayısı 1 ve havuzlama katmanı için ise adım sayısı 2 olarak alınır. (Wout= Çıkış görüntüsünün boyutu, Win= Giriş görüntüsünün boyutu, F= Filtre boyutu, P= Dolgu miktarı, S= Adım sayısı)

$$W_{out}=(W_{in}-F+2P)/S+1 \quad (4.1)$$


Softmax Katmanı: Son aşama olan sınıflandırma katmanı için gerekli olan katmandır. Softmax katmanı giriş verilerini sınıflandırmak için kullanılmaktadır(Zhang ve ark., 2016). Sınıflandırma yapılırken önceki katmandaki değeri alır ve yakın olduğu sınıfa göre yeni bir çıkış değeri üretir.

Sınıflandırma Katmanı:Bu katmanda sınıflandırma yapılmaktadır. Sınıflandırma katmanının çıkış değeri sınıf sayısına eşittir(İnik ve Ülker, 2017). Örneğin bu çalışmada normal ve pkos şeklinde iki sınıflandırma yapılacağı için çıkış değeri 2'dir.

4.1.2. Evrişimsel Sinir Ağının mimarileri


Literatürde çok sayıda derin öğrenme mimarisi vardır. Bu bölümde ESA'lar arasından önemli olarak kabul edilen mimarilerden bahsedilecektir.

ESA çok sayıda evrişim katmanı, tamamen bağlı katmanları ve havuzlama katmanlarını içerir. Basitçe bir ESA modelinde evrişim katmanı arka arkaya eklenir ve aralarına ReLU ve havuzlama katmanları eklenir. Bu kısımda görüntülerden çeşitli özellikler çıkarılır. Oluşturulan modelin son katmanı ise tam bağlantılı katmandır. Bu kısımda ağ eğitime başlanır ve sınıflandırma yapılır. Şekil 4.2.'de genel bir ESA yapısı görülmektedir.



Şekil 4.2. Genel bir ESA yapısı(Ergin, 2021)

LeNet, evrişimli sinir ağlarının ilk başarılı uygulamasıdır. Yann LeCun tarafından 1998 yılında geliştirilmiştir. Posta kodlarını, basit basamakları okumak için kullanılmıştır. LeNet mimarisi 7 katmandan oluşmaktadır. Giriş görüntüsü 32x32'lik matris şeklindedir(LeCun ve ark., 1998).




Şekil 4.3. LeNet mimarisi(LeCun ve ark., 1998)

C1 katmanı, 6 özellik haritasına sahip evrişimli katmandır ve 5x5'lik evrişim çekirdeğine sahiptir. Bu katman sonucunda 28x28 boyutunda özellik haritaları elde edilmiştir. C1 katmanı 156 adet eğitilebilir parametreye sahiptir. S2 katmanı, 14x14 matris boyutunda 6 özellik haritalasına sahip alt örnekleme katmanıdır. Her bir özellik haritası C1'deki 2x2'lik özellik haritasına bağlanmaktadır. S2 katmanı 12 adet eğitilebilir parametreye sahiptir. C3 katmanı, 16 özellik haritasına sahip evrişimli katmandır. Her bir özellik haritası S2'deki 5x5'lik özellik haritasına bağlanmaktadır. C3 katmanı 1516 adet eğitilebilir parametreye sahiptir. S4 katmanı, 5x5 boyutunda 16 özellik haritasına sahip alt örnekleme katmanıdır. Her bir özellik haritası C3'teki 2x2'lik özellik haritasına bağlanmaktadır. S4 katmanı 32 adet eğitilebilir parametreye sahiptir. C5 katmanı, 120 özellik haritasına sahip evrişimli katmandır. Her bir özellik haritası S4'teki 5x5'lik özellik haritasına bağlanmaktadır. C5 katmanının çıktısı 1x1 boyutundadır. C5 katmanı 48120 adet eğitilebilir parametreye sahiptir. F6 katmanı, 84 özellik haritasına sahiptir ve C5'e tamamen bağlıdır. Bu katman 10164 adet eğitilebilir parametreye sahiptir (LeCun ve ark., 1998).

AlexNet mimarisi Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından tasarlanmış bir CNN mimarisidir. Bu mimari makalenin ilk yazarı olan Alex Krizhevsky'in adını almıştır. 2012'de ImageNet ILSVRC'de sunulmuştur. AlexNet mimarisi 8 katmandan oluşmaktadır. Bunların ilk beşi evrişim katmanıdır ve aralarında maksimum havuzlama katmanında bulunmaktadır. Son üç katman ise tamamen bağlı katmanlardır. ReLu aktivasyon fonksiyonu kullanılmıştır. Alexnet mimarisi, 2015 ImageNet yarışmasının kazananı olmuştur ve diğer tüm CNN'lerden daha iyi performans göstermiştir(Krizhevsky ve ark., 2012)

AlexNet, LeNet mimarisine çok benzer bir yapıya sahiptir. Ancak AlexNet'te katman başına daha fazla filtre kullanılmıştır ve bu sayede ağ yapısı daha derindir. LeNet'te sigmoid fonksiyonu kullanılırken AlexNet'te ReLu fonksiyonu kullanılmıştır. LeNet'te ortalama havuzlama kullanılırken AlexNet'te ise maksimum havuzlama katmanı kullanılmıştır. Şekil 4.4.'te LeNet ve AlexNet mimarilerinin karşılaştırılması verilmiştir.



Şekil 4.4. LeNet ve AlexNet karşılaştırması(Wikipedia, 2021)

AlexNet mimarisinde toplam 5 evrişimli katman vardır ve ilk evrişimli katmanda 11x11'lik filtre uygulanmıştır. İkinci evrişimli katmanda 5x5'lik filtre ve sonraki evrişimli katmanlarda 3x3'lük filtre kullanılmıştır. Son üç katman ise tamamen bağlı katmandan oluşmaktadır. Aynı zamanda etkinleştirme için ReLu fonksiyonu kullanılmıştır (Krizhevsky ve ark., 2012). ReLu fonksiyonu daha basittir ve hesaplaması daha kolaydır.

GoogLeNet, 22 katmanlı bir evrişimli sinir ağı mimarisidir. İlk başta 7x7 ve 3x3 boyutlarında evrişimli katman yer alır. Sonraki katmanlardan 9'u başlangıç katmanıdır ve aralarında maksimum havuzlama katmanında bulunmaktadır. Ortalamahavuzlama katmanında tüm özellik haritalarının ortalaması alınır. 2014'te ImageNet ILSVRC'de sunulmuştur ve yarışmanın kazananı olmuştur. Bu mimarinin giriş katmanı 224x224 boyutunda görüntü alabilmektedir. Ağdaki parametrelerin sayısını azaltmak için ortalama havuzlama katmanları kullanılmıştır. Ağı eğitmeden ImageNet üzerinde eğitilmiş olan GoogLeNet ağı kullanılabilir (Szegedy ve ark., 2015). Şekil 4.5.'te GoogLeNet mimarisinin yapısı görülmektedir.



VGGNet mimarisi, Simonyan ve Zisserman tarafından geliştirilmiştir. ImageNet ILSVRC 2014 yarışmasının ikincisi olmuştur. Ağ derinliğinin sinir ağı için oldukça önemlidir. Bu ağda toplam 16 tane evrişimli katman bulunmaktadır. VGGNet mimarisi görüntüden özellik çıkarmada en çok kullanılan mimaridir(Szegedy ve ark., 2015).


Derin öğrenme ile sınıflandırma çalışmalarında bu ESA mimarileri kullanılabilir. Bu tez çalışmasında yukarıda bahsedilen mimariler yerine bu çalışma için katman ve eğitim ayarları yaparak oluşturduğumuz sinir ağı modeli kullanılmıştır. Sınıflandırma için segmente edilmemiş görüntüler ve segmente edilmiş görüntülerin sınıflandırma başarısı test edilmiştir.



5. MATERYAL VE YÖNTEM

Yumurtalık foliküllerinin sayısı ve büyüklüğünü tespit etmek uzmanlar için oldukça zahmetli ve zaman alıcı bir süreçtir. Bu tez çalışmasında folikül tanıma sürecini hızlandırmak için görüntü işleme ve evrişimli sinir ağları kullanılarak uygulamalar geliştirilmiştir.

Bu bölümde görüntülerin elde edilmesi, görüntü ön işleme aşamaları, segmentasyon, derin öğrenme ile sınıflandırma ile ilgili çalışmalardan bahsedilmiştir. Şekil 5.1.'de yumurtalık sınıflandırması için izlenecek olan blok diyagramı gösterilmiştir.



Şekil 5.1. Yumurtalık sınıflandırması için izlenecek olan blok diyagramı


Bu tez çalışması folikül tespiti ve sınıflandırma olmak üzere iki bölümden oluşmaktadır. İlk olarak görüntü işleme yöntemleri ile foliküllerin tespiti yapılmış ardından foliküllerin sayısına göre yumurtalıklar sınıflandırılmıştır.

5.1 Görüntü İşleme ile Folikül Tespiti

Sayısal görüntüler birer matris olarak nitelendirilebilir. Bu görüntüleri işleyebilmek için matrisler üzerinden işlem yapmak gerekmektedir. MATLAB programı matrislerle işlem yapabilmek için uygun bir programdır. Bu tez çalışmasında görüntü işleme için MATLAB yazılım programı kullanılmış, GUIDE ara yüzünde folikül tespiti için bir uygulama geliştirilmiştir.

Bu ara yüz sayesinde yazılan programa uygun bir uygulama tasarlanabilmektedir. Bu çalışma için tasarlanan uygulamanın genel görüntüsü Şekil

5.2.'de verilmiştir. Tasarlanan bu uygulamada folikül tespiti için görüntülere 10 farklı algoritma uygulanmaktadır.



Şekil 5.2. MATLAB GUIDE ara yüzünde geliştirilen uygulama

5.1.1. Görüntü elde etme

Bu tez çalışmasında Selçuk Üniversitesi Kadın Hastalıkları ve Doğum Anabilim dalından görüntü toplamak için öncelikle Selçuk Üniversitesi Tıp Fakültesi'nden etik kurul onayı alınmıştır. Ancak hastanenin Covid 19 pandemi hastanesi olması ve normal hasta kabulünün az olması nedeniyle veri toplamada sıkıntı yaşanmıştır. Bu nedenle Konya Özel Medicana Hastanesi'nden etik kurul onayı alınmış ancak ultrason cihazında yaşanan teknik sorunlar nedeni ile görüntü kaydı alınamamıştır. Yaşanan bu olumsuz durumlar çalışmamızı sınırlandırmış ve bizi hazır görüntü arayışına yöneltmiştir. Ancak literatürde bu amaçla hazırlanan bir veri seti bulunamamış ve kaynak makalelerde PKOS görüntüsü ile çalışan yazarlarla iletişime geçilmiş ve bir olumlu dönüş alınmıştır.


Çalışmada kullandığımız ultrason görüntüleri, Telkom Üniversitesi'nin halka açık web sitesinden elde edilmiştir. Veri seti uzman görüşü ile hazırlanan PKOS'lu ve

normal hastaların yumurtalık ultrason görüntülerini içermektedir. Bu verisetindeki görüntüler ultrason cihazından dikey prob ile elde edilmiştir. Veri setindeki yumurtalık ultrason görüntüleri normal ve PKOS olarak iki sınıfa ayrılmıştır. Tüm görüntüler 200x200x3 boyutundadır ve toplamda 54 görüntü bulunmaktadır. Görüntüler JPG formatındadır ve 40 normal - 14 PKOS olan hastadan elde edilmiştir. Veri setinden alınan görüntülerin %60'ı eğitim, %20'si değerlendirme ve %20'si test verisi olarak ayrılmıştır (Adiwijaya ve ark., 2021).

5.1.2. Ön işleme


Ultrason görüntülerini iyileştirmek ve gürültüleri en aza indirmek için görüntü üzerinde bazı işlemler yapılması gerekir. Bu işlemlere ön işleme aşaması denir. Ön işleme aşamalarında önemsiz detaylar silinir ve önemli bölgeler belirginleştirilir. Bu çalışmada ön işleme aşaması için iki yöntem kullanılmıştır. Şekil 5.3.'te birinci yöntem için ön işleme aşamasında yapılan işlemler blok diyagramı şeklinde verilmiştir.

Birinci yöntem



Şekil 5.3.Birinci yöntem için ön işleme aşaması blok diyagramı


Ön işleme aşamasında görüntüdeki gürültü ve parazitlerin kaldırılması için kullanılan filtre çok önemlidir. Bu tez çalışmasında gri seviyeye dönüştürülen görüntülere gürültüleri azaltmak için 4 farklı filtre (Ortanca Filtre, Ortalama Filtre, Gaussian Filtresi, Wiener Filtresi) uygulanmış ve bu filtrelerin etkileri karşılaştırılmıştır. Şekil 5.4.'te filtreleme işlemi sonucu elde edilen görüntüler sırasıyla verilmiştir.




