

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TRANSFER ÖĞRENMESİ TABANLI HİBRİT EVRİŞİMSEL
SİNİR AĞI MODELLERİ KULLANILARAK MEME KANSERİ
TEŞHİSİ

Chingiz SEYİDBAYLI

YÜKSEK LİSANS TEZİ

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Programı

Danışman

Doç. Dr. Cenk ULU

Temmuz, 2022

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**TRANSFER ÖĞRENMESİ TABANLI HİBRİT EVRİŞİMSEL SİNİR AĞI
MODELLERİ KULLANILARAK MEME KANSERİ TEŞHİSİ**

Chingiz SEYİDBAYLI tarafından hazırlanan tez çalışması 08.07.2022 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalı, Mekatronik Mühendisliği Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Cenk ULU
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Cenk ULU, Danışman
Yıldız Teknik Üniversitesi

Doç. Dr. Hüseyin ÜVET, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Müjde GÜZELKAYA, Üye
İstanbul Teknik Üniversitesi

Danışmanım Doç. Dr. Cenk ULU sorumluluğunda tarafımca hazırlanan Transfer Öğrenmesi Tabanlı Hibrit Evrişimsel Sinir Ağı Modelleri Kullanılarak Meme Kanseri Teşhisi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Chingiz SEYIDBAYLI

İmza

X X X X X



Aileme
ve
biricik eşime

TEŞEKKÜR

Bu çalışma sürecinde yardımlarını ve tecrübesini esirgemeyen danışman hocam Doç. Dr. Cenk ULU'ya teşekkür ederim. Tez çalışmam süresince maddi ve manevi her türlü desteklerini hissettiren annem, babam, kardeşim, yaşadığım heyecan, mutluluk ve yorgunluk dahil herşeyimi paylaştığım eşim, tez çalışmamda hep destekçim olan Gülfize COŞKUN, Hasan ŞAHİN, Batuhan UZUN ve Gökhan AKGÜN'e teşekkür ederim.

Chingiz SEYİDBAYLI



İÇİNDEKİLER

SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ	xi
ÖZET	xii
ABSTRACT	xiv
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı.....	7
1.3 Hipotez.....	7
2 GENEL BİLGİLER	8
2.1 Makine Öğrenmesi.....	8
2.1.1 Denetimli Öğrenme	8
2.1.2 Denetimsiz Öğrenme	9
2.1.3 Pekiştirmeli Öğrenme	10
2.2 Yapay Sinir Ağları.....	11
2.2.1 İnsan Beyni ve Sinir Sistemi Yapısı	11
2.2.2 Nöron Modeli	12
2.2.3 Tek Katmanlı Ağlar.....	13
2.2.4 Çok Katmanlı Ağlar	14
2.3 Derin Öğrenme	15
2.3.1 Evrişimsel Sinir Ağları	16
2.3.2 Ön Eğitilmiş Ağlar	23
2.3.3 Transfer Öğrenmesi.....	26
2.4 Hibrit Modeller.....	27
3 KULLANILAN TEKLİ VE HİBRİT MODEL YAPILARI	30
3.1 Kullanılan Transfer Öğrenmesi Yapısı	30
3.1.1 Dondurulmuş Katmanlar	30
3.1.2 İnce Ayar Yapılmış ve Yeni Eklenmiş Katmanlar	31
3.2 Oluşturulan Tekli Modellerin Eğitilmesi	31

3.3 Hibrit Modellerin Oluřturulması	32
3.4 Hibrit Modellerin Eđitilmesi	48
4 VERİLERİN HAZIRLANMASI	34
4.1 Veri Setleri.....	34
4.1.1 CAMELYON Veri Seti.....	34
4.1.2 BreakHis Veri Seti	35
4.2 Verilerin Hazırlanması	36
4.2.1 CAMELYON Veri Setinin Hazırlanması	36
4.2.2 BreakHis Veri Setinin Hazırlanması	36
5 DENEYSEL SONUÇLAR	38
5.1 Başarım Metrikleri	38
5.2 Tekli Modeller İle Elde Edilen Deneysel Sonuçlar	54
5.3 İkili Hibrit Modeller İle Elde Edilen Deneysel Sonuçlar.....	42
5.4 Üçlü Hibrit Modeller İle Elde Edilen Deneysel Sonuçlar.....	45
5.5 Dörtlü Hibrit Model İle Elde Edilen Deneysel Sonuçlar	48
5.6 Deney Sonuçlarının Deđerlendirilmesi.....	50
6 SONUÇ VE ÖNERİLER	52
KAYNAKÇA	53
TEZDEN ÜRETİLMİŐ YAYINLAR	64

SİMGE LİSTESİ

v_k	Nöron Değeri
w_{kj}	Sinaps Ağırlık Değeri
x_j	Nöron Giriş Değeri
φ	Aktivasyon Fonksiyonu
b_k	Bias Değeri



KISALTMA LİSTESİ

DSÖ	Dünya Sağlık Örgütü
ESA	Evrişimsel Sinir Ağı



ŞEKİL LİSTESİ

Şekil 2.1 Makine öğrenmesi yöntemleri	8
Şekil 2.2 Denetimli öğrenme modeli.....	9
Şekil 2.3 Denetimsiz öğrenme modeli.....	10
Şekil 2.4 Pekiştirmeli öğrenme modeli.....	10
Şekil 2.5 İnsan sinir modeli yapısı (Haykin S., 1998)	12
Şekil 2.6 Nöron modeli	13
Şekil 2.7 Tek katmanlı ağ (Haykin S., 1998)	14
Şekil 2.8 Çok katmanlı ağlar (Haykin S., 1998)	15
Şekil 2.9 Yapay zeka ve makine öğrenmesinin alt dalı olarak derin öğrenme modeli	16
Şekil 2.10 Evrimsel sinir ağı modeli	17
Şekil 2.11 Evrişim işlemi (Haykin S., 2009).....	18
Şekil 2.12 Havuzlama yöntemleri.....	20
Şekil 2.13 Aktivasyon fonksiyonları	21
Şekil 2.14 Tam bağlı katman	22
Şekil 2.15 VGG16 (a) ve VGG 19 (b) mimarisi yapısı (Wang ve ark., 2020)....	24
Şekil 2.16 ResNet50 mimarisi yapısı (He, Zhang, Ren, & Sun, 2016)	25
Şekil 2.17 Xception mimarisi yapısı (Srinivasan, et al., 2021).....	26
Şekil 2.18 Transfer öğrenmesi modeli.....	27
Şekil 2.19 Xie ve ark. tarafından önerilen hibrit model	28
Şekil 2.20 Ding ve ark. tarafından önerilen hibrit model	28
Şekil 2.21 Rahaman ve ark. tarafından önerilen hibrit model	29
Şekil 2.22 Hibrit derin özellik füzyonu yapısı	29
Şekil 3.1 Transfer öğrenmesi için kullanılan dondurulmuş katmanlar	31
Şekil 3.2 İnce ayar yapılmış ve yeni eklenmiş katmanlar	31
Şekil 3.3 Hibrit model yapıları.....	32
Şekil 4.1 CAMELYON veri setine ait örnek görüntüleri.....	34
Şekil 4.2 BreakHis veri Setine ait 40X, 100X, 200X, 400X büyütülmüş meme dokusu görüntüsü (Spanhol ve ark., 2015)	35
Şekil 4.3 ASAP yazılımı üzerinde işaretlenmiş tümör bölgesi ve içerisine çizilmiş bölünecek olan dikdörtgen alan	36

Şekil 4.4 225x225 piksel ölçüsünde bölümlenmiş doku görüntüsü	36
Şekil 4.5 BreakHis veri setinden elde edilmiş 225x225 piksel ölçüsünde doku görüntüsü	37
Şekil 5.1 Karışıklık matrisi yapısı	38
Şekil 5.2 Tekli modellerin CAMELYON veri seti üzerinde karışıklık matrisleri ...	39
Şekil 5.3 Tekli modellerin BreakHis veri seti üzerinde karışıklık matrisleri.....	39
Şekil 5.4 İkili hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri	42
Şekil 5.5 İkili hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri	42
Şekil 5.6 Üçlü hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri	45
Şekil 5.7 Üçlü hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri	46
Şekil 5.8 Dörtlü hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri	49
Şekil 5.9 Dörtlü hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri	49

TABLO LİSTESİ

Tablo 3.1	Hibrit model kombinasyonları.....	32
Tablo 5.1	Tekli modellerin CAMELYON veri seti üzerindeki sonuçları	40
Tablo 5.2	Tekli modellerin BreakHis veri seti üzerindeki sonuçları	41
Tablo 5.3	İkili hibrit modellerin CAMELYON veri seti üzerindeki sonuçları	43
Tablo 5.4	İkili hibrit modellerin BreakHis veri seti üzerindeki sonuçları.....	44
Tablo 5.5	Üçlü hibrit modellerin CAMELYON veri seti üzerindeki sonuçları	47
Tablo 5.6	Üçlü hibrit modellerin BreakHis veri seti üzerindeki sonuçları.....	48
Tablo 5.7	Dörtlü hibrit modellerin CAMELYON veri seti üzerindeki sonuçları ...	49
Tablo 5.8	Dörtlü hibrit modellerin BreakHis veri seti üzerindeki sonuçları.....	50

Transfer Öğrenmesi Tabanlı Hibrit Evrişimsel Sinir Ağı Modelleri Kullanılarak Meme Kanseri Teşhisi

Chingiz SEYIDBAYLI

Mekatronik Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Cenk ULU

Dünya Sağlık Örgütü'ne göre meme kanseri en yaygın kanser türlerinden biridir. 2020 yılında meme kanseri teşhisi koyulmuş 2.26 milyon kişinin 685 bini hayatını kaybetmiştir. Son yıllardadijital kanser tanı sistemlerinin kullanımı popülerlik kazanmıştır. Özellikle son 10 yılda derin öğrenme modelleri ve evrişimsel sinir ağı (ESA) modelleri, yüksek performanslarından dolayı görüntülerden kanser sınıflandırma uygulamalarında yaygın olarak tercih edilmektedir. Transfer öğrenmesi yöntemi kullanılarak ön eğitilmiş modellerin özellik çıkarımı ile ilgili parametreleri yeni modellere aktarılabilmekte ve böylece kısıtlı eğitim veri seti olması durumunda dahi tatmin edici başarımlar elde edilebilmektedir. Son zamanlarda ESA'lar ile elde edilen teşhis performansını daha da arttırmak için hibrit modeller önerilmiştir. Literatürde hibrit modeller, genellikle farklı ESA mimarilerinin belli katmanları birleştirilerek oluşturulmaktadır. Bu hibrit modellerde her bir ESA modelinin katman çıkışları ayrı ayrı işlenip, elde edilen değerler birleştirilerek sınıflandırıcıya girdi olarak verilmektedir.