Şekil 5.4. Filtreleme işlemleri sonucu elde edilen görüntüler (a) Ortanca Filtre çıkışı (b) Ortalama Filtre çıkışı (c) Gaussian Filtresi çıkışı (d) Wiener Filtresi çıkışı

Filtreleme işlemi tamamlanan görüntülere histogram eşitleme uygulandıktan sonra standart eşikleme ile ön planda koyulaştırma işlemi yapılmıştır. Foliküllere etiket tanımlamayı kolaylaştırmak adına görüntünün zıttı alınarak siyah kısımlar beyaz renge, beyaz kısımlar siyah renge çevrilmiştir. Beyaz hale gelen ikili görüntüde 0'lar arka planı 1'ler ise folikülleri ifade etmektedir. Bir sonraki aşamada görüntüleri netleştirmek ve gereksiz nesneleri silmek için morfoloji yöntemleri kullanılmıştır. Bu amaçla, öncelikle kistlerin ortalama boyutuna göre bir değer belirlenmiş daha sonra görüntüye aşındırma ve genişleme işlemleri sırasıyla uygulanmıştır. Aynı adımlar uyarlanabilir eşikleme için de tekrarlanmış ve sonuçlar iki yöntem için karşılaştırılmıştır. Şekil 5.5. ve Şekil 5.8. arasında uygulanan işlem çıkışlarına dair görseller görülmektedir.


(a) (b)



Şekil 5.5. Eşitlemeden öncesi ve sonrası(a) Orijinal görüntü (b) Histogram eşitlenmiş görüntü




Şekil 5.6. Orijinal görüntünün histogram grafiği





Şekil 5.7. Histogram eşitlenmiş görüntünün histogram grafiği

(a) (b)



(c) (d)






Şekil 5.8. Birinci yöntem için folikül tespitinde izlenen adımlar(a) Wiener filtresi çıkışı(b) Uyarlanabilir eşikleme sonucu oluşan görüntü (c) Zıttı alınan görüntü (d) Aşındırma sonucu oluşan görüntü (e) Açma sonucu oluşan görüntü (f) Genişletme sonucu oluşan görüntü

İkinci yöntem


Bu çalışmada folikül tespit amacıyla uygulanan ikinci yöntemde ise görüntüye Gaussian filtresi ve Ayrık DalgacıkDönüşümü (ADD) uygulanmıştır. Ardından k-ortalama kümeleme algoritması ile elde edilen yeni görüntü çeşitli morfolojik işlemlerden geçirilmiş ve sonuçtafiltrelerin etkileri karşılaştırılmıştır. Şekil 5.9.'da ikinci yöntemde kullanılan ön işleme aşamasında izlenen adımlar verilmiştir.



Şekil 5.9. İkinci yöntem için ön işleme aşaması blok diyagramı

Bu yöntemde siyah-beyaz olan ultrason görüntülerinde istenmeyen gürültüleri gidermek için kullanılan 5x5'lik Gaussian filtresi ve ADD sonuçları karşılaştırılmıştır. Gaussian filtresi gürültüleri gidermek için bulanıklaştırma yaparak resmi yumuşatmaktadır.Şekil 5.10.'da görüntüleretek seviyeli 2 boyutlu ADD uygulandıktan sonra oluşan yaklaşım katsayıları, yatay detay katsayıları, dikey detay katsayıları,


diyagonal detay katsayıları gösterilmiştir. Çalışmada dalgacık ailelerinden ortogonal dalgacık türü olan Haar dalgacık kullanılmıştır.



Şekil 5.10.2 Boyutlu ADD uygulandıktan sonra oluşan yaklaşım, yatay detay, dikey detay, diyagonal detay katsayıları

Gürültü filteleme işleminden sonra k-ortalama kümeleme algoritması ile 6 adet kümeleme işlemi gerçekleştirilmiştir. Şekil 5.11.'de k-ortalama kümeleme algoritması ile oluşturulan 6 küme görülmektedir.

Görüntüdeki renk dağınıklığını ve sayısını azaltmak için k-ortalama kümeleme algoritması uygulanmaktadır. Oluşturulan kümeler içerisinde siyah ve beyaz renklerin bir arada toplandığı küme önemlidir. Yerel minimumların önlenmesi için kümeleme 3 kez tekrarlanmıştır. Küme indeksleri ve küme merkezi konumu parametreleri ile en iyi küme oluşturulmaktadır.





Şekil 5.11. K-ortalama kümeleme algoritması ile 6 farklı kümeleme

Kümelemede seçilen görüntüye boşluk doldurma işlemi yapılarak foliküllerin içerisindeki siyahlıklar kaldırılmıştır. Böylece beyaz kısımlar yani foliküller belirgin hale gelmiştir. Daha sonra görüntüye sırasıyla aşındırma ve genişleme morfolojik işlemleri uygulanmıştır. Aşındırma işlemi etraftaki beyazlıkları yok ederek folikül olmayan kısımların folikül olarak algılanmasını önlemektedir. Genleşme işlemi ise beyaz kısımları genişleterek foliküllerin daha kolay algılanmasını sağlamaktadır. Şekil 5.12.' de ikinci yöntem için folikül tespitinde izlenen adımlara dair görseller verilmiştir.

(a)

(b)






Şekil 5.12. İkinci yöntem için folikül tespitinde izlenen adımlar (a) Gaussian filtre çıkışı (b) K-ortalama kümeleme sonucu (c) Boşluk doldurma (d) Aşındırma (e) Genleşme (f) Canny kenar bulma

5.1.3. Segmentasyon

Segmentasyon diğer adıyla görüntü bölütleme, bir görüntüyü çeşitli bölgelere ayırma işlemidir. Segmentasyon aşaması görüntü işlemede daha kolay analiz yapılabilmesi için önemli bir aşamadır. Bu aşamada amaç görüntüdeki nesnelerin arka plandan ayırt edilmesidir. Bu tez çalışmasında Canny kenar bulma algoritması kullanılmıştır. Bu algoritma ile foliküllerin kenarları algılanarak arka plan ve foliküller ayrıştırılmıştır. Öncelikle foliküller ön plan olarak alınmış ve görüntünün kalan kısımları arka plan olarak kabul edilmiştir. Foliküllerin olduğu tüm piksellere aynı etiketleme yapılmış ve arka planı oluşturan piksellere farklı etiketleme yapılmıştır. Böylece her piksel ait olduğu sınıfa göre etiketlenmiştir. Etiket sayısı uygulama üzerinde gösterilmektedir. Bu tez çalışmasında 10 farklı folikül tespiti algoritmasıyla folikül sayımı yapılmıştır. Şekil 5.13.'de birinci yöntem ve ikinci yöntem ile Canny kenar bulma uygulamasının sonuçları verilmiştir.




Şekil 5.13. Canny kenar bulması ile elde edilen sonuçlar (a) Birinci yöntem (b) İkinci yöntem

5.2. Derin Öğrenme ile Sınıflandırma

Derin öğrenme ile sınıflandırma medikal alanlarda son zamanlarda tercih edilen güncel ve gelişime açık bir işlemdir. Derin öğrenme uygulamalarında daha iyi sonuç alabilmek için büyük veri setlerine ihtiyaç vardır ve bu verileri toplamak zordur. Bu yüzden giriş görüntüleri döndürme, yeniden ölçeklendirme, yansıtma, histogram eşitleme, öteleme, gürültü ekleme gibi yöntemlerle çoğaltılmaktadır.

Bu çalışmada 54 adet ultrason görüntüsüne veri arttırımı uygulamak için döndürme, yatay ve dikey yansıtma, histogram eşitleme yöntemleri kullanılmıştır. Böylece elimizdeki mevcut görüntü sayısı beş kat artmış ve toplam giriş görüntüsü 270 olmuştur. Şekil 5.14.'te döndürme, yatay ve dikey yansıtma, histogram eşitleme yöntemleri ile çoğaltılmış verilere birkaç örnek gösterilmiştir.



Şekil 5.14. Döndürme, yatay ve dikey yansıtma, histogram eşitleme ile veri çoğaltma

Bu çalışmada derin öğrenme algoritmalarından ESA ile işlem görmemiş ham görüntüler ve segmente edilmiş görüntüler sınıflandırılmış ve her iki durum sonuçları karşılaştırılmıştır. Segmente edilmiş görüntülerin sınıflandırılmasında öncelikle foliküllerin yeri ve sayısı tespit edilmiştir. Veri seti eğitim, değerlendirme ve test şeklinde ayrılmıştır. İlk olarak bu verilerin sisteme yüklenmesi sağlanmış ardından ESA' nın katman ayarları yapılmıştır. Giriş katmanı, evrişimli katman, toplu normalleştirme katmanı, ReLu katmanı, maksimum havuzlama katmanı, Softmax katmanı, sınıflandırma katmanı kullanılmıştır. Görüntünün boyutuna göre $(W-F+2P)/S+1$ formülü kullanılarak katman özellikleri ayarlanmıştır. Burada W sayısı giriş görüntüsünün büyüklüğüdür ve 200x200 olarak kabul edilmektedir. Adım sayısı (S) evrişim katmanı için 1 ve havuzlama katmanı için 2 alınmıştır. P değeri sıfır olarak alınmalıdır. C1 katmanı için 11x11'lik filtre uygulanmıştır. C2, C3 ve C4 katmanları için 10x10'luk filtre uygulanmıştır. C5 katmanı için ise 4x4'lük filtre uygulanmıştır. P1, P2, P3, P4 katmanları için 2x2 boyutunda filtre kullanılmıştır. Tüm bu işlemler sonucunda girdi boyutu 1x1 olarak elde edilmiştir. Çizelge 5.1.' de sınıflandırma için oluşturulan ESA katmanlarının özellikleri verilmiştir.

Çizelge 5.1. Sınıflandırma için kullanılan ESA katmanlarının özellikleri

Katman Numaraları	Katman Adı	Katman Özellikleri
1	Giriş Katmanı	200x200x3
2	Evrişim Katmanı (C1)	Filtre: 11x11
3	ReLU Katmanı	
4	Havuzlama Katmanı (P1)	Filtre: 2x2
5	Evrişim Katmanı (C2)	Filtre: 10x10
6	ReLU Katmanı	
7	Havuzlama Katmanı (P2)	Filtre: 2x2
8	Evrişim Katmanı (C3)	Filtre: 10x10
9	ReLU Katmanı	
10	Havuzlama Katmanı (P3)	Filtre: 2x2
11	Evrişim Katmanı (C4)	Filtre: 10x10
12	ReLU Katmanı	
13	Havuzlama Katmanı (P4)	Filtre: 2x2
14	Evrişim Katmanı (C5)	Filtre: 4x4
15	ReLU Katmanı	
16	Tam Bağlı Katman	Çıkış büyüklüğü: 2
17	Softmax Katmanı	
18	Sınıflandırma Katmanı	

ESA katmanları ayarlandıktan sonra eğitim seçenekleri belirlenmiş ve ağ eğitilmiştir. Momentumlu stokastik gradyan inişi (sgdm) kullanılarak eğitime başlanmıştır. Öğrenme oranı 0.01 olarak belirlenmiş ve eğitim için maksimum iterasyon sayısı 32 olarak ayarlanmıştır. Öğrenme oranı deneme yanılma yöntemiyle belirlenmiştir. Değerlendirme ve test verileri dikkate alınarak ağ eğitilmiş ve iki sınıflandırma şekli için doğruluk oranları karşılaştırılmıştır. Çizelge 5.2.' de sınıflandırma için ESA eğitim seçenekleri verilmiştir.

Çizelge 5.2. ESA eğitim seçenekleri

Eğitim Seçenekleri	
Training options	SGDM
Initial Learn Rate	0.01
Max Epochs	32
Validation Data	imdsValidation
Validation Frequency	30
Verbose	False
ExecutionEnvironment	CPU

5.3. Performans Değerlendirme Ölçütleri

Bu çalışmada filtreleme, folikül tanıma ve sınıflandırma sonuçlarını değerlendirmek için literatürde en yaygın kullanılan ölçütler belirlenmiştir. Bu ölçütler ile performans değerlendirmesi yapılmıştır.