Bu çalışmada, doku bazlı patoloji görüntüleri üzerinden gerçekleştirilen meme kanseri teşhis işleminde hibrit ESA modeli kullanılarak tekli ESA modelleri ile elde

edilen teşhis başarımının arttırılması amaçlanmıştır. Hibrit modeli oluşturmak için kullanılacak tekil ESA modelleri olarak ResNet50, VGG16, VGG19 ve Xception ön eğitilmiş modelleri tercih edilmiştir. En iyi hibrit modelin elde edilmesi için tekil modellerin ikili, üçlü ve dörtlü kombinasyonları oluşturulmuş ve başarımları deneysel olarak analiz edilmiştir.

Modellerin eğitilmesi ve test edilmesi için CAMELYON ISBI ve BreakeHis veri setleri kullanılmıştır. Veri setlerinden elde edilmiş 225x225 boyutlarında görüntülerin sınıflandırılması gerçekleştirilmiştir. Tekli eğitim modellerinin oluşturulması için VGG16, VGG19, ResNet50 ve Xception modelleri transfer öğrenmesi yöntemi ile alınmış ve genel özellik çıkaran katmanları dondurulmuştur. Kalan katmanlardaki belirli bir katmanın çıkışına global maksimum havuzlama katmanı eklenmiş ve geri kalan katmanlar modelden çıkarılmıştır. Bu katmandan sonra sınıflandırma işlemi için bir tam bağlı ağ eklenmiştir. Bu tam bağlı ağda 1024 nörondan oluşan yoğunluk katmanı yer almakta, seyreltme ve yığın normalizasyon işlemleri yapılmakta ve softmax fonksiyonu kullanılarak sınıflandırma gerçekleştirilmektedir. Dondurulmuş katmanlar dışında kalan katmanların eğitimi gerçekleştirilmiştir. Tekil modellerin eğitimi yapıp, parametreleri kaydedildikten sonra, ikili, üçlü ve dörtlü eğitim hibrit modelleri oluşturulmuştur. Bu modeller oluşturulurken kaydedilmiş her bir tekli modelin 1024 nörondan oluşan katmanından elde edilen öznitelik vektörlerinin birleştirilmesi ile yeni öznitelik vektörleri elde edilmiştir. Bu birleştirilmiş vektörlere seyreltme ve yığın normalizasyon işleminin uygulandığı tam bağlı katman ile sınıflandırma işlemi gerçekleştirilmiştir. Sonuçların başarımlar ölçümleri için kesinlik, duyarlılık, F1-skoru ve doğruluk metrikleri seçilmiştir. Elde edilen deneysel sonuçlara göre CAMELYON veri seti için en iyi sonucu %97.08 doğruluk oranı ile ResNet50 – VGG16 – Xception üçlü hibrit modeli ve BreakeHis veri seti için en iyi sonucu %97.75 doğruluk oranı ile VGG16 – VGG19 ikili hibrit modeli göstermiştir.

Anahtar Kelimeler: Evrimsel sinir ağı, hibrit model, ön eğitilmiş ağlar, transfer öğrenmesi, meme kanseri teşhisi.

Breast Cancer Detection Using Transfer Learning Based Hybrid Convolutional Neural Network Models

Chingiz SEYIDBAYLI

Department of Mechatronics Engineering

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Cenk ULU

According to the World Health Organization, breast cancer is one of the most common types of cancer. 685.000 of the 2.26 million people diagnosed with breast cancer died in 2020. The use of digital cancer diagnosis systems has gained popularity in recent years. Especially in the last 10 years, deep learning models and convolutional neural network (CNN) models have been widely preferred in cancer classification applications due to their high performance. By using the transfer learning method, the parameters related to the feature extraction of the pre-trained models can be transferred to the new models and thus satisfactory performances can be obtained even in the case of a limited training data set. Recently, hybrid models have been proposed to further enhance the diagnostic performance of CNNs. In literature, hybrid models are generally constructed by combining certain layers of different CNN architectures. In these hybrid models, the layer outputs of each CNN model are processed separately and the obtained values are combined and given as input to the classifier.

In this study, it is aimed to increase the detection performance obtained with single CNN models by using the hybrid CNN model in breast cancer detection applications performed on histopathological images. ResNet50, VGG16, VGG19,

and Xception pre-trained models are preferred as single CNN models to construct the hybrid models. In order to obtain the optimal hybrid model, double, triple, and quadruple combinations of single models are constructed and their performances are analyzed experimentally.

To train and test the models, CAMELYON ISBI and BreakHis datasets are used. Classification of images with the size of 225x225 pixels obtained from datasets is performed. In order to construct single training models, VGG16, VGG19, ResNet50, and Xception models are taken by the transfer learning method, and their general feature extraction layers are frozen. A global maximum pooling layer is added to the output of a particular layer in the remaining layers, and subsequent layers are removed from the model. After the global maximum pooling layer, a fully connected network is added for the classification process. This fully connected network has a density layer consisting of 1024 neurons, a dropout layer, and a batch normalization layer, and classification is performed using the softmax function. The training of the layers other than the frozen layers is performed. After training the single models and saving their parameters, training hybrid models composed of two, three, and four CNN models are constructed. While constructing these hybrid models, a new feature vector is obtained by combining the feature vectors obtained from the layer consisting of 1024 neurons of each saved single model. The classification process is performed for these combined vectors by using a fully connected network including dropout and batch normalization layers. To evaluate the performances of the models, precision, recall, F1- score, and accuracy are chosen as the performance metrics. The experimental results show that the best performances are obtained by the ResNet50 – VGG16 – Xception hybrid model with the accuracy of 97.08% and the VGG16 – VGG19 hybrid model with the accuracy of 97.75% for the CAMELYON dataset and the BreakHis dataset, respectively.

Keywords: Convolutional neural network, hybrid model, pre-trained networks, transfer learning, breast cancer detection.

1.1 Literatür Özeti

Kanser, Dünya genelinde yaygın ölüm nedenlerindendir. Bu hastalıktan 2020 yılında yaklaşık 10 milyon ölüm gerçekleşmiştir (Dünya Sağlık Örgütü, 2022). Listenin başında ise meme kanseri gelmektedir. Dünya Sağlık Örgütü (DSÖ) verilerine göre 2020 yılında 2,26 milyon kişiye meme kanseri teşhisi konmuş ve bu vakaların 685 bini ölümle sonuçlanmıştır (Dünya Sağlık Örgütü, 2021).

Meme kanseri, lobüller (süt üretimi için bezleri içeren dokular) vasıtası ile meme ucuna doğru bağlanan kanallara uzanan kanser türüdür. Tipik belirtiler gelişmeden önce hastanın yumrudan şüphelenmesi ile tespit edilir. Radyografik görüntüleme esnasında iyi huylu olduğuna kanaat getirilirse müdahale edilmez. Eğer lezyon ya da tümörden şüphelenilirse mamografi, manyetik rezonans, bilgisayarlı tomografi, fiziki muayene veya histopatolojik görüntü incelenmesi yöntemi ile teşhis edilir. Yardımcı tarama yöntemi için tümörün doğrusal olarak büyümesi beklenir. Ama eğer hastalıklı bölge heterojen biçimde büyümeye başlarsa yanlış teşhise yol açabilir. Bu problem beraberinde fazladan maliyete ve hastanın psikolojisinin etkilenmesine yol açabilir. Bu gibi durumlar göz önüne alındığında, teşhis başarımını arttırmak için geleneksel teşhis uygulamalarının yanında bilgisayar destekli teşhis sistemlerine de ihtiyaç duyulmuştur (Dogra, 2019; Løberg ve ark., 2015; Nahid ve ark. 2017; Sadoughi, ve ark., 2018; Zou, ve ark, 2019).

Bilgisayar destekli teşhis sistemleri 1950'lerin sonlarından itibaren araştırmacılar tarafından karar süreçlerini yönetmek, akış şemaları, istatistiksel model eşleştirme gibi alanlarda kullanılmaya başlamıştır (Yanase ve ark., 2019). 1970'lerin başında eğitim amacıyla kullanılmak üzere MYCIN (Shortliffe ve ark., 1975), Internist-I (Miller, Pople, ve ark., 1985) ve CADUCEUS (CADUCEUS: An Experimental Expert System for Medical Diagnosis, 1986) gibi uzmanlar sistemler geliştirildi.

Yine aynı dönemde Richard M. Karp tarafından yayınlanmış “Reducibility among Combinatorial Problems” (Birleşimsel Problemler Arasında İndirgenebilirlik) (Karp, 1972) makalesinden sonra araştırmacılar uzman sistemlerde bulunan sınırlamaları farkettiler ve bununla beraber yeni yaklaşımlar ortaya atılmaya başlanmıştır (Yanase ve ark., 2019).

Bilgisayar teknolojisinin gelişmesi ile günümüzde yaygın olarak yapay zeka destekli sistemlerden derin öğrenme yöntemleri kullanılmaktadır. Sinir ağlarının başarımları kayda değer oranda ilerlemiş ve birçok endüstriyel uygulamada etkin şekilde kullanılmaktadır (Szegedy ve ark., 2015). Makine öğrenmesi ve derin öğrenme yöntemi sayesinde, geleneksel yapay zeka yöntemleri ile çözülmesi zor problemler daha yüksek başarımla çözülebilmektedir (LeCun ve ark., 2015). Derin öğrenme modelleri, öğrenme için etiketsiz verileri kullanabilir ve bu sebepten ötürü heterojen verilerle çalışmak için uygundur (Chen ve ark., 2014). Bu alanda karmaşık verilerden öğrenme (Miotto ve ark., 2018; Wei ve ark., 2017), görüntü analizi (Shin ve ark., 2016), metin işleme (Song ve ark., 2016) gibi alanlarda çalışma sonuçları kabul görmektedir. Derin öğrenmenin kullanıldığı bir diğer alan da tıbbi teşhistir. Bu alanda derin öğrenme, sınıflandırma, bölütleme, tahmin vb. işlemler için kullanılmaktadır. Bilgisayar destekli teşhis sistemleri yanlış teşhisi %77 oranında azaltmaktadır (Nover ve ark., 2009; Burhenne, et al., 2000).

Derin öğrenme yöntemleri ile geliştirilen önemli sağlık çalışmalarına örnek olarak kısa eksenli kardiyak manyetik rezonans görüntülemeye (MRG) sol ventrikülün segmentasyonunu kolaylaştırabilen deforme olabilen bir modelin parametrelerinin şifrelemesi (Avendi ve ark., 2016) ve MRG taramalarından biyobelirteçleri belirlemek için yapılan tıbbi görüntüleme çalışmalarını gösterebiliriz (Li ve ark., 2015).

Derin öğrenme yöntemlerinden olan evrimsel sinir ağları (ESA) tıbbi görüntü analizinde yaygın biçimde kullanılmaktadır. ESA’lar çok katmanlı algılayıcılar olarak görüntüleri girdi olarak alıp, daha sonra ağırlık ile özellik haritaları oluştururlar. Bu yapılar, geleneksel derin öğrenme modellerine göre kullanılan parametre sayısını azaltarak modelin verimliliğini artırmaktadırlar (Dabral ve ark., 2021).

ESA'lar, hastalıkların teşhisinde özellikle kanser biyopsilerinin teşhisi için vazgeçilmez hale gelmiştir (Tearney ve ark., 1997; Hendee, 1983). Bu derin öğrenme modelleri, tıbbi görüntüleme alanında günümüzde X ışınları, MRG, bilgisayarlı tomografi (BT), pozitron emisyon tomografisi (PET) ve ultrason yöntemleri ile elde edilmiş tıbbi görüntülerde kullanılmaktadır (Heidenreich, Desgrandschamps, ve ark., 2002). ESA'lar ile meme kanseri, akciğer kanseri, prostat kanseri, kemik baskılanması, deri lezyonları ve Alzheimer hastalığı gibi hastalıkların teşhisi için görüntü analizi yapılmaktadır (Nomura ve ark., 2017; Liang ve ark., 2016; Firmino ve ark., 2014; El-Baz ve ark., 2013; Nishio ve ark., 2017; Kawagishi ve ark., 2017; de Carvalho Filho ve ark., 2017; Nomura ve ark., 2017; Liang ve ark., 2016).

Bilgisayar destekli teşhis sistemlerinde doğruluk oranı ve model performansını artırmak için birçok ESA model yapısı önerilmiştir.

Afonso ve ark. (Afonso ve ark., 2019) tarafından yapılmış çalışmada Parkinson hastalığını teşhis etmek amacı ile motor sinyallerinin tekrarlama grafikleri, görüntü alanı ile eşleştirilmiştir. Daha sonra elde edilmiş bu veri ESA'yı beslemek için kullanılmış ve deneysel çalışmalarda %87 doğruluk oranı elde edilmiştir.

Längkvist ve ark. (Längkvist ve ark., 2018) BT kesitlerinde üreter taşlarının tanımlanması için ESA kullanarak model tasarımı yapmışlardır. Önerilen yöntem, 465 hastadan oluşan veri setinde değerlendirilmiş ve hasta başına %100 duyarlılık ve ortalama olarak 2.68 yanlış pozitif sonuç elde edilmiştir.

Altat (Altat, 2021), mamografi görüntülerinden meme kanseri teşhisi için darbe bağlantılı sinir ağı (Pulse-coupled Neural Network) ve transfer öğrenme tabanlı evrişimsel sinir ağı ile birkaç farklı ön eğitilmiş ağı birleştirip hibrit model elde ederek eğitimde kullanılmamış veri seti üzerinde denemiş ve %98.77 oranında doğruluk elde etmiştir.

Bilgisayar destekli teşhis sistemlerinde kanser teşhisi için biyopsi numunelerinin incelenmesi önem arz etmektedir. Tüm Slayt Görüntüleme yöntemi olarak adlandırılan bu yöntemde veriler hücre bazlı olan sitolojik ve doku bazlı olan histolojik olarak iki gruba ayrılmaktadır. Hücre bazlı görüntülerin sınıflandırılması işlemi her bir hücre için tek tek yapıldığından veri setinin hazırlanması için uzun

zaman harcanmaktadır. Yoğun emek harcanmasından dolayı hücre bazlı az sayıda veri seti bulunmaktadır. Örnek olarak hücre bazlı yapıya sahip olan kadın rahim ağzı kanseri için SIPaKMeD (Plissiti ve ark., 2018) ve Herlev (Arya ve ark.,2018) gibi sınıflandırılmış az sayıda veri bulunmaktadır. Histopatoloji (doku numunelerini inceleyen bilim dalı) alanında ise farklı organlara ait birçok veri setleri bulunmaktadır. Farklı veri setleri yeni çalışmalara ve yeni yöntemlerin geliştirilmesine zemin yaratmaktadır. Örneğin, meme kanseri üzerine BreakHis (Spanhol ve ark., 2015), CAMELYON (Ehtesham ve ark., 2017), BACH (Aresta, ve ark., 2019), Wisconsin (Dua ve ark., 2019), BreCaHAD (Aksac ve ark., 2019) gibi birçok veri setleri mevcuttur. Bu veri setleri ile hem bölütleme, hem de sınıflandırma üzerine çalışmalar yapılmıştır.

Wang ve ark. (Wang ve ark., 2020) tarafından yapılan çalışmada EfficientNet ağı kullanılmış ve model performansını artırmak ve görüntü kalitesini korumak için Rastgele Merkez Kırpma yöntemi önerilmiştir. Ayrıca sinir ağının alt örnekleme ölçeği küçük çözünürlüklü görüntüler için yeniden ayarlanmış ve %97.96 doğruluk değeri ve %99.68 Eğri Altındaki Alan (AUC) değeri elde edilmiştir.

Vo-Le ve ark. (Vo-Le ve ark., 2021) tarafından yapılan çalışmada transfer öğrenmesi yöntemi ile CAMELYON ve VBCAN veri setleri üzerinde histopatolojik görüntülerden meme kanseri teşhisi yapılmıştır. Çalışmada, VGG16, GoogleNet ve ResNet50 ön eğitilmiş modellerinin kombinasyonları öznetelik çıkarımda kullanılmış ve sonrasında geleneksel makine öğrenmesi yöntemi ile sınıflandırma yapılmıştır. CAMELYON veri seti ile test edildiğinde en yüksek doğruluk oranı %89.86 değeri ile VGG16 modeli olmuştur. VBCAN veri setinde (Vo-Le ve ark., 2021) ise ResNet50 modeli %96.98 doğruluk değerine ulaşmıştır.

ESA performansını artırmak için önerilen yöntemlerden bir tanesi de ESA hibrit yapıda kullanılmasıdır. Hibrit ESA'lar yapısına ve oluşturulma şekline göre farklılık göstermektedir.

Xie ve ark. (Xie ve ark., 2017) tarafından yapılan çalışmada geleneksel sözlük tabanlı özelliklerin görüntülerde daha fazla ayırt edici özellik barındırmasından dolayı ESA modelinin ayrı katmanlarında elde edilmiş farklı boyutlardaki özellik

haritalarını birleştirmiş ve elde edilen vektörü destek vektör makineleri ile sınıflandırmıştır.

Ding ve ark. (Ding ve ark., 2020) önerdiği yöntemde bir boyutlu giriş verileri biçimlendirilmiş, elde edilen iki boyutlu veriler ESA mimarisine girdi olarak verilmiştir. Çok katmanlı ağdan elde edilmiş bir boyutlu verilerin özellikleri ile, ESA çıkışında elde edilmiş özellikler birleştirilmiş ve sınıflandırma için tam bağlı katmana girdi verisi olarak kullanılmıştır.

Rahaman ve ark. (Rahaman ve ark., 2021) tarafından önerilen hibrit derin özellik füzyonu yöntemi ile farklı ESA'lar tarafından çıkarılmış öznitelik vektörleri birleştirilmiş ve elde edilmiş yeni vektör tam bağlı katmanda sınıflandırılmıştır. Çalışmada dört farklı ön eğitilmiş ESA modelinin 1024 boyutunda olan çıkışları birleştirilmiş ve tam bağlı katmanda sınıflandırılmıştır.

Meme kanseri teşhisi için geliştirilen yöntemler arasında da hibrit ESA yapıları mevcuttur. Zhu ve ark. (Zhu ve ark., 2019) tarafından önerilen hibrit yöntemde tam slayt görüntüleri, hem bölümlenmiş olarak, hem de tam slayt görüntülerinin alt örnekleme ESA ağına beslenmiş ve bölümlenmiş görüntülerden elde edilen tahmin oyu ile alt örneklenmiş görüntüden çıkarılmış sonuçlar birleştirilerek tahmin yapılmıştır. Model BreakHis ve BACH veri setleri ile test edilmiştir. Görüntü bazında BreakHis veri seti için 40x büyütme oranı için %85.6, 100x için %83.9, 200x için %85.4 ve 400x için %81.2 başarımlar elde edilmiştir. BACH veri setinde ise %86.6 başarımlar elde edilmiştir. Abedhaliem ve ark. (Abedhaliem ve ark., 2022) tarafından yapılmış çalışmada BACH veri setinden ResNet18, Inception ResNet V2, ShuffleNet ve Xception ESA modelleriyle çıkarılmış öznitelik vektörleri, el yordamı ile çıkarılmış özniteliklerle birleştirilmiş ve temel bileşenler analizi ile elde edilmiş yeni değerler Destek Vektör Makineleri (DVM), Rastgele Orman (RF) ve K-En Yakın Komşuluk yöntemleri ile sınıflandırılmıştır. Önerilen yöntem ile %96.97 doğruluk başarımları elde edilmiştir. Yan ve ark. (Yan ve ark., 2020) tarafından hibrit ESA modeli ile elde edilmiş öznitelik vektörlerinin birleştirilerek Yenilenebilir Sinir Ağları ile sınıflandırılma işleminin gerçekleştirildiği bir yöntem önerilmiştir. BreakHis veri setinin kullanıldığı bu çalışmada %91.3 başarımlar elde edilmiştir. Singh ve ark. (Singh ve