5.3.1. Filtreleme sonuçlarını değerlendirmede kullanılan ölçütler

Kullanılan filtrelerin performanslarını değerlendirmek amacıyla MSE (Ortalama Kare Hatası) ve PSNR (Pik Sinyal Gürültü Oranı) kullanılmıştır. Orijinal görüntü ile iyileştirilmiş görüntüler normalize edilerek karşılaştırılmıştır. MSE değeri ne kadar düşükse iki görüntü arasındaki benzerlik o kadar fazladır. Eşitlik 5.1’de MSE değerini hesaplamak için kullanılan formül verilmiştir. $M \times N$ görüntünün matris boyutunu vermektedir. I görüntünün orijinal hali, K ise gürültülü halidir.

$$MSE = \frac{1}{M \times N} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (5.1)$$

Filtreleme uygulamalarında görüntü kalitesinin ölçümü için PSNR kullanılmaktadır. (Hore ve Ziou, 2010) PSNR değeri ne kadar yüksek ise görüntü

kalitesi de o kadar iyidir. PSNR değeri düşük olduğu zaman görüntüler arasındaki fark çoktur. İyi filtrelenmiş bir görüntüde MSE değerinin yüksek, PSNR değerinin düşük olması istenir. Eşitlik 5.2’de PSNR değerini hesaplamak için gerekli formül verilmiştir. MAX_1 bir görüntüdeki pikselin alacağı maksimum değerdir.

$$PSNR = 10 \log_{10} \left(\frac{MAX_1^2}{MSE} \right) (5.2)$$

5.3.2. Folikül tanıma sonuçlarını değerlendirmede kullanılan ölçütler

Bu çalışmada folikül tespiti için yöntemlerin performanslarını değerlendirmek için Yanlış Kabul Oranı (FAR) ve Yanlış Reddetme Oranı (FRR) ölçütleri kullanılmıştır. FAR, folikül olmayan bölgelerin folikül olarak algılanması durumudur. FRR ise folikül olan bölgelerin folikül olarak algılanmaması durumudur. Uzman görüşü ve uygulanan yöntemlerden elde edilen sonuçlar karşılaştırılarak bu çalışma için en iyi folikül tanıma algoritması tespit edilmiştir.

5.3.3. Sınıflandırma sonuçlarını değerlendirmede kullanılan ölçütler

Bu çalışmada eğitilen ağın sınıflandırma başarısını değerlendirmek için literatürde önerilen değerlendirme ölçütleri kullanılmıştır

Doğru Pozitif (DP): Gerçek pozitiflerin sayısıdır. Bir durumun veya özelliğin varlığını gösteren test sonucudur.

Doğru Negatif (DN): Gerçek negatiflerin sayısıdır. Bir durumun veya özelliğin var olmadığını gösteren test sonucudur.

Yanlış Pozitif (YP): Yanlış pozitiflerin sayısıdır. Bir durumun veya özelliğin varlığını yanlış gösteren test sonucudur.

Yanlış Negatif (YN): Yanlış negatiflerin sayısıdır. Bir durumun veya özelliğin var olmadığını yanlış gösteren test sonucudur.

Doğruluk: Sınıflandırmanın başarı oranını ifade eder.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} (5.3)$$

Hassasiyet, Duyarlılık: Hasta olanlara karşı olan duyarlılığı ifade eder.

$$Hassasiyet = \frac{DP}{DP+YN}(5.4)$$

Kesinlik:Hasta olmayanlara karşı olan duyarlılığı ifade eder.

$$Kesinlik = \frac{DP}{DP+YP}(5.5)$$

F1:Duyarlılık ve kesinlik değerlerinin harmonik ortalamasıdır. F1 değeri ne kadar artarsa sınıflandırma başarısıda o kadar artmaktadır.

$$F1 == \frac{2DP}{2DP+YP+YN} \quad (5.6)$$

6. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında 2021 yılında halka açık yayınlanan 54 yumurtalık ultrason görüntüsüne sahip bir veri seti kullanılmıştır. Bu görüntüler veri artırma teknikleriyle çoğaltılmıştır. Yumurtalık ultrason görüntülerindeki foliküllerin tespiti için iki farklı yöntem geliştirilmiş ve toplamda 10 farklı algoritma denenmiştir. Birinci yöntemde ultrason görüntülerindeki gürültüleri etkili bir biçimde ortadan kaldıracak yöntemi geliştirmek için farklı filtreleme teknikleri denenmiştir. Çizelge 6.1.'de görüntüye uygulanan filtrelerin performans değerlendirmesi verilmiştir. Filtrelerin performans değerlendirmesinde ölçüt olarak MSE ve PSNR değerleri kullanılmıştır. Giriş ve çıkış görüntüleri normalize edilip MSE ve PSNR değerleri hesaplanmıştır. MSE ve PSNR değerlerinin ortalaması ve standart sapması ile filtrelerin performans değerlendirmesi yapılmıştır. Filtreler içinde en iyi sonucu $0,0223 \pm 0,009$ MSE ve $64,9797 \pm 1,8295$ PSNR değeri ile Gaussian filtresi vermiştir.

Çizelge 6.1. Kullanılan filtrelerin performans değerlendirmesi (Ortalama $\pm$ Standart Sapma)

	Ortanca Filtre	Ortalama Filtre	Gaussian Filtresi	Wiener Filtresi	ADD
MSE	$0,0623 \pm 0,0687$	$0,0611 \pm 0,0684$	$0,0223 \pm 0,009$	$0,0401 \pm 0,0135$	$0,0387 \pm 0,0137$
PSNR	$61,1645 \pm 1,6249$	$61,2213 \pm 1,5512$	$64,9797 \pm 1,8295$	$62,3464 \pm 1,5186$	$62,5598 \pm 1,7416$

Çizelge 6.2.'de bu tez çalışmasında test edilen yöntemlerin sonuçları ile uzman kişinin sonuçlarının karşılaştırılması verilmiştir. Çizelge 6.3.'de ise folikül tanıma başarı oranları FAR ve FRR ölçütleri ile birlikte verilmiştir. Bu çizelgeler incelendiğinde yüksek folikül tanıma başarı oranı %97,63 ile Wiener filtresi kullanılarak elde edilmiştir. Folikül tespitinde yüksek doğruluk sağladığından bu filtrenin önerilen yöntemler ile birlikte folikül tespiti çalışmalarında tercih edilebileceği düşünülmektedir. Birinci yöntem için standart eşikleme ve uyarlanabilir eşikleme karşılaştırıldığında uyarlanabilir eşiklemeden alınan sonuçların daha başarılı olduğu görülmüştür. Uyarlanabilir eşikleme ile folikül olmayan dış kısımdaki siyahlıklar dengelemiş ve foliküller daha belirginleşmiştir. Dolayısıyla uyarlanabilir eşiklemenin standart eşiklemeye göre daha iyi bir kontrast ayarı sağladığı sonucuna varılmıştır.

İkinci yöntem için de yine Çizelge 6.2. ve Çizelge 6.3. incelendiğinde %83,98 ile en yüksek folikül tanıma oranını Gaussian filtresi ve k-ortalama kümeleme yöntemi vermektedir. Gaussian filtresi, ADD'ye göre görüntüdeki gürültüleri daha iyi filtrelemektedir. Her iki yöntem için elde edilen sonuçlar, Yanlış Kabul Oranı (FAR) ve Yanlış Reddetme Oranı (FRR) kullanılarak tablolarda gösterilmiş ve sonuçlar değerlendirilmiştir. Çalışmada uygulanan 10 algorithmadan en yüksek folikül tanıma %97,63 başarı oranı ile Wiener filtresi ve uyarlanabilir eşikleme uygulanarak elde edilmiştir. Bu yöntem için FAR %33,45 ve FRR %1,61'dir.

Çizelge 6.2.Uzman görüşü ve önerilen yöntem ile folikül tespiti sonuçlarının karşılaştırılması

Uygulanan Yöntem	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Ortanca filtre ile histogram eşitleme ve standart eşikleme	381	541	182	359	199
Ortanca filtre ile uyarlanabilir eşikleme	381	522	370	152	11
Ortalama filtre ile histogram eşitleme ve standart eşikleme	381	553	185	368	196
Ortalama filtre ile uyarlanabilir eşikleme	381	568	368	200	13
Gaussian filtresi ile histogram eşitleme ve standart eşikleme	381	624	225	399	156
Gaussian filtresi ile uyarlanabilir eşikleme	381	409	361	48	20
Wiener filtresi ile histogram eşitleme ve standart eşikleme	381	561	178	383	203
Wiener filtresi ile uyarlanabilir eşikleme	381	559	372	187	9
Gaussian filtresi ile k-ortalama kümeleme	381	522	320	202	61
Ayrık Dalgacık Dönüşümü ile k-ortalama kümeleme	381	531	319	212	62

*Tip I hatası: Folikül olmayan bölgeler folikül olarak algılanır

**Tip II hatası: Folikül olan bölgeler folikül olarak algılanmaz

Çizelge 6.3.Folikül tanıma başarı oranları

Uygulanan Yöntem	Folikül Tanıma Başarısı	Tip I*Hatası (FAR)	Tip II** Hatası (FRR)
Ortanca filtre ile histogram eşitleme ve standart eşikleme	47,76	66,35	36,78
Ortanca filtre ile uyarlanabilir eşikleme	97,11	29,11	2,10
Ortalama filtre ile histogram eşitleme ve standart eşikleme	48,55	66,54	35,44
Ortalama filtre ile uyarlanabilir eşikleme	96,58	35,21	2,28
Gaussian filtresi ile histogram eşitleme ve standart eşikleme	59,05	63,94	25
Gaussian filtresi ile uyarlanabilir eşikleme	94,75	11,73	4,88
Wiener filtresi ile histogram eşitleme ve standart eşikleme	46,71	68,27	36,18
Wiener filtresi ile uyarlanabilir eşikleme	97,63	33,45	1,61
Gaussian filtresi ile k-ortalama kümeleme	83,98	38,69	11,68
Ayrık Dalgacık Dönüşümü ile k-ortalama kümeleme	83,72	39,92	11,67


*Tip I hatası: Folikül olmayan bölgeler folikül olarak algılanır

**Tip II hatası: Folikül olan bölgeler folikül olarak algılanmaz

Çalışmanın bir sonraki aşaması olarak segmente edilmiş ve edilmemiş görüntülerin ESA ile sınıflandırılması yapılmıştır. Sinir ağının başarısını artırmak için veri çoğaltma işlemi uygulanmıştır. Veri sayısı döndürme, yatay yansıtma, dikey yansıtma ve histogram eşikleme ile beş katına çıkarılmıştır. Folikül tespitinin ardından segmente edilmiş görüntüler kaydedilip yeni bir veri seti oluşturulmuştur. Kaydedilen veriler ile sinir ağı eğitilmiş ve yumurtalık ultrason görüntüleri “normal” ve “pkos” şeklinde sınıflandırılmıştır. Sınıflandırma için program 10 kez çalıştırılıp her bir değer kaydedilerek ortalaması sonuç olarak alınmıştır. Segmente edilmiş görüntülerle eğitilen ESA’nın değerlendirme verileri ile başarısı ortalama %77,81 olmuştur. Tasarlanan algoritma segmente edilmiş görüntülere uygulandığında hızı 5 dakika 4

saniyedir. Görüntülerin segmente edilmemiş, ham hali ile eğitilen ESA başarısı ortalama %65,81 olmuştur ve algoritmanın çalışma hızı 5 dakika 26 saniyedir.


Şekil 6.1., Şekil 6.2 ve Şekil 6.3.'te segmente edilmemiş ham görüntüler ile yapılan sınıflandırmanın grafiği ve karmaşıklık matrisi verilmiştir. Şekil 6.4., Şekil 6.5. ve Şekil 6.6.'da ise segmente edilmiş görüntüler ile yapılan sınıflandırmanın grafiği ve karmaşıklık matrisi verilmiştir. Bu karmaşıklık matrisindeki değerler kullanılarak sınıflandırma performans değerlendirme yapılmıştır.




Şekil 6.1. Segmente edilmemiş görüntüler için değerlendirme verileri ile sınıflandırma grafiği



Şekil 6.2. Segmente edilmemiş görüntüler için değerlendirme verileri ile karmaşıklık matrisi



Şekil 6.3. Segmente edilmemiş görüntüler için test verileri ile karmaşıklık matrisi



Şekil 6.4. Segmente edilmiş görüntüler için değerlendirme verileri ile sınıflandırma grafiği



Şekil 6.5. Segmente edilmiş görüntüler için değerlendirme verileri ile karmaşıklık matrisi



Şekil 6.6. Segmente edilmiş görüntüler için test verileri ile karmaşıklık matrisi

Çizelge 6.4.'te segmente edilmemiş görüntülerin sınıflandırma istatistikleri verilmiştir. Çizelge 6.5.'te ise segmente edilmiş görüntülerin sınıflandırma istatistikleri verilmiştir. Ağ önce eğitilmiş daha sonra hem değerlendirme verileriyle hem de test verileriyle sınıflandırma doğrulukları test edilmiştir. Segmente edilmemiş ham görüntülerde test verileriyle yapılan sınıflandırmanın başarısı %68,91 oranıyla değerlendirme verileriyle yapılandan daha iyi sonuç vermiştir. Segmente edilmiş görüntülerde ise değerlendirme verileriyle yapılan sınıflandırma %77,81 oranıyla test verileriyle yapılan sınıflandırmadan daha yüksek başarı sağlamıştır. Sınıflandırma performansını değerlendirmek için Hassasiyet, Duyarlılık, Kesinlik ve F1 parametreleri kullanılmıştır.