ark., 2011) meme histopatoloji görüntüsünü tasarladıkları 8 özellik ve 3 ileri ve geri yönlü Yapay Sinir Ağı (YSA) ile sınıflandırmış ve %95 başarı oranına ulaşmışlardır. Wang ve ark. (Wang ve ark., 2018) hiyerarşik kayıplı ESA tasarlamış ve dört sınıflı bir sınıflandırma işlemi gerçekleştirmişlerdir. Önerilen modelde iki özellik haritası birleştirilerek elde edilen yeni yapıya uygulanan evrişim işlemi ile sınıflandırma işlemi gerçekleştirilmiştir. Özellik haritalarından birincisi giriş verisine uygulanan ESA modelinden, ikincisi ise giriş verisine uygulanmış global havuzlama, evrişim ve havuzdan çıkarma işlemlerinden elde edilmiştir. Universidade do Porto tarafından oluşturulmuş veri setinde %88 doğruluk oranı elde edilmiştir. Patil ve ark. (Patil ve ark., 2019) dikkate dayalı çoklu örnek öğrenme yöntemi (A-MIL) ile ESA tasarlamış ve BreakHis ve BACH veri setleri ile test etmişlerdir. Model BreakHis 400x veri seti üzerinde %84.43, BACH veri seti üzerinde %80 doğruluk elde etmiştir. Joseph ve ark. (Joseph ve ark., 2022) el işi özellik ve derin öğrenme ağı kullanarak çok sınıflı sınıflandırma işlemi gerçekleştirmişlerdir. BreakHis 400x veri seti üzerinde %96.84 doğruluk oranı göstermiştir. Deniz ve ark. (Deniz ve ark., 2018) Alexnet ve VGG16 ön eğitilmiş ESA modellerini kullanarak her bir ağıdan elde edilmiş öznitelik vektörlerini birleştirmiş ve DVM yardımı ile sınıflandırma işlemini gerçekleştirmişlerdir. Ön eğitilmiş modellerin çıkardığı öznitelik matrisleri birleştirilmiş ve sınıflandırma gerçekleştirilmiştir. Ayrıca Alexnet ağı üzerinde ince ayar yapılarak model test edilmiştir. BreakHis veri seti üzerinde hibrit modelden %86.75, iyileştirilmiş Alexnet modelinden ise %91.3 doğruluk değeri elde edilmiştir. Erdem ve ark. (Erdem ve ark., 2021) tarafından önerilmiş yöntemde VGG16 ve Inception-V3 modellerinin “Global Average Pooling2d” katmanından elde edilen öznitelik değerleri birleştirilmiş ve 512 nöronlu oluşan iki tam bağlı katman ile sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yöntem BreakHis 40X veri setinde %99.03 başarıma ulaşmıştır. Dandil ve ark. (Dandil ve ark., 2021) tarafından yapılmış çalışmada dört farklı yöntemle elde edilmiş öznitelik vektörleri birleştirilmiş ve Bag of Words yöntemi ve derin sinir ağı yöntemlerinin birleştirilmesi ile sınıflandırılmıştır. Kullanılan veri seti üzerinde %94.5, test veri seti üzerinde %80.8 başarımlar elde edilmiştir.

1.2 Tezin Amacı


Bu tez çalışmasının amacı, doku bazlı patoloji görüntüleri üzerinden gerçekleştirilen meme kanseri teşhis işleminde hibrit ESA modeli kullanarak tekli ESA modelleri ile elde edilen teşhis başarımını arttırmaktır. Çalışmada BreakHis ve CAMELYON veri setleri kullanılmıştır. Kullanılan hibrit modeli oluştururken öncelikle ön eğitilmiş ResNet50, VGG16, VGG19 ve Xception ESA modellerinin genel özellik çıkarma katmanları transfer öğrenmesi yöntemi ile alınmış ve genel özellik çıkaran katmanları dondurulmuştur. Kalan katmanlardaki belirli bir katmanın çıkışına global maksimum havuzlama katmanı eklenmiş ve geri kalan katmanlar modelden çıkarılmıştır. Bu katmandan sonra sınıflandırma işlemi için bir tam bağlı katman eklenmiştir. Bu tam bağlı katmanda 1024 nörondan oluşan yoğunluk katmanı yer almakta, seyreltme ve yığın normalizasyon işlemleri yapılmakta ve softmax fonksiyonu kullanılarak sınıflandırma gerçekleştirilmektedir. Dondurulmuş katmanlar dışında kalan katmanların eğitimi gerçekleştirilmiştir. Daha sonrasında en uygun hibrit model kombinasyonunun belirlenmesi için modellerin ikili, üçlü ve dörtlü şekilde gruplandırması yapılmış ve bu kombinasyonlarda elde edilen öznitelik matrisleri derin öznitelik füzyonu yöntemi ile birleştirilerek tam bağlı ağ yardımı ile sınıflandırma işlemi gerçekleştirilmiştir. Oluşturulan hibrit ESA modelinin başarımı tekil model başarımları ile karşılaştırılarak üstünlüğü gösterilmiştir.

1.3 Hipotez

Bu tez çalışmasının hipotezi, doku bazlı patoloji görüntüleri üzerinden gerçekleştirilen meme kanseri teşhis işleminde ön eğitilmiş ağların kullanıldığı hibrit ESA model yapısının kullanılması ile tekli ESA modellerinin kullanılması durumuna göre daha üstün bir başarımlar elde edileceğidir.

2.1 Makine Öğrenmesi

Makine öğrenmesi, araştırmacılar, mühendisler, veri bilimciler tarafından tercih edilen modeller ve algoritmalar ile örüntü tanıma, veri analitiği, tahmin sistemleri için kullanılan hesaplama yöntemidir. Veriler üzerindeki gizli örüntüleri ve özellikleri keşfetmeye yardımcı olur (Ahuja ve ark., 2017). Makine öğrenmesi, bilgisayarlara açıkça programlanmadan öğrenme yeteneği sağlar (Latif ve ark., 2019). Tahmin için seçilen model veya algoritmalar evrensel olmamasından dolayı geçmiş gözlem ve çalışmalar incelenerek uygun model seçimi yapılır (Haykin S. , 1998). Makine öğrenmesinin Şekil 2.1'de gösterildiği gibi denetimli, denetimsiz ve pekiştirmeli öğrenme gibi alt kategorileri mevcuttur.




Şekil 2.1 Makine öğrenmesi yöntemleri

2.1.1 Denetimli Öğrenme

Makine öğrenmesi Şekil 2.2'de gösterildiği gibi modelinin veri etiketine dayalı olarak öğrenme türüdür. Veriler ve verilerin açıklaması olan etiketler modele eğitim için beslenir. Model kendisini eğiterek ve güncelleyerek etiket-veri çiftini öğrenir. Daha sonradan eğitimi tamamlanmış model yine etiketli veri ile test edilir ve çıktı olarak elde edilen etiketler gerçek etiket ile karşılaştırılarak doğruluk oranı belirlenir. Denetimli öğrenmenin amacı, girdi ve çıktılar arasındaki eşlemeyi

öğrenerek sisteme girdi olarak verilen verilerin çıktılarını tahmin etmektir. Bazen öğretmenle öğrenme, etiketli veriden öğrenme veya tümevarımsal öğrenme olarak da adlandırılmaktadır (Haykin S. , 1998; Kotsiantis, 2007).

Denetimli öğrenme, sınıflandırma ve regresyon olarak ikiye ayrılır. Regresyon problemlerinde girdi verilerini çıktı fonksiyonları ile eşleştirmeye çalışılır. Sınıflandırma problemlerine ise girdinin hangi gruba veya sınıfa ait olduğu belirlenmeye çalışılır.




Şekil 2.2 Denetimli öğrenme modeli

2.1.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketlenmemiş ve sınıflandırılmamış veriler ile öğrenme modelidir. Makine öğrenmesi algoritması bu işlemleri gerçekleştirirken herhangi dış rehberliğe ihtiyaç duymaz, etiketlenilmemiş olsa bile Şekil 2.3'deki gibi veriler arasında benzerlik ve farklılıklara göre gruplandırma işlemini gerçekleştirmektedir. Etiketsiz veriler öncelikle model tarafından işlenerek özellikleri çıkarılır ve benzer özelliklere sahip verilerin gruplandırılması veya hesaplanması için algoritma elde edilir. Sonrasında tahmin işlemi ile kümeleme gerçekleştirilir. Amaç, verilerdeki gizli örüntülerin keşfedilmesidir (Hastie ve ark., 2009; Dridi, 2021).


Denetimsiz öğrenme modellerinde işlemler temel olarak girdiler arasında bağlantıların keşfedilmesi ile ilgilidir. Seçilen denetimsiz öğrenme modeline göre verilerle kümeleme, boyut azaltma işlemleri gerçekleştirilir.



Şekil 2.3 Denetimsiz öğrenme modeli

2.1.3 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir etmenin deneme yanılma yolu ile bilinmeyen ortamı öğrenme yöntemidir. Şekil 2.4’de görüldüğü üzere etmen, yaptığı eyleme karşılık çevreden geri bildirimi ödül veya ceza olarak alır, daha sonra elde ettiği bu geri dönüşü kendisini eğitmek ve çevre hakkında bilgi edinmek için kullanır. Amaç, etmenin ödülünü en yüksek değere ulaştırması için en iyi eylemleri seçmesidir. Pekiştirmeli öğrenmede etmen, denetimsiz öğrenme gibi herhangi bir uzman bilgisine ihtiyaç duymadan eylemleri deneyerek politika oluşturur. Pekiştirmeli öğrenmenin temelinde herhangi bir durumda etmenin o ana kadar öğrendiği bilgiden yararlanması veya o durumda hiç denenmemiş eylemleri deneyerek yeni eylemler keşfetmesi arasında seçim yapılması problemi yer alır (NAEEM ve ark., 2020).



Şekil 2.4 Pekiştirmeli öğrenme modeli


2.2 Yapay Sinir Ağları

Yapay sinir ağları, insanın beyinde gerçekleşen süreçleri simüle eden, biyolojik bir sinir sisteminden ilham alınarak tasarlanmış hesaplama ağlarıdır (Park ve ark., 2016).

2.2.1 İnsan Beyni ve Sinir Sistemi Yapısı

İnsan sinir sisteminin merkezinde bilgileri alan, işleyen ve ona uygun karar veren beyin durur. Reseptörler dışarıdan gelen uyarıları beyne ileten elektriksel sinyaller üretir (Haykin S., 2009). Beyin 10 milyar nöron ve bu nöronları birbirine bağlayan 60 trilyon sinapstan veya bağlantıdan oluştuğu tahmin edilmektedir (Shepherd & Koch, 1990).