Çizelge 6.4.Segmente edilmemiş görüntülerin sınıflandırma istatistikleri

	Değerlendirme verileri ile elde edilen sonuçlar	Test verileri ile elde edilen sonuçlar
Doğruluk	65,81	68,91
Hassasiyet, Duyarlılık	74,75	83,25
Kesinlik	78,02	76,58
F1	74,78	78,01

Çizelge 6.5.Segmente edilmiş görüntülerin sınıflandırma istatistikleri

	Değerlendirme verileri ile elde edilen sonuçlar	Test verileri ile elde edilen sonuçlar
Doğruluk	77,81	72,36
Hassasiyet, Duyarlılık	94,45	90,25
Kesinlik	79,53	76,21
F1	86,22	82,60

7. SONUÇLAR VE ÖNERİLER

7.1 Sonuçlar

Literatürde yapılan çalışmalar incelendiğinde folikül tespiti ve yumurtalık ultrason görüntülerinin sınıflandırması için sınırlı sayıda çalışma olduğu görülmektedir. Bu çalışmalar incelendiğinde folikül tespitinin yüksek doğrulukla gerçekleştirilmesi için gürültü gidermede seçilen filtrenin önemli olduğu sonucu ortaya çıkmaktadır. Bu tez çalışması görüntü işleme ve sınıflandırma olmak üzere iki farklı başlık altında incelenebilir. Görüntü işlemede uygulanan filtrelerden $0,0223 \pm 0,009$ MSE ve $64,9797 \pm 1,8295$ PSNR değeri ile en iyi filtrelemeyi sağlayan Gaussian filtresi olmasına rağmen folikül sayısı tespitinde Wiener filtresi ve uyarlanabilir eşikleme ile %97,63 oranında yüksek bir doğruluk elde edilmiştir. Bu durum folikül tespitinde sadece seçilen filtrenin değil, doğru kombinasyon ile eşikleme işleminin gerçekleştirilmesinin önemini ortaya koymaktadır. Yumurtalık ultrason görüntülerinin sınıflandırmasını yapan çalışmalara bakıldığında çoğu çalışmada segmente edilmemiş görüntüler üzerinden sınıflandırma gerçekleştirildiği ya da segmentasyon işleminin ESA ile yapıldığı görülmektedir. Bu çalışmanın sınıflandırma aşamasında ise hem segmente edilmiş hem de segmente edilmemiş görüntüler ile uygulamalar gerçekleştirilmiştir. Sinir ağı eğitim verileri ile eğitildikten sonra değerlendirme verileri ve test verileri ile sınıflandırma başarısı karşılaştırılmıştır. Bu çalışmada segmente edilmiş görüntülerin sınıflandırmasından elde edilen başarı oranı %77,81'dir.

(Wisesty ve ark., 2018) 10 adet yumurtalık görüntüsü kullanarak bir folikül tespit etme çalışması gerçekleştirmişlerdir. Bu çalışmada standart eşikleme ve Otsu Eşikleme yöntemini karşılaştırmışlar, sobel filtresi kullanılarak görüntü bölütleme ve stereoloji yaklaşımı kullanılarak foliküllerin sayısı ve çapı hesaplamışlardır. Sonuçta Otsu eşik yönteminin daha iyi sonuç verdiğini belirtmişlerdir. Daha sonra (Adiwijaya ve ark., 2021) Wisesty ile birlikte 54 adet yumurtalık görüntüsü içeren veri setini yayınlamıştır. Tez çalışmasında folikül tespiti 54 görüntü içeren bu veri seti ile gerçekleştirilmiş, aynı zamanda sınıflandırma aşamasında kullanılmak üzere görüntü sayısı veri arttırımı teknikleri ile 270'e çıkarılmıştır.

Çizelge 7.1.'de literatürde yer alan folikül tespiti çalışmaları görülmektedir. (Wisesty ve ark., 2018) 10 yumurtalık görüntüsü kullanarak yaptıkları çalışma sonuçları ile bu tez çalışmasında 54 yumurtalık görüntüsü kullanılarak elde

edilen sonuçlar karşılaştırıldığında veri setinin büyüklüğünün artması folikül tespit başarı oranını arttırdığı görülmektedir. Aynı zamanda Wiener filtresinin uyarlanabilir eşikleme ile kombinasyonu bu görüntüler için folikül tespitinde oldukça başarılı olmuştur. Bunun yanında Çizelge 7.2.'de yumurtalık görüntüleri ile sınıflandırma yapan çalışmalara yer verilmiştir. Sonuçlar incelendiğinde kısıtlı yumurtalık görüntülerine veri artırımı uygulandığında ESA derin öğrenme modeli kullanılarak literatür ile uyumlu sınıflandırma sonucu elde edildiği görülmektedir.

Çizelge 7.1.Folikül tespiti yapan çalışmalar

Araştırma	Materyal ve Yöntem	Veri Setinin Büyüklüğü	Sonuçlar
(Wisesty ve ark., 2018)	Önişleme aşamasında standart eşikleme ve Otsu Eşikleme karşılaştırılmıştır. Sobel filtresi kullanılarak görüntü bölütleme ve stereoloji yaklaşımı kullanılarak foliküllerin sayısı ve çapı hesaplanmıştır. Otsu Eşik yöntemi daha iyi sonuçlar vermiştir.	10 yumurtalık Ultrason görüntüsü	Standart Eşikleme için Duyarlılık: %86 Otsu Eşikleme için Duyarlılık: %89
(Rao ve Kumar, 2019)	Gauss düşük geçiş filtresi ve KonturletDönüşümü'nü karşılaştırılmıştır. Segmentasyon için Canny, Sobel, Prewitt kenar algılama operatörlerinden en iyi sonucu Canny kenar algılama ile ulaşılmıştır.	50 yumurtalık ultrason görüntüsü	Gauss düşük geçiş için Doğruluk: %62,3 Konturlet dönüşümü için Doğruluk: %75,2
(Nazarudin ve ark., 2020)	Görüntü segmentasyonunda Watershed dönüşümü, bölgesel genişletme, kenar tabanlı yöntem, aktif kontur yöntemi, eşikleme yöntemi ve kümeleme yöntemini karşılaştırmıştır. En iyi folikül tanıma oranı %87.5 ile Canny kenar algılama olmuştur.	-	Folikül tanıma için Doğruluk: %87,5

Tez Çalışması	10 farklı algoritma ile folikül tespiti sonuçları karşılaştırılmış ve en iyi sonuca Wiener filtresi ile uyalanabilireşikleme sonucunda ulaşılmıştır.	54 yumurtalık Ultrason görüntüsü	Folikül tanıma için Doğruluk: %93,63
----------------------	--	-------------------------------------	--

Çizelge 7.2.Yumurtalık görüntüleri ile sınıflandırma yapan çalışmalar

Araştırma	Sonuçlar	Veri Setinin Büyüklüğü	Sınıflandırma
(Purnama ve ark., 2015)	Gabor dalgacık ile özellik çıkarımı yapılmıştır. Sinir Ağı-LVQ, KNN-öklid mesafesi ve SVM-RBF algoritmalarının sınıflandırması karşılaştırılmıştır.	60 normal yumurtalık 20 polikistik yumurtalık	Sinir Ağı-LVQ için Doğruluk: %74,63 KNN-öklid mesafesi için Doğruluk: %78,81 SVM-RBF için Doğruluk: %82.55
(Wisesty, 2016)	Gabor Dalgacık Yöntemi ile özellik çıkarımı yapılmıştır. Ultrason görüntüleri Destek Vektör Makineleri ile sınıflandırılmıştır.	17 normal yumurtalık 104 polikistik yumurtalık	Doğruluk: %75.5480
(Wisesty ve Nasri, 2016)	Gabor Dalgacık Yöntemi ile özellik çıkarımı yapılmıştır. Sınıflandırma için Levenberg-Marquardt optimizasyonu ve Eşlenik Gradyan- FletcherReeves yöntemleri test edilmiştir. LevenbergMarquardt daha yüksek doğruluk sağlamıştır ancak çalışma süresi daha uzundur.	-	LevenbergMarquardt Doğruluk: %93,92 Eşlenik Gradyan- FletcherReeves Doğruluk: %87,85
(Thufailah ve Wisesty, 2018)	PKOS'u tespit etmek için önce Gabor Dalgacık ile özellik çıkarımı yapılmıştır. Sınıflandırma için Destek Vektör Makinaları ve Elman Sinir Ağları karşılaştırılmıştır.	-	Destek Vektör Makinaları için Doğruluk: %83,6 Elman Sinir Ağı ile sınıflandırma için Doğruluk: %78,1

(Dewi ve Wisesty, 2018)	PKOS sınıflandırması için ultrason görüntülerinden Gabor Dalgacık Yöntemi ile özellik çıkarımı yapılmıştır. Sınıflandırma için Evrişimli Sinir Ağları kullanılmıştır.	-	Evrişimli Sinir Ağı için Doğruluk: %80,84
Tez Çalışması	Ham görüntüler ile segmente edilen, veri artırımı uygulanmışpkos ve normal yumurtalık görüntüleri ESA derin öğrenme modeli ile sınıflandırılmıştır.	200 normal yumurtalık 70 polikistik yumurtalık	Segmente edilmiş görüntüler için doğruluk: %77,81 Segmente edilmemiş görüntüler için doğruluk: %65,81

7.2. Öneriler

PKOS birçok kadının günlük yaşam kalitesini etkileyen önemli bir hastalıktır. Ancak literatürde bu hastalığın araştırılması ve folikül tespiti başarısının görüntü işleme yöntemleri ile ölçülmesi için yeterli veri seti bulunmamaktadır. Bu çalışmada hastanelerin Kadın hastalıkları ve doğum polikliniklerindenPKOS ve normal yumurtalık ultrason görüntüsü kaydedilerek literatürdeki veri seti açığı giderilmek istenmiş ancak 2019'da dünyada 2020 yılının Mart ayında ise ülkemizde başlayan Covid 19 salgını sebebiyle hastanelerin pandemi hastanesi olarak hizmet vermesinden dolayı tez çalışması için görüntü toplanamamıştır. Literatürdeki veri eksikliğini gidermek ve yumurtalıklarda folikül tespiti ile PKOS tanısınıningerçek zamanlı uygulamalarında başarı sağlamak aynı zamanda bir karar destek sistemi tasarlamak içinhastanelerden yumurtalık görüntüsü kaydedilip daha büyük veri setleri oluşturulabilir.

Bu çalışmada makine öğrenmesi algoritmaları yerine Evrişimsel derin öğrenme modeli tercih edilmiştir. Makine öğrenmesi modellerini test etmek için ön işleme tamamlanmış görüntülerden özellik çıkarma teknikleri ile görüntüleri en iyi temsil edecek özellikleri elde etmek gerekmektedir. Bu çalışma için foliküllerin çapı, birbirine uzaklığı, folikül sayısı gibi değerler yumurtalık görüntülerinden çıkarılacak özellikler olarak düşünülebilir. Derin öğrenme modelleri ise fazladan bir özellik çıkarım işlemine ihtiyaç duymadan, ham ya da segmente edilmiş görüntüleri sınıflayarak otomatik tanı sistemlerinde tercih edilebilecek özelliklere sahiptir. Bu sebeple bu çalışma için elde

ettiğimiz yumurtalık görüntüleri her ne kadar veri arttırımı teknikleri de uygulansa derin öğrenme modelleri için sınırlı kalmaktadır. Sonuç olarak daha fazla yumurtalık görüntüsü ile farklı derin öğrenme mimarileri denenerek bu çalışmada elde edilen sınıflandırma doğruluğu arttırılabilir ve otomatik bir tanı sistemi geliştirilebilir.