Yetişkin bir beyinde çalışma mekanizması nöronlar arasında yeni sinaptik bağlantıların yaratılması ve mevcut sinapsların düzenlenmesi ile gerçekleşmektedir. Şekil 2.5'deki gibi pürüzsüz yüzeye, az dallanmış ve uzun yapıya sahip aksonlar, iletim kanalları ve algılayıcı düzensiz yüzeye sahip ve daha fazla dallanan yapıya sahip olan dendritler plastisite mekanizmasına yardımcı olurlar (Freeman, 1975).



Şekil 2.5 İnsan sinir modeli yapısı (Haykin S., 1998)

2.2.2 Nöron Modeli

Nöron, yapay sinir ağında en temel bilgi işleme birimidir. Bir nöronun temel yapısı Şekil 2.6'da gösterilmiştir. Nöral modelde herhangi k nöronuna bağlanan j sinapsının girişindeki x_j sinyali w_{kj} ağırlığı ile çarpılır ve toplayıcıya eklenir. Toplayıcıya giren bias değeri sinyal ve ağırlık çarpımı ile toplanır ve aktivasyon fonksiyonuna girer.



Şekil 2.6 Nöron modeli

Matematiksel olarak k nöronu Denklem 2.1 ve 2.2’de ifade edildiği gibi yazılabilir:


$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (2.1)$$

$$y_k = \varphi(v_k + b_k) \quad (2.2)$$

Nöronun değerini temsil eden v_k değeri nörona giren tüm değerlerin ağırlıklar ile çarpılmasının toplamını, y_k değeri ise bu toplam ifadesinin bias değeri ile toplamının aktivasyon fonksiyonunda hesaplanmış değerini temsil eder.

2.2.3 Tek Katmanlı Ağlar


Tek katmanlı sinir ağında Şekil 2.7’de gösterildiği gibi nöronlar bir katman olarak düzenlenir. Nöronların çıkışları doğrudan çıkış katmanına yansır. Bu tip ağlara ileri beslemeli ağlar denir. Kaynak düğümlerin girişleri katman olarak sayılmaz.



Şekil 2.7 Tek katmanlı ağ (Haykin S., 1998)

2.2.4 Çok Katmanlı Ağlar

İleri beslemeli ağın diğer bir türü çok katmanlı ağlardır. Tek katmanlı yapıdan farklı olarak burada Şekil 2.8’de görüldüğü gibi giriş veya çıkış katmanında görünmeyen “gizli” katman veya katmanlar bulunmaktadır. Gizli katmanın amacı girdi katmanından alınan veriyi ağırlıklandırarak bir aktivasyon fonksiyonu aracılığı ile çıktı katmanına iletmektir. Bu sayede gizli katman, karmaşık verilerde bulunan örüntülerin öğrenilmesini kolaylaştırmaktadır.



Şekil 2.8 Çok katmanlı ağlar (Haykin S., 1998)

2.3 Derin Öğrenme

Diğer adı temsili öğrenme (Bengio ve ark., 2013) olan ve yaygın olarak kullanılan derin öğrenme Şekil 2.9'da gösterildiği gibi yapay zeka ve makine öğrenmesinin bir alt dalıdır. Derin öğrenme metin madenciliği (Amrit ve ark., 2017), istenmeyen e-posta algılama (Crawford ve ark., 2015), video önerme (Deldjoo ve ark., 2016), görüntü sınıflandırma (Al-Dulaimi ve ark., 2019) gibi birçok uygulamada kullanılmaktadır.


Derin öğrenme algoritmaları ile otomatik şekilde veriden özellik çıkarılabilmektedir. Bu modeller, ilk katmanlarda düşük seviyeli, son katmanlar ise yüksek seviyeli öznetelik çıkarmaktadırlar. Derin öğrenme mimarisi, farklı olayları kullanarak insan beyni gibi veriden otomatik çıkarım yapabilmektedir (Alzubaidi ve ark., 2021).



Şekil 2.9 Yapay zeka ve makine öğrenmesinin alt dalı olarak derin öğrenme modeli

2.3.1 Evrişimsel Sinir Ağları

Derin öğrenme yöntemleri arasında en yaygın olarak kullanılanlardan bir tanesi Evrişimsel Sinir Ağlarıdır (ESA). ESA'lar kendi öncülerine göre insan denetimi olmadan öznitelikleri otomatik olarak tanımlar (Gu ve ark., 2018). Bilgisayarlı görü, yüz tanıma (Fang ve ark., 2020), konuşma işleme (Palaz ve ark. 2019) gibi birçok alanda ESA'lar kullanılmaktadır. Geleneksel sinir ağlarından farklı olarak ESA'lar görüntü gibi iki boyutlu verilerden tam yararlanmak için kullanılır. Bu işlem az sayıda parametre kullanarak eğitim sürecini basitleştirir. Çok katmanlı algılayıcı yapısına benzeyen bu yapı Şekil 2.10'da gösterildiği gibi bir dizi katmandan oluşur (Alzubaidi ve ark., 2021). Bu katmanlar evrişim katmanı, havuzlama katmanı, aktivasyon katmanı, tam bağlı katmanlarıdır. Ayrıca seyreltme, yığın normalizasyon gibi düzenlileştirme (regülerizasyon) işlemleri mevcuttur.



Şekil 2.10 Evrişimsel sinir ağı modeli

2.3.1.1 Evrişim Katmanı

ESA mimarisinin en önemli bileşeni olan evrişim katmanı, bir dizi çekirdek olarak adlandırılan filtreden oluşur. Evrişim katmanının amacı N boyutlu metriğe sahip girdi verisinin özellik haritasını çıkarmaktır.


Çekirdek, ağırlık olarak tanımlanan ayrık sayı veya değerlerden oluşan bir matristir. ESA eğitiminin başlangıcında ağırlıklar rastgele atanır. Bu ağırlıklar eğitim sürecinde düzenlenir ve veriden önemli özellikleri çıkarmayı öğrenir.

Evrişim işlemi çekirdek matrisinin Şekil 2.11’de görüldüğü üzere girdi verisi üzerinde dolaşması ile gerçekleşir. Örnek olarak RGB görüntüler üç kanallı bir veri iken gri tonlamalı görüntüler ise tek kanallı bir veridir. Şekilde verilmiş büyük matris girdi verisini, yeşil matris ise çekirdek matrisini temsil eder. Çekirdek matrisi girdi matrisi üzerinde yatay ve dikey olarak kayarak dolaşır. Bu işlem daha fazla kayma alanı kalmayana kadar devam eder. Çekirdek matrisi genellikle 1×1 , 3×3 , 5×5 ve 7×7 boyutlarında seçilmektedir.


Çekirdek matrisinin girdi matrisi üzerinde bulunduğu bölgedeki değerler ile skaler çarpımı gerçekleşir ve bu değerler toplanır. Kayma işleminin bitmesi ile yeni matris elde edilmiş olur. Evrişim işleminden geçmiş olan matrisin boyutu, giriş matrisinden daha küçük olur. Eğer aynı boyutlu matris elde edilmek istenirse bu

zaman çekirdek matrisinin orta noktası, giriş matrisinin köşesine gelecek şekilde yerleştirilir.


Adım - 1




Adım - 2




Adım - 3




Adım - 4



Adım - 5



Adım - N



Şekil 2.11 Evrişim işlemi (Haykin S., 2009)

Çekirdek matrisinin adım değerleri ve başlangıç noktaları değiştirilebilir özelliklerdir. Bu değerlerin değiştirilmesi ile özellik haritasının boyutları değişir. Ama genellikle burada amaç elde edilmiş yeni matrisin önceki matrise göre daha küçük boyutta olmasıdır.

Renkli görüntünün 3 kanaldan oluşmasından dolayı, girişin bir renkli resim olması durumunda evrişim işleminin çıktısı 3 boyutlu bir matris olmaktadır. Fakat

renklerin önem taşımadığı durumlarda iş yükünü azaltmak için girdi resimleri siyah beyaz olarak kullanılmaktadır.


Evrişim işlemi gerçekleştikten sonra elde edilen özellik haritası daha yüksek seviyeli özellikleri çıkarmak için bir sonraki evrişim katmanına giriş olarak uygulanır. Bu işlemde filtre sonucunda elde edilen özellik haritasının konuma bağlı oluşu modelin performansını düşürmektedir. Bu durumda havuzlama yöntemi ile daha büyük kayma adımı ve doldurma yöntemi ile görüntünün daha yüksek seviyeli özellikler çıkarması sağlanabilir.

2.3.1.2 Havuzlama Katmanı

Havuzlama katmanı, özellik haritalarının alt örneklemesini oluşturmak için kullanılır. Bu işlem evrişim işleminin ardından gerçekleştirilir. Bu işlemin amacı, havuzlama aşamasının her adımında baskın bilgileri koruyarak daha küçük özellik haritasının oluşturulmasıdır. Havuzlama, evrişim işleminde doldurma ve daha büyük kayma adımı ile elde edilen yüksek seviyeli özelliklerin elde edilmesi için kullanılan başka bir yöntemdir.

Farklı havuzlama katmanlarında kullanılmak üzere farklı havuzlama yöntemleri vardır. En yaygın kullanılan havuzlama yöntemleri ağaç havuzlama, kapılı havuzlama, maksimum havuzlama, ortalama havuzlama, global ortalama havuzlama ve global maksimum havuzlama yöntemleridir. Şekil 2.12’de ortalama havuzlama, global ortalama havuzlama ve maksimum havuzlama işlemlerinin örneği verilmiştir.

Ortalama havuzlama işleminde havuzlama filtresi üzerinde durduğu alanda bulunan değerlerin ortalamasını alarak yeni elde edilecek matrisin ilgili konumuna yerleştirir. Daha sonra havuzlama filtresi, evrişim katmanında olduğu gibi daha fazla kayma alanı kalmayana kadar görüntü üzerinde kayarak yeni özellik haritası oluşturur. Maksimum havuzlama yönteminde ise filtre, içerisinde kalan girdi verisinin en büyük değerini alarak yeni özellik haritasını oluşturur. Global ortalama havuzlama yönteminde ise tüm görüntünün ortalama değeri elde edilerek özellik matrisi çıkarılır.



Şekil 2.12 Havuzlama yöntemleri

2.3.1.3 Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu, nöronların uygun şekilde ateşlenerek girdi verisini çıktı verisine eşleştirmek için kullanılan bir fonksiyondur. Girdi değeri, bias ve ağırlıklar ile hesaplanmış nöron çıkışıdır. Bu aktivasyon fonksiyonu ilgili girdiye göre nöronu ateşleme kararını verir. Fonksiyonlar ayrıca ESA' lara ekstra karmaşık yapıları öğrenme yeteneği verir. Yaygın aktivasyon fonksiyonları aşağıda belirtilmiştir

Sigmoid Fonksiyonu: Girişi gerçek sayı olan bu fonksiyon 0 ile 1 arasında bir çıkış değeri üretir ve Şekil 2.13(a)'da gösterildiği gibi S şeklinde bir görünüme sahiptir. Sigmoid fonksiyonu denklem 2.1'de gösterildiği gibi ifade edilir:


$$f(x)_{\text{sigm}} = \frac{1}{1 + e^{-x}} \quad (2.1)$$

Tanh Fonksiyonu: Girişi sigmoid fonksiyonu gibi gerçek sayılar olan Tanh fonksiyonunun çıkışı Şekil 2.13(b)'de gösterildiği gibi -1 ile 1 arasındadır. Tanh fonksiyonu denklem 2.2'de gösterildiği gibi ifade edilir:

$$f(x)_{\text{tanh}} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

ReLU Fonksiyonu: ESA yapılarında en çok kullanılan fonksiyondur. Şekil 2.13(c)'de gösterildiği gibi tüm giriş değerlerini pozitif değerlere dönüştürür. ReLU fonksiyonu denklem 2.3'de gösterildiği gibi ifade edilir:


$$f(x)_{ReLU} = \max(0, x) \quad (2.3)$$



Şekil 2.13 Aktivasyon fonksiyonları

2.3.1.4 Tam Bağlı Katman

Tam bağlı katmanlar, ESA mimarilerinin sonunda bulunur ve sınıflandırma işlemi için kullanılır. Bu katmanlarda Şekil 2.14'de gösterildiği gibi her bir nöron, bir önceki katmanın nöronlarına bağlıdır. Tam bağlı katmalardan oluşan ağın girişi son havuzlama veya son evrişim katmanının çıkışından gelir. Bu girdi, özellik haritalarını oluşturan bir vektör biçimindedir.



Şekil 2.14 Tam bağlı katman

2.3.1.5 Seyreltme

Genelleme işlemi için yaygın olarak kullanılan bu teknik her eğitim aşamasında nöronları rastgele düşürür veya modelden atar. Bu durumda o nöronlar ve nöron bağlantıları yok sayılır. Bunun amacı özellik seçim gücünü tüm nöronlara dağıtmak ve modeli farklı bağımsız özellikler öğrenmeye zorlamaktır. Ayrıca bu yöntem aşırı öğrenme probleminin önüne de geçmektedir. Buna rağmen test işlemi sırasında tahmin etmek için tam ölçekli ağ kullanılır.

2.3.1.6 Yığın Normalizasyon

Yığın normalizasyon yöntemi, çıktı aktivasyonlarının performanslarını sağlar. Bu performans Gauss dağılım birimini takip eder. Her katmandaki çıktıdan ortalamayı çıkarıp standart sapmaya bölmek çıktıyı normalleştirir. Ön işleme görevi gören bu katmanın aktivasyon katmanlarına uygulanması, dahili kovaryans kaymasını azaltmak içindir. Bu kayma, farklı kaynaklardan toplanmış görüntülerin eğitimleri sırasında sürekli ağırlık güncellemesi maliyete neden olacaktır. Fakat yığın normalizasyon bu maliyeti en aza indirmek için kullanılır.

2.3.2 Ön Eğitilmiş Ağlar

Son 10 yılda farklı araştırma grupları tarafından birçok ESA mimarisi önerilmiştir. Bu modellerin amacı farklı uygulamaların performanslarını iyileştirmektir. ESA'ların tarihi, el yazısı rakamlarını tanımak için kullanılan LeNet (LeCun ve ark., 1995) ile başlamıştır. Krizhevsky ve ark. tarafından önerilen görüntü tanıma ve sınıflandırma alanlarında yenilikçi sonuçlar elde etmiş AlexNet (Krizhevsky, Sutskever, & Hinton, 2017) mimarisi yaygın biçimde kabul görmektedir. Alexnet mimarisi sonrasında VGG (Simonyan & Zisserman, 2014), GoogleNet (Szegedy ve ark., 2015), ResNet (He ve ark., 2016), Xception (Chollet, 2017) vb. gibi bir çok başarılı ESA mimariler ortaya çıkmıştır. Bu modellerin eğitilmesi ve test edilmesinde ImageNet (Deng ve ark., 2009), CIFAR-10, CIFAR-100 (CIFAR-10 and CIFAR-100 datasets), MNIST (Fatahi, 2014) veri setleri yaygın olarak kullanılmaktadır. ESA mimarilerinde en yeni gelişmeler ağ derinliğinin değişmesi ile elde edilmiştir. Bu ağlar ön eğitilmiş sinir ağları olarak da ifade edilmektedir. Yaygın olarak kullanılan ve ayrıca bu çalışmada da tercih edilmiş ağ modellerinin yapıları aşağıdaki bölümde belirtilmiştir.


2.3.2.1 VGG

ESA'ların görüntü tanıma işlemlerinde etkinliği kabul edildikten sonra Simonyan ve Zisserman tarafından Görsel Geometri Grubu – Visual Geometry Group (VGG) adı verilen model önerilmiştir. Bu model, kendi öncüleri ZefNet (Zeiler & Fergus, 2014) ve AlexNet mimarilerinden 19 adet daha fazla katmana sahiptir.

VGG ağında kendi öncüsü ZefNet mimarisinin aksine 5×5 ve 11×11 ölçüsünde filtre yerine 3×3 boyutunda filtre yerleştirilmiştir Şekil 2.15'de gösterildiği gibi VGG modelinde 224×224 ölçülü giriş katmanında sonra gelen evrişim katmanından ardından ölçüleri düşürmek için havuzlama katmanı mevcuttur. Kullanılabilir filtre sayısına bakacak olursak, önce 128'e, sonra 256'ya çıkarabileceğimiz 64 civarında filtre mevcuttur. Son katmanlarda 512 filtre kullanılmaktadır. VGG16 ve VGG19 modelleri arasında temel fark evrişim katmanı sayısı farkıdır.

Ek olarak, VGG mimarisinde evrişim katmanlarının ortasına 1×1 ölçüsünde filtre eklenerek ağ karmaşıklığı düzenlenmiştir. Ağ ayarlarında çözünürlüğü korumak


için dolgu uygulanırken, VGG mimarisinde maksimum havuzlama katmanı eklenmiştir. VGG mimarisinin eksik yanı 140 milyon parametre kullanmasından dolayı hesaplama süresinin yüksek olmasıdır.



Şekil 2.15 VGG16 (a) ve VGG 19 (b) mimarisi yapısı (Wang ve ark., 2020)

2.3.2.2 ResNet


ILSVRC yarışmasının 2015 yılı kazananı olan ResNet mimarisinin (He ve ark., 2016) özelliği öncülerinde var olan kaybolan gradyan sorunun ortadan kaldırılmasıdır. ResNet mimarisinin 34 katmandan 1202 katmana kadar farklı derinliklere sahip olan versiyonları tasarlanmıştır. En yaygını ise Şekil 2.16'da gösterilen 49 evrişim katmanı artı bir tam bağlı katmandan oluşan ResNet50 mimarisidir. ResNet mimarisinin ana fikri, Highway ağlarında derin ağ eğitimlerinde adresleme sorununun ortadan kaldırılması için baypas yolu konseptinin kullanılmasıdır. ResNet parametresiz ve veriden bağımsız olarak çapraz katman bağlantısını etkinleştirmek için kısa yol sunmaktadır. Bu öneri gradyan azalma sorununu ortadan kaldırmaktadır. 152 katman derinliği ile VGG mimarisinin 8 katı derinliğe sahiptir. Fakat VGG ile kıyaslandığında daha düşük hesaplama karmaşıklığına sahiptir.



Şekil 2.16 ResNet50 mimarisi yapısı (He, Zhang, Ren, & Sun, 2016)

2.3.2.3 Xception

Xception mimarsinin (Chollet, 2017) ana özelliği, modelin ayrılabilir evrişime sahip olmasıdır. Model, başlangıç bloğunu daha geniş hale getirip ve 3×3 boyutuna dönüştürüp ardından 1×1 evrişim katmanı ile hesaplama karmaşıklığını azaltmaktadır. Geleneksel ESA mimarisi yalnızca bir dönüşüm segmenti kullanırken, Xception üç dönüşüm segmenti uygulamaktadır. Şekil 2.17’de Xception mimarisinin yapısı gösterilmiştir.




Şekil 2.17 Xception mimarisi yapısı (Srinivasan, et al., 2021)

2.3.3 Transfer Öğrenmesi

Evrişimsel sinir ağlarında iyi bir başarımla elde etmek için büyük miktarda veri gerekmektedir. Gereğinden az sayıda veri eksik öğrenmeye sebebiyet vermektedir. Küçük miktarda veri seti ile eğitimin çözümü transfer öğrenmesi yöntemidir. Transfer öğrenmesi mekanizması ESA modelinin büyük veri ile eğitilmesi ve daha sonradan küçük veri seti ile ince ayar yapılması şeklinde çalışır. Transfer öğrenmesi modeli Şekil 2.18’de verilmiştir.

Öğrenci-öğretmen ve öğreten-öğrenen ilişkisi olarak tanımlanan bu yapıda öğretmen öğrendiği bilgileri doğrudan öğrenciye aktarır ve öğrenci ağırlık ve bozucu değerleri ile modeli optimize eder. Bu aktarım ön eğitilmiş modelin tamamı olabileceği gibi, bir kısmı da olabilir. Modeli sıfırdan eğitmek yerine bu şekilde kullanımı maliyetleri büyük oranda düşürmekte ve model doğruluğunu artırmaktadır.



Şekil 2.18 Transfer öğrenmesi modeli


2.4 Hibrit Modeller

Evrişimsel sinir ağlarının performansını artırmak için hibrit modeller önerilmiştir. Hibrit modeller, ESA mimarisinin veya mimarilerinin herhangi bir kısmında elde edilmiş çıkışların birleştirilmesidir. Belirli bir yöntemi veya yapısı olmayan bu modeller araştırmacılar tarafından probleme özgü seçilmektedir.