KAYNAKLAR

- Adiwijaya, NOVIA WISESTY, U. ve Astuti, W., 2021, Polycystic Ovary Ultrasound Images Dataset, Root.
- Asunción, M., Calvo, R. M., San Millán, J. L., Sancho, J., Avila, S. ve Escobar-Morreale, H. c. F., 2000, A prospective study of the prevalence of the polycystic ovary syndrome in unselected Caucasian women from Spain, *The Journal of Clinical Endocrinology & Metabolism*, 85 (7), 2434-2438.
- Azziz, R., Sanchez, L., Knochenhauer, E., Moran, C., Lazenby, J., Stephens, K., Taylor, K. ve Boots, L., 2004, Androgen excess in women: experience with over 1000 consecutive patients, *The Journal of Clinical Endocrinology & Metabolism*, 89 (2), 453-462.
- Azziz, R., Carmina, E., Dewailly, D., Diamanti-Kandarakis, E., Escobar-Morreale, H. F., Futterweit, W., Janssen, O. E., Legro, R. S., Norman, R. J. ve Taylor, A. E., 2009, The Androgen Excess and PCOS Society criteria for the polycystic ovary syndrome: the complete task force report, *Fertility and sterility*, 91 (2), 456-488.
- Balen, A. H., Laven, J. S., Tan, S. L. ve Dewailly, D., 2003, Ultrasound assessment of the polycystic ovary: international consensus definitions, *Human reproduction update*, 9 (6), 505-514.
- Battaglia, C., Artini, P. G., Genazzani, A., Gretnigni, R., Salvatori, M., Sgherzi, M., Giulini, S., Lombardo, M. ve Volpe, A., 1997, Color Doppler analysis in oligo- and amenorrheic women with polycystic ovary syndrome, *Gynecological Endocrinology*, 11 (2), 105-110.
- Broekmans, F., Knauff, E., Valkenburg, O., Laven, J., Eijkemans, M. ve Fauser, B., 2006, PCOS according to the Rotterdam consensus criteria: change in prevalence among WHO-II anovulation and association with metabolic factors, *BJOG: An International Journal of Obstetrics & Gynaecology*, 113 (10), 1210-1217.
- Brosnan, T. ve Sun, D.-W., 2004, Improving quality inspection of food products by computer vision—a review, *Journal of food engineering*, 61 (1), 3-16.
- Chervyakov, N., Lyakhov, P. ve Nagornov, N., 2018, Quantization noise of multilevel discrete wavelet transform filters in image processing, *Optoelectronics, Instrumentation and Data Processing*, 54 (6), 608-616.
- Dahlgren, E., Janson, P., Johansson, S., Lapidus, L. ve Oden, A., 1992, Polycystic ovary syndrome and risk for myocardial infarction: evaluated from a risk factor model based on a prospective population study of women, *Acta obstetrica et gynecologica Scandinavica*, 71 (8), 599-604.
- De Fauw, J., Ledsam, J. R., Romera-Paredes, B., Nikolov, S., Tomasev, N., Blackwell, S., Askham, H., Glorot, X., O'Donoghue, B. ve Visentin, D., 2018, Clinically

applicable deep learning for diagnosis and referral in retinal disease, *Nature medicine*, 24 (9), 1342-1350.

- Dewi, R. ve Wisesty, U., 2018, Classification of polycystic ovary based on ultrasound images using competitive neural network, *Journal of Physics: Conference Series*, 012005.
- Diamanti-Kandarakis, E., Kouli, C. R., Bergiele, A. T., Filandra, F. A., Tsianateli, T. C., Spina, G. G., Zapanti, E. D. ve Bartzis, M. I., 1999, A survey of the polycystic ovary syndrome in the Greek island of Lesbos: hormonal and metabolic profile, *The Journal of Clinical Endocrinology & Metabolism*, 84 (11), 4006-4011.
- Doorn, J. v., 2014, Analysis of Deep Convolutional Neural Network Architectures.
- Dumont, A., Robin, G., Catteau-Jonard, S. ve Dewailly, D., 2015, Role of Anti-Müllerian Hormone in pathophysiology, diagnosis and treatment of Polycystic Ovary Syndrome: a review, *Reproductive Biology and Endocrinology*, 13 (1), 1-10.
- Dunaif, A., Graf, M., Mandeli, J., Laumas, V. ve Dobrjansky, A., 1987, Characterization of groups of hyperandrogenic women with acanthosis nigricans, impaired glucose tolerance, and/or hyperinsulinemia, *The Journal of Clinical Endocrinology & Metabolism*, 65 (3), 499-507.
- Efford, N., 2000, Digital image processing: a practical introduction using java (with CD-ROM), Addison-Wesley Longman Publishing Co., Inc., p.
- Ehrmann, D. A., Barnes, R. B., Rosenfield, R. L., Cavaghan, M. K. ve Imperial, J., 1999, Prevalence of impaired glucose tolerance and diabetes in women with polycystic ovary syndrome, *Diabetes care*, 22 (1), 141-146.
- Ergin, T., 2021, Convolutional Neural Network
<https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>: [Ziyaret Tarihi: 25 Mayıs 2021].
- ESHRE, T. R. ve Group, A.-S. P. C. W., 2004, Revised 2003 consensus on diagnostic criteria and long-term health risks related to polycystic ovary syndrome (PCOS), *Human Reproduction*, 19 (1), 41-47.
- FAUSER, B. C., PACHE, T. D., LAMBERTS, S. W., HOP, W. C., DE JONG, F. H. ve DAHL, K. D., 1991, Serum bioactive and immunoreactive luteinizing hormone and follicle-stimulating hormone levels in women with cycle abnormalities, with or without polycystic ovarian disease, *The Journal of Clinical Endocrinology & Metabolism*, 73 (4), 811-817.
- Friedman-Berg, F., Allendoerfer, K. ve Pai, S., 2008, Moving toward an air traffic control display standard: Creating a standardized color palette for terminal situation displays.

- Gonzalez, A., Abril, E., Roca, A., Aragón, M. J., Figueroa, M. J., Velarde, P., Ruiz, R. o., Favez, O., Galán, J. J. ve Herreros, J. A., 2003, Specific CAPN10 gene haplotypes influence the clinical profile of polycystic ovary patients, *The Journal of Clinical Endocrinology & Metabolism*, 88 (11), 5529-5536.
- Gonzalez, R. C. ve Woods, R. E., 2006, Digital Image Processing-Third Edition, p. 23-879.
- Gougeon, A. ve Lefèvre, B., 1983, Evolution of the diameters of the largest healthy and atretic follicles during the human menstrual cycle, *Reproduction*, 69 (2), 497-502.
- Gougeon, A., 2004, Dynamics of human follicular growth: morphologic, dynamic, and functional aspects. *Ovary* (2004) 2: 25–43. doi: 10.1016, B978-012444562-8/50003-3.
- Govind, A., Obhrai, M. ve Clayton, R., 1999, Polycystic ovaries are inherited as an autosomal dominant trait: analysis of 29 polycystic ovary syndrome and 10 control families, *The Journal of Clinical Endocrinology & Metabolism*, 84 (1), 38-43.
- Gupta, G., 2011, Algorithm for image processing using improved median filter and comparison of mean, median and improved median filter, *International Journal of Soft Computing and Engineering (IJSCE)*, 1 (5), 304-311.
- Hahn, S., Tan, S., Elsenbruch, S., Quadbeck, B., Herrmann, B., Mann, K. ve Janssen, O., 2005, Clinical and biochemical characterization of women with polycystic ovary syndrome in North Rhine-Westphalia, *Hormone and Metabolic Research*, 37 (07), 438-444.
- Hiremath, P. ve Tegnoor, J. R., 2010, Automatic detection of follicles in ultrasound images of ovaries using edge based method, *IJCA, Special Issue on RTIPPR*, 2, 120-125.
- Hiremath, P. ve Tegnoor, J. R., 2013, Follicle detection and ovarian classification in digital ultrasound images of ovaries, *Advancements and breakthroughs in ultrasound imaging*, 5, 167-199.
- Hore, A. ve Ziou, D., 2010, Image quality metrics: PSNR vs. SSIM, *2010 20th international conference on pattern recognition*, 2366-2369.
- Huang, A., Brennan, K. ve Azziz, R., 2010, Prevalence of hyperandrogenemia in the polycystic ovary syndrome diagnosed by the National Institutes of Health 1990 criteria, *Fertility and sterility*, 93 (6), 1938-1941.
- İnik, Ö. ve Ülker, E., 2017, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6 (3), 85-104.

- İnik, Ö., Ceyhan, A., Balcıoğlu, E. ve Ülker, E., 2019, A new method for automatic counting of ovarian follicles on whole slide histological images based on convolutional neural network, *Computers in biology and medicine*, 112, 103350.
- Jensen, J. A., 2007, Medical ultrasound imaging, *Progress in biophysics and molecular biology*, 93 (1-3), 153-165.
- Khan, S. S. ve Ahmad, A., 2004, Cluster center initialization algorithm for K-means clustering, *Pattern recognition letters*, 25 (11), 1293-1302.
- Kiruthika, V. ve Ramya, M., 2014, Automatic segmentation of ovarian follicle using K-means clustering, *2014 fifth international conference on signal and image processing*, 137-141.
- Knochenhauer, E., Key, T., Kahsar-Miller, M., Waggoner, W., Boots, L. ve Azziz, R., 1998, Prevalence of the polycystic ovary syndrome in unselected black and white women of the southeastern United States: a prospective study, *The Journal of Clinical Endocrinology & Metabolism*, 83 (9), 3078-3082.
- Krishna, B. V. ve Kaliaperumal, B., 2013, Image pattern recognition technique for the classification of multiple power quality disturbances, *Turkish Journal of Electrical Engineering and Computer Science*, 21 (3), 656-678.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012, Imagenet classification with deep convolutional neural networks, *Advances in neural information processing systems*, 25, 1097-1105.
- Lane, D. E., 2006, Polycystic ovary syndrome and its differential diagnosis, *Obstetrical & gynecological survey*, 61 (2), 125-135.
- Lawrence, M. J., Eramian, M. G., Pierson, R. A. ve Neufeld, E., 2007, Computer assisted detection of polycystic ovary morphology in ultrasound images, *Fourth Canadian Conference on Computer and Robot Vision (CRV'07)*, 105-112.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998, Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86 (11), 2278-2324.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015, Deep learning, *nature*, 521 (7553), 436-444.
- Legro, R. S., Driscoll, D., Strauss, J. F., Fox, J. ve Dunaif, A., 1998, Evidence for a genetic basis for hyperandrogenemia in polycystic ovary syndrome, *Proceedings of the National Academy of Sciences*, 95 (25), 14956-14960.
- Legro, R. S., Kunesman, A. R., Dodson, W. C. ve Dunaif, A., 1999, Prevalence and predictors of risk for type 2 diabetes mellitus and impaired glucose tolerance in polycystic ovary syndrome: a prospective, controlled study in 254 affected women, *The Journal of Clinical Endocrinology & Metabolism*, 84 (1), 165-169.

- Li, Y., Wu, Z. ve Radke, R. J., 2015, Multi-shot re-identification with random-projection-based random forests, *2015 IEEE Winter Conference on Applications of Computer Vision*, 373-380.
- Liu, S., Liu, S., Cai, W., Pujol, S., Kikinis, R. ve Feng, D., 2014, Early diagnosis of Alzheimer's disease with deep learning, *2014 IEEE 11th international symposium on biomedical imaging (ISBI)*, 1015-1018.
- Lujan, M. E., Chizen, D. R. ve Pierson, R. A., 2008, Diagnostic criteria for polycystic ovary syndrome: pitfalls and controversies, *Journal of obstetrics and gynaecology Canada*, 30 (8), 671-679.
- Lunde, O., Magnus, P., Sandvik, L. ve Høglo, S., 1989, Familial clustering in the polycystic ovarian syndrome, *Gynecologic and obstetric investigation*, 28 (1), 23-30.
- Nazarudin, A., Zulkarnain, N., Hussain, A., Mokri, S. ve Nordin, I., 2020, Review on automated follicle identification for polycystic ovarian syndrome, *Bulletin of Electrical Engineering and Informatics*, 9 (2), 588-593.
- Oh, S. L., Ng, E. Y., San Tan, R. ve Acharya, U. R., 2018, Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats, *Computers in biology and medicine*, 102, 278-287.
- Pache, T., Wladimiroff, J., Hop, W. ve Fauser, B., 1992, How to discriminate between normal and polycystic ovaries: transvaginal US study, *Radiology*, 183 (2), 421-423.
- Padmapriya, B. ve Kesavamurthy, T., 2016, Detection of follicles in poly cystic ovarian syndrome in ultrasound images using morphological operations, *Journal of Medical Imaging and Health Informatics*, 6 (1), 240-243.
- Petrou, M. M. ve Petrou, C., 2010, Image processing: the fundamentals, John Wiley & Sons, p.
- Pfeifer, S. M., 2005, Polycystic ovary syndrome in adolescent girls, *Seminars in Pediatric Surgery*, 14 (2), 111-117.
- Philip, K. M., Kandasamy, K., Sundaram, R. S. ve Ramanathan, S., 2007, A Review On Polycystic Ovarian Syndrome And Its Relation With The Metabolic Syndrome, *International Journal of Pharmaceutical Science and Health Care*, 2 (7), 84-90.
- Pratt, W. K., 2007, Digital Image Processing: PIKS Scientific inside, 245-678.
- Purnama, B., Wisesti, U. N., Nhita, F., Gayatri, A. ve Mutiah, T., 2015, A classification of polycystic Ovary Syndrome based on follicle detection of ultrasound images, *2015 3rd International Conference on Information and Communication Technology (ICoICT)*, 396-401.

- Rao, M. J. ve Kumar, D. R. K., 2019, Follicle Detection in Digital Ultrasound Images using Adaptive K-means Clustering Algorithm, *International Journal of Applied Engineering Research ISSN 0973-4562 Volume 14, Number 2*, 397-403.
- Russ, J. C., 2006, The image processing handbook, CRC press, p.
- Schmidhuber, J., 2015, Deep learning in neural networks: An overview, *Neural networks*, 61, 85-117.
- Shi, X., Cheng, H.-D., Hu, L., Ju, W. ve Tian, J., 2010, Detection and classification of masses in breast ultrasound images, *Digital signal processing*, 20 (3), 824-836.
- Soille, P., 2013, Morphological image analysis: principles and applications, Springer Science & Business Media, p.
- Soni, P. ve Vashisht, S., 2019, Image segmentation for detecting polycystic ovarian disease using deep neural networks, *International Journal of Computer Sciences and Engineering Open Access*, 7.
- Sonigo, C., Jankowski, S., Yoo, O., Trassard, O., Bousquet, N., Grynberg, M., Beau, I. ve Binart, N., 2018, High-throughput ovarian follicle counting by an innovative deep learning approach, *Scientific reports*, 8 (1), 1-9.
- Sun, D.-W., 2016, Computer vision technology for food quality evaluation, Academic Press, p.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015, Going deeper with convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9.
- Taylor, A. E., McCourt, B., Martin, K. A., Anderson, E. J., Adams, J. M., Schoenfeld, D. ve Hall, J. E., 1997, Determinants of abnormal gonadotropin secretion in clinically defined women with polycystic ovary syndrome, *The Journal of Clinical Endocrinology & Metabolism*, 82 (7), 2248-2256.
- Thufailah, I. ve Wisesty, U., 2018, An implementation of Elman neural network for polycystic ovary classification based on ultrasound images, *Journal of Physics: Conference Series*, 012016.
- Tukey, J. W., 1977, Exploratory data analysis, Reading, Mass., p.
- Wiki, A. I., 2021, Activation Function, <https://docs.paperspace.com/machine-learning/wiki/activation-function#activation-function-types>: [Ziyaret Tarihi: 12 Nisan 2021].
- Wikipedia, 2021, AlexNet, <https://en.wikipedia.org/wiki/AlexNet>: [Ziyaret Tarihi: 28 Mayıs 2021].

- Wild, S., Pierpoint, T., McKeigue, P. ve Jacobs, H., 2000, Cardiovascular disease in women with polycystic ovary syndrome at long-term follow-up: a retrospective cohort study, *Clinical endocrinology*, 52 (5), 595-600.
- Wisesty, U. N., 2016, Implementasi Gabor Wavelet dan Support Vector Machine pada Deteksi Polycystic Ovary (PCO) Berdasarkan Citra Ultrasonografi, *Indonesian Journal on Computing (Indo-JC)*, 1 (2), 67-82.
- Wisesty, U. N. ve Nasri, J., 2016, Modified backpropagation algorithm for polycystic ovary syndrome detection based on ultrasound images, *International Conference on Soft Computing and Data Mining*, 141-151.
- Wisesty, U. N., Thufailah, I. F., Dewi, R. M., Adiwijaya ve Jondri, 2018, Study of Segmentation Technique and Stereology to Detect PCO Follicles on USG Images, *Journal of Computer Science*, 14, 351-359.
- Wood, J. R., Dumesic, D. A., Abbott, D. H. ve Strauss III, J. F., 2007, Molecular abnormalities in oocytes from women with polycystic ovary syndrome revealed by microarray analysis, *The Journal of Clinical Endocrinology & Metabolism*, 92 (2), 705-713.
- Zawadzski, J., 1992, Diagnostic criteria for polycystic ovary syndrome: towards a rational approach, *Polycystic ovary syndrome*, 39-50.
- Zeng, T. ve Liu, J., 2019, Automatic detection of follicle ultrasound images based on improved Faster R-CNN, *Journal of Physics: Conference Series*, 042112.
- Zhang, Y., Zhang, E. ve Chen, W., 2016, Deep neural network for halftone image classification based on sparse auto-encoder, *Engineering Applications of Artificial Intelligence*, 50, 245-255.
- Zhu, Y. ve Huang, C., 2012, An improved median filtering algorithm for image noise reduction, *Physics Procedia*, 25, 609-616.

EKLER

EK-1 FİLTRELEME PERFORMANSLARININ MSE PARAMETRESİ İLE DEĞERLENDİRİLMESİ

TEST VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_4	0,0471	0,0503	0,0214	0,0472	0,04
normal_8	0,0372	0,0353	0,0206	0,0282	0,0351
normal_11	0,0857	0,0725	0,0178	0,0394	0,0238
normal_16	0,0505	0,0357	0,0114	0,037	0,019
normal_22	0,0629	0,034	0,0101	0,0282	0,0535
normal_28	0,0772	0,0572	0,03	0,0457	0,0577
normal_34	0,0496	0,0546	0,0253	0,0527	0,054
normal_36	0,0514	0,0508	0,0233	0,0424	0,0454
pco_10	0,0301	0,0275	0,0128	0,025	0,0303
pco_11	0,0828	0,0717	0,027	0,0681	0,0301
pco_13	0,0692	0,0665	0,0433	0,0468	0,0335

EĞİTİM VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_1	0,0241	0,0232	0,0132	0,0183	0,0177
normal_3	0,07	0,0615	0,0251	0,0408	0,0391
normal_5	0,0766	0,0705	0,0376	0,058	0,0655
normal_7	0,0461	0,043	0,0142	0,0245	0,049
normal_9	0,0827	0,1042	0,0314	0,0382	0,0302
normal_12	0,0394	0,0479	0,0243	0,0328	0,0282
normal_13	0,0687	0,0621	0,0242	0,0541	0,0232
normal_14	0,0756	0,0653	0,0218	0,0563	0,0638
normal_15	0,061	0,0687	0,0272	0,0337	0,0375
normal_17	0,0163	0,0178	0,0072	0,0127	0,0084
normal_19	0,0369	0,0398	0,0163	0,0306	0,0303
normal_20	0,0509	0,0514	0,0206	0,0476	0,0418
normal_23	0,0382	0,0398	0,0201	0,0288	0,0251
normal_24	0,0582	0,537	0,0236	0,0413	0,0465
normal_26	0,036	0,0352	0,0162	0,0292	0,0335
normal_27	0,0603	0,058	0,0292	0,0513	0,0457
normal_29	0,039	0,0403	0,0205	0,0271	0,0315
normal_30	0,0618	0,0614	0,0231	0,0576	0,0527
normal_32	0,0502	0,0396	0,0208	0,0356	0,0347

normal_33	0,0462	0,0508	0,018	0,0385	0,0467
normal_35	0,533	0,0556	0,0155	0,0435	0,063
normal_37	0,1023	0,094	0,0292	0,0335	0,0241
normal_39	0,0458	0,053	0,0239	0,0515	0,0488
normal_40	0,0396	0,043	0,018	0,0293	0,0321
pco_2	0,0384	0,0367	0,0171	0,0256	0,0218
pco_3	0,0289	0,0307	0,0172	0,0246	0,0207
pco_5	0,0788	0,0689	0,0274	0,0554	0,039
pco_6	0,0412	0,0425	0,0181	0,0372	0,0448
pco_8	0,0861	0,0925	0,0306	0,0528	0,0632
pco_9	0,0368	0,0486	0,0162	0,0401	0,0449
pco_12	0,0649	0,0669	0,0358	0,0565	0,0416
pco_14	0,0472	0,0465	0,025	0,0404	0,0356

DEĞERLENDİRME VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_2	0,0542	0,0613	0,023	0,0467	0,0534
normal_6	0,041	0,0427	0,0207	0,0278	0,0359
normal_10	0,0314	0,0416	0,0116	0,0277	0,0312
normal_18	0,0899	0,0855	0,0531	0,0814	0,0693
normal_21	0,0468	0,0495	0,0283	0,0461	0,0511
normal_25	0,0386	0,0339	0,0097	0,0289	0,0199
normal_31	0,0344	0,041	0,0141	0,0317	0,0222
normal_38	0,0763	0,0822	0,0446	0,0675	0,0467
pco_1	0,0309	0,0279	0,0105	0,027	0,03
pco_4	0,0349	0,0349	0,0171	0,0285	0,0416
pco_7	0,0458	0,0469	0,0203	0,0453	0,036

EK-2 FİLTRELEME PERFORMANSLARININ PSNR PARAMETRESİ İLE DEĞERLENDİRİLMESİ

TEST VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_4	61,3983	61,1173	64,8267	61,3937	62,1102
normal_8	62,4254	62,6531	64,9869	63,6322	62,6777
normal_11	58,7997	59,5274	65,6266	62,1758	64,3559
normal_16	61,0957	62,6072	67,5808	62,4459	65,3547
normal_22	60,1426	62,816	68,0769	63,6206	60,8473
normal_28	59,2532	60,5587	63,356	61,5293	60,5209
normal_34	61,1738	60,7609	64,1082	60,9106	60,8089
normal_36	61,0254	61,0722	64,4619	61,852	61,565
pco_10	63,3524	63,7414	67,0587	64,1514	63,3164
pco_11	58,9531	59,5726	63,8212	59,8009	63,3451
pco_13	59,7297	59,9042	61,7634	61,426	62,8771

EĞİTİM VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_1	64,3016	64,4712	66,9333	65,5122	65,6634
normal_3	59,6814	60,2403	64,1254	62,0189	62,2118
normal_5	59,2899	59,6474	62,376	60,4984	59,97
normal_7	61,4985	61,7936	66,6003	64,2436	61,2266
normal_9	58,9531	57,9511	63,1546	62,3102	63,3307
normal_12	62,1814	61,3274	64,2747	62,9654	63,6206
normal_13	59,7628	60,1999	64,2971	60,8028	64,4806
normal_14	59,3456	59,98	64,7512	60,6276	60,0826
normal_15	60,2775	59,7612	63,7891	62,8545	62,3934
normal_17	66,0156	65,6266	69,5424	67,0928	68,901
normal_19	62,4547	62,132	66,0223	63,2771	63,3128
normal_20	61,0615	61,0212	64,9974	61,3502	61,9164
normal_23	62,3073	62,132	65,1042	63,5369	64,1427
normal_24	60,4797	60,827	64,4109	61,9766	61,4516
normal_26	62,5618	62,6654	66,0424	63,477	62,8868
normal_27	60,3294	60,5003	63,4695	61,0317	61,5293
normal_29	62,2202	62,0751	65,008	63,7971	63,1511
normal_30	60,2192	60,2456	64,49	60,5247	60,9127
normal_32	61,1216	62,1539	64,9606	62,6133	62,7306
normal_33	61,4867	61,07	65,5781	62,2762	61,44
normal_35	60,8656	60,682	66,2135	61,7459	60,134
normal_37	58,031	58,4007	63,4733	62,8771	64,3016

normal_39	61,5269	60,888	64,3423	61,0106	61,2422
normal_40	62,1484	61,7961	65,566	63,4658	63,059
pco_2	62,2875	62,4841	65,8136	64,0442	64,7512
pco_3	63,5293	63,2665	65,7818	64,2126	64,9763
pco_5	59,1683	59,7502	63,7493	60,6977	62,2229
pco_6	61,9818	61,844	65,542	62,4312	61,6204
pco_8	58,7795	58,4694	63,27	60,9065	60,1236
pco_9	62,4753	61,2689	66,029	62,0967	61,6035
pco_12	60,0117	59,8749	62,592	60,6084	61,9347
pco_14	61,3937	61,4563	64,1514	62,067	62,6133

DEĞERLENDİRME VERİLERİ

Görsel Adı	Ortanca Filtre	Ortalama Filtre	Gaussian Filtre	Wiener Filtre	ADD
normal_2	60,7928	60,2562	64,5041	61,4376	60,8574
normal_6	62,003	61,8291	64,9816	63,6943	62,5829
normal_10	63,1684	61,9425	67,4769	63,7139	63,1962
normal_18	58,5932	58,8124	60,8778	59,0246	59,7219
normal_21	61,4307	61,1891	63,6168	61,4985	61,0466
normal_25	62,2621	62,8224	68,2743	63,5218	65,1368
normal_31	62,7652	62,003	66,6463	63,1202	64,6722
normal_38	59,3056	58,9834	61,635	59,8346	61,4353
pco_1	63,2383	63,667	67,9293	63,8252	63,356
pco_4	62,7025	62,7025	65,7945	63,5824	61,9347
pco_7	61,5269	61,4144	65,0505	61,5674	62,5738

EK-3UZMAN KİŞİ TARAFINDAN MANUEL OLARAK YAPILAN FOLİKÜL TESPİTİ

TEST VERİLERİ

Görsel Adı	Folikül Sayısı
normal_4	4
normal_8	6
normal_11	6
normal_16	7
normal_22	6
normal_28	9
normal_34	6
normal_36	5
pco_10	14
pco_11	10
pco_13	12