Örneğin Xie ve ark. (Xie ve ark., 2017) tarafından önerilen bir hibrit ESA modeli Şekil 2.19’da gösterilmiştir. Bu modelde ESA modelinin ayrı katmanlarında elde edilmiş farklı boyutlardaki özellik haritaları birleştirilmiş ve elde edilen öznitelik vektörü destek vektör makineleri yöntemi kullanılarak sınıflandırmıştır.

Ding ve ark. (Ding ve ark., 2020) önerdiği farklı bir hibrit yöntem Şekil 2.20’de gösterilmiştir. Bu yöntemde bir boyutlu giriş verileri biçimlendirilmiş, elde edilen iki boyutlu veriler ESA mimarisine girdi olarak verilmiştir. Çok katmanlı ağdan elde edilmiş bir boyutlu verilerin özellikleri ile ESA çıkışında elde edilmiş özellikler birleştirilmiş ve tam bağlı katmanda sınıflandırma işlemi gerçekleştirilmiştir.

Rahaman ve ark. (Rahaman ve ark., 2021) tarafından önerilen hibrit ESA modeli Şekil 2.21’de gösterilmiştir. Bu hibrit modelde dört farklı ESA modelinden çıkarılmış öznitelik vektörleri hibrit derin özellik füzyonu yöntemi kullanılarak birleştirilmiş ve elde edilmiş yeni vektör tam bağlı katmanda sınıflandırılmıştır.




Şekil 2.19 Xie ve ark. tarafından önerilen hibrit model




Şekil 2.20 Ding ve ark. tarafından önerilen hibrit model

Hibrit derin özellik füzyonu yöntemi Şekil 2.21’de gösterilmiştir. Bu yöntemde ince ayar yapılmış ön eğitilmiş modellerden elde edilen 1024 boyutundaki öznitelik vektörleri birleştirilerek $N \times 1024$ boyutunda yeni bir öznitelik vektörü elde edilmektedir. Bu yeni oluşturulan öznitelik vektörü tam bağlı ağı giriş olarak uygulanmakta ve sınıflandırma işlemi gerçekleştirilmektedir.



Şekil 2.21 Rahaman ve ark. tarafından önerilen hibrit model



Şekil 2.22 Hibrit derin özellik füzyonu yapısı

Bu çalışmada Rahaman ve ark. (Rahaman ve ark., 2021) tarafından hücre bazlı kadın rahim ağzı kanseri teşhisi uygulaması için önerilmiş ve başarılı sonuçlar elde edilmiş hibrit ESA model yapısı tercih edilmiştir. Bu tez çalışmasında doku bazlı meme kanseri teşhisi uygulamasında kullanılmıştır. Hibrit modelde kullanılacak tekil ESA modelleri için ResNet50, VGG16, VGG19 ve Xception ön eğitilmiş modelleri tercih edilmiştir. En iyi hibrit modelin elde edilmesi için tekil modellerin ikili, üçlü ve dörtlü kombinasyonları oluşturulmuş ve başarımları deneysel olarak analiz edilmiştir.

3.1 Kullanılan Transfer Öğrenmesi Yapısı

ResNet50, VGG16, VGG19 ve Xception ön eğitilmiş modelleri tamamen olduğu gibi kullanılmamış, transfer öğrenmesi yöntemi ile belirli katmanları aktarıldıktan sonra modeller üzerinde ince ayar yapılmıştır. Modellerin genel özellik çıkaran katmanları dondurulmuş şekilde yeni modele aktarılmış ve parametreleri olduğu gibi kullanılmıştır. Bu katmanlardan sonra gelen katmanlar “eğitilebilir” şekilde yeni modele aktarılmış ve modelin ara katmanından elde edilen çıkışlara yeni katmanlar eklenmiştir.

3.1.1 Dondurulmuş Katmanlar

Dondurulmuş katmanlar, ön eğitilmiş modellerden olduğu gibi alınarak oluşturulmuş yeni modele aktarılan katmanları ifade etmektedir. Bu katmanların ilgili ağırlıkları doğrudan yeni modele aktarılmış ve tekrar bir eğitim sürecine dahil edilmeden kullanılmıştır. Tüm ağlar için bu katmanların ortak özelliği genel özellik çıkarma katmanları olmasıdır. Dondurulmuş katmanlar, Şekil 3.1’de gösterildiği gibi ResNet50 ağı için 85. katman, VGG16 ağı için 12. katman, VGG19 ağı için 16. katman ve Xception ağı için 35. katmana kadar olan kısımlardır.

Model Adı	ResNet50	VGG16	VGG19	Xception
Dondurulmuş Katmanlar	0. input_3 . . 85. Conv4_block1_2_bn	0. input_3 . . 12. block4_conv2	0. input_3 . . 16. block4_pool	0. input_3 . . 35. add_2

Şekil 3.1 Transfer öğrenmesi için kullanılan dondurulmuş katmanlar

3.1.2 İnce Ayar Yapılmış ve Yeni Eklenmiş Katmanlar

İnce ayar yapılan katmanlar, veriler üzerinden daha detaylı özellik çıkaran katmanlardır. İyileştirme yapılması için Şekil 3.2’deki gösterildiği üzere ResNet50 modeli için 86-174, VGG16 modeli için 13-18, VGG19 modeli için 17-21, Xception modeli için 34-131 aralığındaki katmanlar “eğitilebilir” şekilde bırakılmıştır. Belirli katmanlardan sonrasına yığın normalizasyon, seyreltme, global maksimum havuzlama, 1024 boyutunda öznitelik vektörü çıkışı veren yoğunluk katmanı, ReLU aktivasyon fonksiyonu ve ikili sınıflandırma yapılması için Softmax aktivasyon fonksiyonu eklenmiştir. Yeni katmanlar, ResNet50 modelinde 87. katman çıkışına, VGG16 modelinde 13. katman çıkışına, VGG19 modelinde 18. Katman çıkışına ve Xception modelinde ise 37. Katman çıkışına eklenmiştir.

Model Adı	ResNet50	VGG16	VGG19	Xception
İnce Ayar Yapılmış Katmanlar	86. conv4_block1_2_relu . . 174. conv5_block3_out	13. block4_conv3 . . 18. block5_pool	17. block5_conv1 . . 21. block5_pool	36. block5_sepconv1_act . . 131. block14_sepconv2_act
Yeni Eklenmiş Katmanlar	Global Maks. Havuzlama Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ (1024), ReLu Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ, Softmax	Global Maks. Havuzlama Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ (1024), ReLu Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ, Softmax	Global Maks. Havuzlama Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ (1024), ReLu Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ, Softmax	Global Maks. Havuzlama Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ (1024), ReLu Yığın Normalleştirme Seyreltme Tam Bağlantılı Ağ, Softmax

Şekil 3.2 İnce ayar yapılmış ve yeni eklenmiş katmanlar


3.2 Oluşturulan Tekli Modellerin Eğitilmesi

Revize edilen dört tekil modelde de ağırlık değeri olarak ImageNet ağınnın ağırlıkları kullanılmaktadır. Toplamda 100 epoch olarak gerçekleştirilen eğitimin ilk 50 epoch’luk bölümünde 10^{-3} öğrenme oranı, geri kalan 50 epoch’luk bölümünde ise 10^{-5} öğrenme oranı ile değeri kullanılmıştır. Eğitim

tamamlandıktan sonra model ve model ağırlıkları hibrit modelde kullanılmak üzere kaydedilmiştir.

3.3 Hibrit Modellerin Oluşturulması

Bu tez çalışmasında, en iyi hibrit modeli belirlemek için Tablo 3.1’de gösterildiği gibi tekli modellerin ikili, üçlü ve dörtlü kombinasyonları şeklinde hibrit modeller oluşturularak performansları ölçülmüştür. Bu işlem gerçekleştirilirken her bir kaydedilmiş tekli model tekrardan çağırılmış ve Şekil 3.2’de gösterilen 1024 adet nöron bulunan katmanın çıkışlarından elde edilen öznitelik vektörleri derin özellik füzyonu yöntemi kullanılarak birleştirilmiştir. Bu durumda ikili model için 2048, üçlü model için 3072, dörtlü model için 4096 boyutunda yeni öznitelik vektörleri elde edilmiştir. Elde edilen bu vektörlere yığın normalizasyon ve seyreltme işleminin ardından Softmax fonksiyonu ile sınıflandırılmıştır. tam bağlı katmana giriş olarak beslenmiştir. Tam bağlı katmanda sınıflandırma işlemi softmax fonksiyonu kullanılarak gerçekleştirilmiştir.



Şekil 3.3 Hibrit model yapıları

Tablo 3.1 Hibrit model kombinasyonları

İkili Hibrit Modeller	Üçlü Hibrit Modeller	Dörtlü Hibrit Model
ResNet50 – VGG16	ResNet50 – VGG16 – VGG19	ResNet50 – VGG16 – VGG19 – Xception
ResNet50 – VGG19	ResNet50 – VGG16 – Xception	
ResNet50 – Xception	ResNet50 – VGG19 – Xception	
VGG16 – VGG19	VGG16 – VGG19 – Xception	

VGG16 – Xception		
VGG19 – Xception		

3.4 Hibrit Modellerin Eğitilmesi

Tablo 3.1’de belirtilen hibrit model kombinasyonları oluşturulduktan sonra Şekil 3.3’de gösterilen hibrit model yapılarındaki tam bağlı katmanlar eğitime tabi tutulmuştur. Eğitim sürecinde öğrenme oranı 10^{-3} olarak seçilmiş ve eğitim 200 epoch olarak gerçekleştirilmiştir.




4.1 Veri Setleri

Çalışmada meme dokusuna ait histopatoloji görüntüleri için CAMELYON ve BreakHis veri setleri kullanılmıştır.

4.1.1 CAMELYON Veri Seti

CAMELYON veri seti, Radboud Üniversitesi Tıbbi merkezinin etik kurul izni ile Hollanda'nın the RUMC, the Utrecht University Medical Center (UMCU), the Rijnstate Hospital (RST), the Canisius-Wilhelmina Hospital (CWZ), ve LabPON (LPON) gibi beş farklı sağlık kuruluşundan toplanmış patoloji slayt görüntülerinden oluşmaktadır. Verilerin tamamı patologlar tarafından yorumlanmıştır. Görüntüler TIFF formatında olup, patoloji tarayıcıları aracılığı ile taramış ve Automated Slide Analysis Platform (ASAP) yorumlama yazılımı ile üzerinde tümör bölgelerinin işaretlemesi gerçekleştirilmiştir. Veri setinden 1399 adet tam slayt görüntüsü olup, toplamda 2.95 terabayt veri boyutuna sahiptir. Şekil 4.1'de bu veri setinden alınmış örnek görüntüler gösterilmiştir.