EĞİTİM VERİLERİ

Görsel Adı	Folikül Sayısı
normal_1	5
normal_3	4
normal_5	3
normal_7	5
normal_9	7
normal_12	6
normal_13	3
normal_14	7
normal_15	2
normal_17	5
normal_19	9
normal_20	6
normal_23	5
normal_24	7
normal_26	8
normal_27	6
normal_29	6
normal_30	6
normal_32	6
normal_33	3
normal_35	4
normal_37	3
normal_39	6
normal_40	5

pco_2	15
pco_3	12
pco_5	14
pco_6	10
pco_8	12
pco_9	15
pco_12	11
pco_14	10

DEĞERLENDİRME VERİLERİ

Görsel Adı	Folikül Sayısı
normal_2	9
normal_6	6
normal_10	5
normal_18	6
normal_21	6
normal_25	7
normal_31	7
normal_38	4
pco_1	10
pco_4	10
pco_7	10

EK-4ORTANCA FİLTRE VE HİSTOGRAM EŞİTLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	10	2	8	2
Normal_8	6	13	3	10	3
Normal_11	6	11	3	8	3
Normal_16	7	10	4	6	3
Normal_22	6	10	5	5	1
Normal_28	9	4	2	2	7
Normal_34	6	10	2	8	4
Normal_36	5	7	3	4	2
Pco_10	14	12	6	6	8
Pco_11	10	16	7	9	3
Pco_13	12	11	5	6	7

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	11	5	6	0
Normal_3	4	10	1	9	3
Normal_5	3	10	1	9	2
Normal_7	5	8	2	6	3
Normal_9	7	9	2	7	5
Normal_12	6	8	3	5	3
Normal_13	3	7	2	5	1
Normal_14	7	7	2	5	5
Normal_15	2	12	1	11	1
Normal_17	5	10	3	7	2
Normal_19	9	7	3	4	6
Normal_20	6	6	1	5	5
Normal_23	5	12	3	9	2
Normal_24	7	7	1	6	6
Normal_26	8	12	4	8	4
Normal_27	6	8	5	3	1
Normal_29	6	12	4	8	2
Normal_30	6	4	1	3	5
Normal_32	6	13	3	10	3
Normal_33	3	8	1	7	2
Normal_35	4	12	2	10	2
Normal_37	3	9	1	8	2

Normal_39	6	6	3	3	3
Normal_40	5	14	5	9	0
Pco_2	15	19	11	8	4
Pco_3	12	12	6	6	6
Pco_5	14	20	11	9	3
Pco_6	10	10	4	6	6
Pco_8	12	7	2	5	10
Pco_9	15	13	7	6	8
Pco_12	11	6	1	5	10
Pco_14	10	12	5	7	5

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	19	7	12	2
Normal_6	6	14	2	12	4
Normal_10	5	8	4	4	1
Normal_18	6	9	3	6	3
Normal_21	6	11	4	7	2
Normal_25	7	12	4	8	3
Normal_31	7	8	2	6	5
Normal_38	4	9	2	7	2
Pco_1	10	9	4	5	6
Pco_4	10	7	2	5	8
Pco_7	10	10	4	6	6

EK-5ORTANCA FİLTRE VE UYARLANABİLİR EŞİKLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	5	4	1	0
Normal_8	6	8	6	2	0
Normal_11	6	7	6	1	0
Normal_16	7	9	7	2	0
Normal_22	6	11	6	5	0
Normal_28	9	16	9	7	0
Normal_34	6	10	5	5	1
Normal_36	5	8	5	3	0
Pco_10	14	14	13	1	1
Pco_11	10	17	10	7	0
Pco_13	12	10	10	1	2

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	7	4	3	1
Normal_3	4	6	4	2	0
Normal_5	3	7	3	4	0
Normal_7	5	9	5	4	0
Normal_9	7	9	7	2	0
Normal_12	6	11	6	5	0
Normal_13	3	5	3	2	0
Normal_14	7	10	7	3	0
Normal_15	2	5	2	3	0
Normal_17	5	8	5	3	0
Normal_19	9	14	9	5	0
Normal_20	6	6	5	1	1
Normal_23	5	8	5	3	0
Normal_24	7	9	7	2	0
Normal_26	8	17	8	9	0
Normal_27	6	11	6	5	0
Normal_29	6	9	6	3	0
Normal_30	6	9	6	3	0
Normal_32	6	9	6	3	0
Normal_33	3	5	3	2	0
Normal_35	4	4	4	0	0
Normal_37	3	4	3	1	0

Normal_39	6	7	6	1	0
Normal_40	5	7	5	2	0
Pco_2	15	15	12	3	3
Pco_3	12	19	12	7	0
Pco_5	14	15	13	2	1
Pco_6	10	12	10	0	0
Pco_8	12	13	12	1	0
Pco_9	15	16	14	2	1
Pco_12	11	13	11	3	0
Pco_14	10	17	10	7	0

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	13	9	4	0
Normal_6	6	7	6	1	0
Normal_10	5	7	5	2	0
Normal_18	6	9	6	3	0
Normal_21	6	7	6	1	0
Normal_25	7	10	7	3	0
Normal_31	7	13	7	6	0
Normal_38	4	5	4	1	0
Pco_1	10	10	10	0	0
Pco_4	10	10	10	0	0
Pco_7	10	11	10	1	0

EK-6 ORTALAMA FİLTRE VE HİSTOGRAM EŞİTLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	10	1	9	3
Normal_8	6	11	3	8	3
Normal_11	6	13	2	11	4
Normal_16	7	8	3	5	4
Normal_22	6	11	3	8	3
Normal_28	9	6	1	5	8
Normal_34	6	10	2	8	4
Normal_36	5	6	2	4	3
Pco_10	14	14	7	7	7
Pco_11	10	11	6	5	4
Pco_13	12	7	4	3	8

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	11	5	6	0
Normal_3	4	11	1	10	3
Normal_5	3	12	1	11	2
Normal_7	5	8	2	6	3
Normal_9	7	7	3	4	4
Normal_12	6	7	2	5	4
Normal_13	3	4	2	2	1
Normal_14	7	7	2	5	5
Normal_15	2	10	1	9	1
Normal_17	5	12	3	9	2
Normal_19	9	7	3	4	6
Normal_20	6	10	1	9	5
Normal_23	5	11	3	7	2
Normal_24	7	7	1	6	6
Normal_26	8	14	4	10	4
Normal_27	6	8	5	3	1
Normal_29	6	12	4	8	2
Normal_30	6	4	1	3	5
Normal_32	6	14	3	11	3
Normal_33	3	9	1	8	2
Normal_35	4	8	2	6	2
Normal_37	3	10	1	9	2

Normal_39	6	7	3	4	3
Normal_40	5	15	4	11	1
Pco_2	15	19	10	9	5
Pco_3	12	18	6	12	6
Pco_5	14	20	11	9	3
Pco_6	10	11	4	7	6
Pco_8	12	8	3	5	9
Pco_9	15	12	7	6	8
Pco_12	11	6	1	5	10
Pco_14	10	11	5	6	5

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	14	7	7	2
Normal_6	6	16	2	14	4
Normal_10	5	10	4	6	1
Normal_18	6	11	3	8	3
Normal_21	6	10	4	6	2
Normal_25	7	10	4	6	3
Normal_31	7	10	2	8	5
Normal_38	4	12	3	9	1
Pco_1	10	12	9	3	1
Pco_4	10	11	8	3	2
Pco_7	10	13	8	3	2

EK-7ORTALAMA FİLTRE VE UYARLANABİLİR EŞİKLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	5	4	1	0
Normal_8	6	8	6	2	0
Normal_11	6	8	6	2	0
Normal_16	7	9	7	2	0
Normal_22	6	9	6	3	0
Normal_28	9	17	9	8	0
Normal_34	6	11	6	5	0
Normal_36	5	13	5	8	0
Pco_10	14	13	12	1	2
Pco_11	10	12	10	2	0
Pco_13	12	12	10	2	2

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	9	4	5	1
Normal_3	4	7	4	3	0
Normal_5	3	7	3	4	0
Normal_7	5	8	5	3	0
Normal_9	7	9	7	2	0
Normal_12	6	12	6	6	0
Normal_13	3	5	3	2	0
Normal_14	7	10	7	3	0
Normal_15	2	9	2	7	0
Normal_17	5	9	5	4	0
Normal_19	9	12	9	3	0
Normal_20	6	8	6	2	0
Normal_23	5	10	5	5	0
Normal_24	7	11	7	4	0
Normal_26	8	18	8	10	0
Normal_27	6	10	6	4	0
Normal_29	6	11	6	5	0
Normal_30	6	10	6	4	0
Normal_32	6	9	6	3	0
Normal_33	3	4	3	1	0
Normal_35	4	5	4	1	0
Normal_37	3	4	3	1	0

Normal_39	6	7	6	1	0
Normal_40	5	9	5	4	0
Pco_2	15	16	12	4	3
Pco_3	12	22	12	10	0
Pco_5	14	18	13	5	1
Pco_6	10	12	10	2	0
Pco_8	12	13	12	1	0
Pco_9	15	17	14	3	1
Pco_12	11	16	11	5	0
Pco_14	10	16	10	6	0

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	16	9	7	0
Normal_6	6	6	6	0	0
Normal_10	5	8	5	3	0
Normal_18	6	10	6	4	0
Normal_21	6	8	6	2	0
Normal_25	7	14	7	7	0
Normal_31	7	17	7	10	0
Normal_38	4	6	4	2	0
Pco_1	10	12	9	3	1
Pco_4	10	11	8	3	2
Pco_7	10	13	8	3	2

EK-8 GAUSSIAN FİLTRESİ VE HİSTOGRAM EŞİTLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	10	4	6	0
Normal_8	6	12	6	6	0
Normal_11	6	11	6	5	0
Normal_16	7	13	7	6	0
Normal_22	6	13	6	7	0
Normal_28	9	8	5	3	4
Normal_34	6	13	4	9	2
Normal_36	5	10	4	6	1
Pco_10	14	14	7	7	7
Pco_11	10	16	8	8	2
Pco_13	12	16	8	8	4

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	9	4	5	1
Normal_3	4	20	1	19	3
Normal_5	3	11	1	10	2
Normal_7	5	12	2	10	3
Normal_9	7	7	4	3	3
Normal_12	6	10	3	7	3
Normal_13	3	6	2	4	1
Normal_14	7	12	2	10	5
Normal_15	2	9	2	7	0
Normal_17	5	11	5	6	0
Normal_19	9	10	3	7	6
Normal_20	6	17	1	16	5
Normal_23	5	11	4	7	1
Normal_24	7	7	1	6	6
Normal_26	8	14	4	10	4
Normal_27	6	7	6	1	0
Normal_29	6	11	5	6	1
Normal_30	6	5	1	4	5
Normal_32	6	17	4	13	2
Normal_33	3	10	1	9	2
Normal_35	4	8	2	6	2
Normal_37	3	4	1	3	2

Normal_39	6	10	3	7	3
Normal_40	5	10	5	5	0
Pco_2	15	18	10	8	5
Pco_3	12	11	7	4	5
Pco_5	14	23	12	11	2
Pco_6	10	10	5	5	5
Pco_8	12	8	4	4	8
Pco_9	15	14	8	6	7
Pco_12	11	8	3	5	8
Pco_14	10	23	5	18	5

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	18	6	12	3
Normal_6	6	17	4	13	2
Normal_10	5	14	4	10	1
Normal_18	6	12	3	9	3
Normal_21	6	11	4	7	2
Normal_25	7	12	5	7	2
Normal_31	7	10	2	8	5
Normal_38	4	10	3	7	1
Pco_1	10	13	5	8	5
Pco_4	10	8	3	5	7
Pco_7	10	17	6	11	4

EK-9 GAUSSIAN FİLTRESİ VE UYARLANABİLİR EŞİKLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	4	4	0	0
Normal_8	6	6	6	0	0
Normal_11	6	6	6	0	0
Normal_16	7	7	7	0	0
Normal_22	6	7	6	1	0
Normal_28	9	13	9	4	0
Normal_34	6	6	5	1	1
Normal_36	5	6	5	1	0
Pco_10	14	13	12	1	2
Pco_11	10	12	10	2	0
Pco_13	12	8	8	0	4

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	5	4	1	1
Normal_3	4	4	4	0	0
Normal_5	3	6	3	3	0
Normal_7	5	6	5	1	0
Normal_9	7	6	6	0	1
Normal_12	6	7	6	1	0
Normal_13	3	5	3	2	0
Normal_14	7	9	7	2	0
Normal_15	2	10	2	8	0
Normal_17	5	4	4	1	1
Normal_19	9	9	9	0	0
Normal_20	6	7	5	1	1
Normal_23	5	7	5	2	0
Normal_24	7	8	7	1	0
Normal_26	8	10	8	2	0
Normal_27	6	8	6	2	0
Normal_29	6	6	6	0	0
Normal_30	6	8	6	2	0
Normal_32	6	6	5	1	1
Normal_33	3	3	3	0	0
Normal_35	4	4	4	0	0
Normal_37	3	4	3	1	0

Normal_39	6	6	6	0	0
Normal_40	5	6	5	1	0
Pco_2	15	11	11	0	4
Pco_3	12	13	12	1	0
Pco_5	14	15	14	1	0
Pco_6	10	10	10	0	0
Pco_8	12	13	12	1	0
Pco_9	15	14	14	0	1
Pco_12	11	11	11	0	0
Pco_14	10	11	10	1	0

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	9	9	0	0
Normal_6	6	6	6	0	0
Normal_10	5	5	5	0	0
Normal_18	6	6	5	1	1
Normal_21	6	6	6	0	0
Normal_25	7	6	6	0	1
Normal_31	7	7	6	1	1
Normal_38	4	4	4	0	0
Pco_1	10	10	10	0	0
Pco_4	10	10	10	0	0
Pco_7	10	10	10	0	0

EK-10WIENER FİLTRESİ VE HİSTOGRAM EŞİTLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	11	1	10	3
Normal_8	6	11	4	7	2
Normal_11	6	10	2	8	4
Normal_16	7	8	3	5	4
Normal_22	6	11	4	7	2
Normal_28	9	6	1	5	8
Normal_34	6	11	3	8	3
Normal_36	5	5	2	3	3
Pco_10	14	11	6	5	8
Pco_11	10	16	6	10	4
Pco_13	12	7	4	3	8

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	12	5	7	0
Normal_3	4	12	1	11	3
Normal_5	3	11	1	10	2
Normal_7	5	8	2	6	3
Normal_9	7	7	3	4	4
Normal_12	6	8	2	6	4
Normal_13	3	5	2	3	1
Normal_14	7	7	2	5	5
Normal_15	2	12	1	11	1
Normal_17	5	13	3	10	2
Normal_19	9	7	3	4	6
Normal_20	6	12	1	11	5
Normal_23	5	9	3	6	2
Normal_24	7	7	1	6	6
Normal_26	8	14	4	10	4
Normal_27	6	8	5	3	1
Normal_29	6	11	4	7	2
Normal_30	6	5	1	4	5
Normal_32	6	16	3	13	3
Normal_33	3	9	1	8	2
Normal_35	4	12	2	10	2
Normal_37	3	8	1	7	2

Normal_39	6	7	3	4	3
Normal_40	5	13	4	9	1
Pco_2	15	17	11	6	4
Pco_3	12	18	7	11	5
Pco_5	14	20	11	9	3
Pco_6	10	11	4	7	6
Pco_8	12	11	3	8	9
Pco_9	15	13	7	6	8
Pco_12	11	8	1	7	10
Pco_14	10	11	5	6	5

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	14	7	7	2
Normal_6	6	16	2	14	4
Normal_10	5	12	4	8	1
Normal_18	6	10	3	7	3
Normal_21	6	10	4	6	2
Normal_25	7	10	4	6	3
Normal_31	7	9	2	7	5
Normal_38	4	13	3	10	1
Pco_1	10	10	4	6	6
Pco_4	10	8	2	6	8
Pco_7	10	10	4	6	6

EK-11WIENER FİLTRESİ VE UYARLANABİLİR EŞİKLEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	5	4	1	0
Normal_8	6	9	6	3	0
Normal_11	6	7	6	1	0
Normal_16	7	9	7	2	0
Normal_22	6	10	6	4	0
Normal_28	9	17	9	8	0
Normal_34	6	10	6	4	0
Normal_36	5	11	5	6	0
Pco_10	14	13	12	1	2
Pco_11	10	18	10	8	0
Pco_13	12	12	10	2	2

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	7	4	3	1
Normal_3	4	7	4	3	0
Normal_5	3	8	3	5	0
Normal_7	5	8	5	3	0
Normal_9	7	10	7	3	0
Normal_12	6	12	6	6	0
Normal_13	3	5	3	2	0
Normal_14	7	10	7	3	0
Normal_15	2	8	2	6	0
Normal_17	5	10	5	5	0
Normal_19	9	12	9	3	0
Normal_20	6	8	6	2	0
Normal_23	5	10	5	5	0
Normal_24	7	11	7	4	0
Normal_26	8	18	8	10	0
Normal_27	6	10	6	4	0
Normal_29	6	9	6	3	0
Normal_30	6	9	6	3	0
Normal_32	6	9	6	3	0
Normal_33	3	4	3	1	0
Normal_35	4	6	4	2	0
Normal_37	3	4	3	1	0

Normal_39	6	7	6	1	0
Normal_40	5	9	5	4	0
Pco_2	15	14	12	2	3
Pco_3	12	20	12	8	0
Pco_5	14	19	14	5	0
Pco_6	10	12	10	2	0
Pco_8	12	12	12	0	0
Pco_9	15	15	14	1	1
Pco_12	11	16	11	5	0
Pco_14	10	16	10	6	0

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	15	9	6	0
Normal_6	6	7	6	1	0
Normal_10	5	7	5	2	0
Normal_18	6	10	6	4	0
Normal_21	6	8	6	2	0
Normal_25	7	14	7	7	0
Normal_31	7	16	7	9	0
Normal_38	4	4	4	0	0
Pco_1	10	11	10	1	0
Pco_4	10	11	10	1	0
Pco_7	10	13	10	3	0

EK-12GAUSSIAN FİLTRESİ VE K-ORTALAMA KÜMELEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	5	3	2	1
Normal_8	6	6	6	0	0
Normal_11	6	7	4	3	2
Normal_16	7	16	6	10	1
Normal_22	6	12	6	6	0
Normal_28	9	8	5	3	4
Normal_34	6	17	6	11	0
Normal_36	5	6	3	3	2
Pco_10	14	14	9	5	5
Pco_11	10	9	9	0	1
Pco_13	12	11	5	6	7

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	6	2	4	3
Normal_3	4	5	4	1	0
Normal_5	3	3	3	0	0
Normal_7	5	5	5	0	0
Normal_9	7	9	4	5	3
Normal_12	6	16	4	12	2
Normal_13	3	8	3	5	0
Normal_14	7	7	7	0	0
Normal_15	2	5	2	3	0
Normal_17	5	12	5	7	0
Normal_19	9	7	7	0	2
Normal_20	6	15	4	11	2
Normal_23	5	7	5	2	0
Normal_24	7	11	5	6	2
Normal_26	8	12	5	7	3
Normal_27	6	6	6	0	0
Normal_29	6	11	6	5	0
Normal_30	6	10	6	4	0
Normal_32	6	16	4	12	2
Normal_33	3	10	1	9	2
Normal_35	4	4	4	0	0
Normal_37	3	5	3	2	0

Normal_39	6	7	6	1	0
Normal_40	5	9	5	4	0
Pco_2	15	20	12	8	3
Pco_3	12	17	11	6	1
Pco_5	14	16	14	2	0
Pco_6	10	10	10	0	0
Pco_8	12	12	12	0	0
Pco_9	15	15	15	0	0
Pco_12	11	10	10	0	1
Pco_14	10	10	9	1	1

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	11	8	3	1
Normal_6	6	7	5	2	1
Normal_10	5	8	5	3	0
Normal_18	6	5	5	0	1
Normal_21	6	18	5	13	1
Normal_25	7	8	4	4	3
Normal_31	7	10	5	5	2
Normal_38	4	6	4	2	0
Pco_1	10	10	10	0	0
Pco_4	10	12	8	4	2
Pco_7	10	17	8	9	2

EK-13 AYRIK DALGACIK DÖNÜŞÜMÜ VE K-ORTALAMA KÜMELEME

TEST VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_4	4	4	3	1	1
Normal_8	6	11	4	7	2
Normal_11	6	7	4	3	2
Normal_16	7	14	6	8	1
Normal_22	6	13	6	7	0
Normal_28	9	8	6	2	3
Normal_34	6	9	6	3	0
Normal_36	5	6	3	3	2
Pco_10	14	17	9	8	5
Pco_11	10	9	9	0	1
Pco_13	12	10	5	5	7

EĞİTİM VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_1	5	11	4	7	1
Normal_3	4	12	3	9	1
Normal_5	3	3	3	0	0
Normal_7	5	5	5	0	0
Normal_9	7	6	4	2	3
Normal_12	6	15	4	11	2
Normal_13	3	5	2	3	1
Normal_14	7	7	7	0	0
Normal_15	2	5	2	3	0
Normal_17	5	14	5	9	0
Normal_19	9	6	6	0	3
Normal_20	6	11	4	7	2
Normal_23	5	8	5	3	0
Normal_24	7	11	5	6	2
Normal_26	8	11	5	6	3
Normal_27	6	7	6	1	0
Normal_29	6	11	6	5	0
Normal_30	6	11	6	5	0
Normal_32	6	14	4	10	2
Normal_33	3	14	1	13	2
Normal_35	4	4	4	0	0
Normal_37	3	6	3	3	0

Normal_39	6	6	6	0	0
Normal_40	5	9	5	4	0
Pco_2	15	21	12	9	3
Pco_3	12	17	11	6	1
Pco_5	14	15	14	1	0
Pco_6	10	10	10	0	0
Pco_8	12	11	10	1	2
Pco_9	15	15	15	0	0
Pco_12	11	13	11	2	0
Pco_14	10	9	8	1	2

DEĞERLENDİRME VERİLERİ

Görsel Adı	Mevcut Folikül Sayısı (Uzman görüşü)	Tespit Edilen Folikül Sayısı (Önerilen Yöntem)	Doğru Folikül Sayısı	Tip I* Hatası	Tip II* Hatası
Normal_2	9	16	9	7	0
Normal_6	6	6	5	1	1
Normal_10	5	11	5	6	0
Normal_18	6	6	5	1	1
Normal_21	6	17	5	12	1
Normal_25	7	5	4	1	3
Normal_31	7	13	5	8	2
Normal_38	4	5	4	1	0
Pco_1	10	11	10	1	0
Pco_4	10	10	10	0	0
Pco_7	10	16	8	8	2

EK-14SELÇUK ÜNİVERSİTESİ TIP FAKÜLTESİ ETİK KURUL RAPORU

T.C.
SELÇUK ÜNİVERSİTESİ
TIP FAKÜLTESİ DEKANLIĞI

YEREL ETİK KURULU KARARLARI**Toplantı Sayısı: 2020/22****Toplantı Tarihi : 18.11.2020**

Karar Sayısı 2020/526 S.Ü. Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü Dr.Öğr.Üyesi Güzin ÖZMEN'in "Görüntü İşleme Yöntemleri ile Polikistik Over Sendromunda Folikül Tespiti" başlıklı araştırmasının değerlendirilme talebi ile ilgili 15.10.2020 tarihli dilekçesi ve ekleri görüşüldü.

Yapılan inceleme ve görüşmelerden sonra; Dr.Öğr.Üyesi Güzin ÖZMEN'in "Görüntü İşleme Yöntemleri ile Polikistik Over Sendromunda Folikül Tespiti" adlı araştırmasının kabulüne oy birliği ile karar verildi.

Yardımcı Araştırmacılar: Özlem SEÇİLMİŞ KERİMOĞLU, Perihan Gülşah YILMAZ.

EK-15KONYA ÖZEL MEDİCANA HASTANESİ ETİK KURUL RAPORU**MEDICANA**

21.01.2021

21.01.2020 tarihli 2021/01 nolu Akademik ve Etik Kurul kararına göre;

Selçuk Üniversitesi Teknoloji Fakültesi, Biyomedikal Mühendisliği Bölümü Dr. Öğr. Üyesi Güzin ÖZMEN'in "Görüntü İşleme Yöntemleri ile Polikistik Over Sendromunda Folikül Tespiti" başlıklı araştırması hasta mahremiyeti gözönünde bulundurulmak kaydı ile uygun görülmüştür.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Perihan Gülşah GÜLHAN
Uyruğu : T.C.

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Ali Naili Erdem Anadolu Lisesi, Mamak, Ankara	2014
Üniversite	: Selçuk Üniversitesi, Selçuklu, Konya	2018
Yüksek Lisans	: Selçuk Üniversitesi, Selçuklu, Konya	Devam ediyor

YAYINLAR

Özet Bildiri/Sözlü Sunum

Yılmaz, P.G., Özmen, G., “Follicle Detection for Polycystic Ovary Syndrome by using Image PRocessing Methods”, ICAT 2020” “9th International Conferance on Advanced Technolohies”, 10-12 August 2020, Istanbul, Turkey.

Makale

Yılmaz, P.G., Özmen, G., “Follicle Detection for Polycystic Ovary Syndrome by using Image PRocessing Methods”, IJAMEC 2020” “International Journal of Applied Mathematics Electronics and Computers”, 4-31 December 2020, 203-208.