Şekil 4.1 CAMELYON veri setine ait örnek görüntüleri

4.1.2 BreakeHis Veri Seti

BreakeHis veri seti, Şekil 4.2’de gösterildiği gibi 82 hastadan toplanmış dört farklı (40X, 100X, 200X ve 400X) büyütme oranına sahip meme tümörü mikroskopik görüntülerinden oluşmaktadır. Veri seti, P&D Laboratuvarı ve Parana, Brezilya merkezli Patolojik Anatomi ve Sitopatoloji işbirliği ile 2480 iyi huylu, 5429 kötü huylu olmak üzere toplamda 9109 adet görüntüden oluşturulmuştur. İyi huylu tümör sınıfında bulunan görüntüler herhangi bir malignite kriteri ile eşleşmeyen bir lezyona ait görüntülerdir. Kötü huylu tümörler ise lezyon, lokal invaziv ve metastaza sebebiyet verebilecek tümör türleridir.

Çalışmada 400X büyütme oranına sahip görüntüler kullanılmıştır. Veriler, kısmi mastektomi veya eksizyonel biyopsi olarak adlandırılan SOB (Slice Biopsy) yöntemi ile toplanılmıştır.




Şekil 4.2 BreakeHis veri Setine ait 40X, 100X, 200X, 400X büyütülmüş meme dokusu görüntüsü (Spanhol ve ark., 2015)


4.2 Verilerin Hazırlanması

4.2.1 CAMELYON Veri Setinin Hazırlanması

CAMELYON veri seti, yayınlanmış resmi yarışma sayfası olan camelyon17.grand-challenge.org adresinden indirilmiştir. Görüntüler Şekil 4.3’de görüldüğü gibi ASAP yazılımı ile görüntülenmiş ve tümör bölgelerinin bulunduğu XML uzantılı dosyalar yüklenmiştir. Ardından tümör bölgesi içerisinde alanı en büyük olacak şekilde dikdörtgen çizilmiştir. Çizilmiş dikdörtgen koordinatları yeni XML dosyasına kaydedilmiştir. OpenSlide kütüphanesi ile ilgili koordinatlar dosyadan okunmuş ve Tam Slayt görüntüsünden Şekil 4.4’deki gibi 225x225 piksel ölçüsünde, 50 normal ve 50 tümör tam slayt görüntüsünden her sınıfa ait 6000 adet olmak üzere toplamda 12000 adet görüntü oluşturulmuştur. Verilerin %60’ı eğitim, %20’si doğrulama ve %20’si test için kullanılmıştır.



Şekil 4.3 ASAP yazılımı üzerinde işaretlenmiş tümör bölgesi ve içerisine çizilmiş bölünecek olan dikdörtgen alan




Şekil 4.4 225x225 piksel ölçüsünde bölümlenmiş doku görüntüsü

4.2.2 BreakHis Veri Setinin Hazırlanması

BreakHis 400x veri seti görüntüleri Google şirketine ait Kaggle platformundan indirilmiştir. Veri seti içerisinde 700x460 piksel ölçülerinde 547 adet benign ve 1148 adet malign histopatolojik meme görüntüsü mevcuttur. Veri setinden Şekil

4.5’de olduđu gibi 225x225 piksel ölçüsünde 2110 benign ve 2110 malign olmak üzere toplamda 4220 adet görüntü elde edilmiştir. Verilerin %60’ı eğitim, %20’si doğrulama ve %20’si test için kullanılmıştır.



Şekil 4.5 BreaKHis veri setinden elde edilmiş 225x225 piksel ölçüsünde doku görüntüsü

5.1 Başarım Metrikleri

Bu çalışmada deneysel sonuçlarının gösterilmesinde her bir model için karışıklık matrislerinden yararlanılmıştır. Kullanılan karışıklık matrisinin yapısı Şekil 5.1’de gösterilmiştir. Deneysel çalışmalarda başarımlar ölçütleri olarak tüm analizlerde kesinlik, duyarlılık, F1 skoru ve doğruluk oranı metrikleri kullanılmıştır. Bu metrikler ile ilgili formüller sırası ile 5.1, 5.2, 5.3 ve 5.4’de gösterilmiştir.

Gerçek Değer	Tahmin Edilen Değer	
	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Doğru	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Yanlış	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Şekil 5.1 Karışıklık matrisi yapısı

$$Kesinlik = \frac{DP}{DP + YP} \quad 5.1$$


$$Duyarlılık = \frac{DP}{DP + YN} \quad 5.2$$

$$F1 = \frac{2 \times Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \quad 5.3$$


$$Doğruluk = \frac{DP + DN}{DP + YN + YP + DN} \quad 5.4$$

5.2 Tekli Modeller İle Elde Edilen Deneysel Sonuçlar

Çalışmada kullanılmış ResNet50, VGG16, VGG19 ve Xception ön eğitilmiş ESA modellerinin Camelyon ve BreakHis veri setleri üzerindeki deneysel sonuçlarını gösteren karışıklık matrisleri Şekil 5.2 ve Şekil 5.3’de ve elde edilen başarımlar Tablo 5.1 ve Tablo 5.2’de verilmiştir.



Şekil 5.2 Tekli modellerin CAMELYON veri seti üzerinde karışıklık matrisleri



Şekil 5.3 Tekli modellerin BreakHis veri seti üzerinde karışıklık matrisleri

Tablo 5.1 Tekli modellerin CAMELYON veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50	Normal	0.9620	0.970833333	0.966403982	0.96625
	Tümör	0.9705	0.961666667	0.9660946	
	Ortalama	0.9662	0.96625	0.966249291	
VGG16	Normal	0.9665	0.9625	0.964509395	0.964583333
	Tümör	0.9626	0.966666667	0.964656965	
	Ortalama	0.9645	0.964583333	0.96458318	
VGG19	Normal	0.9587	0.93	0.944162437	0.945
	Tümör	0.9320	0.9600	0.945812808	
	Ortalama	0.9454	0.9450	0.944987622	
Xception	Normal	0.9166	0.9625	0.93902439	0.9375
	Tümör	0.9605	0.9125	0.935897436	
	Ortalama	0.9385	0.9375	0.937460913	

Tablo 5.2 Tekli modellerin BreakeHis veri seti üzerindeki sonuçları


Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50	Normal	0.9382	0.9715	0.9545	0.9537
	Tümör	0.9705	0.9360	0.95295	
	Ortalama	0.9543	0.9537	0.95377	
VGG16	Normal	0.9306	0.9857	0.95742	0.9561
	Tümör	0.9848	0.9265	0.95482	
	Ortalama	0.9577	0.9561	0.9561	
VGG19	Normal	0.9276	0.9825	0.9542	0.9529
	Tümör	0.9813	0.9233	0.9514	
	Ortalama	0.9545	0.9529	0.9528	
Xception	Normal	0.8161	0.9573	0.8811	0.8708
	Tümör	0.9484	0.7843	0.8586	
	Ortalama	0.8822	0.8708	0.8698	

Tablo 5.1'den görüldüğü gibi CAMELYON veri seti için en yüksek doğruluk oranına sahip model %96.62 ile ResNet50 modelidir. Daha sonra sırasıyla %96.45 ile VGG16, %94.50 ile VGG19 ve %93.75 ile Xception modelleri gelmektedir. Tablo 5.2'den görüldüğü gibi BreakeHis veri seti için ise en yüksek doğruluk oranı %95.61 şeklinde VGG16 modeli ile elde edilmiştir. Daha sonra sırasıyla %95.37 ile ResNet50, %95.29 ile VGG19 ve %87.08 ile Xception modelleri gelmektedir.


CAMELYON veri seti için ortalama F1 Skoru değer sıralaması 0.9662 ile ResNet50, 0.9645 ile VGG16, 0.9449 ile VGG19, 0.9374 ile Xception şeklinde sıralanmıştır. BreakeHis veri seti için ise F1 Skoru sıralaması 0.9561 ile VGG16, 0.9537 ile ResNet50, 0.9528 ile VGG19 ve 0.8698 ile Xception şeklindedir.

5.3 İkili Hibrit Modeller İle Elde Edilen Deneysel Sonuçlar

Çalışmada kullanılmış ResNet50 – VGG16, ResNet50 – VGG19, ResNet50 – Xception, VGG16 – VGG19, VGG16 – Xception ve VGG19 – Xception ikili hibrit modellerin CAMELYON ve BreakHis veri setleri üzerindeki deneysel sonuçlarını gösteren karışıklık matrisleri Şekil 5.4 ve Şekil 5.5’de gösterilmiştir. Elde edilen başarımlar Tablo 5.3 ve Tablo 5.4’de verilmiştir.



Şekil 5.4 İkili hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri



Şekil 5.5 İkili hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri

Tablo 5.3 İkili hibrit modellerin CAMELYON veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16	Normal	0.9595	0.9683	0.9639	0.9637
	Tümör	0.9680	0.9591	0.9635	
	Ortalama	0.9637	0.9637	0.9637	
ResNet50 – VGG19	Normal	0.9645	0.9750	0.9697	0.9695
	Tümör	0.9747	0.9641	0.9694	
	Ortalama	0.9696	0.9695	0.9695	
ResNet50 – Xception	Normal	0.9517	0.9858	0.9684	0.9679
	Tümör	0.9853	0.9500	0.9673	
	Ortalama	0.9685	0.9679	0.9679	
VGG16 – VGG19	Normal	0.9612	0.9716	0.9664	0.9662
	Tümör	0.9713	0.9608	0.9660	
	Ortalama	0.9663	0.9662	0.9662	
VGG16 – Xception	Normal	0.9621	0.9750	0.9685	0.9683
	Tümör	0.9746	0.9616	0.9681	
	Ortalama	0.9684	0.9683	0.9683	
VGG19 – Xception	Normal	0.9539	0.9675	0.9606	0.9604
	Tümör	0.9670	0.9533	0.9601	
	Ortalama	0.9605	0.9604	0.9604	

Tablo 5.4 İkili hibrit modellerin BreaKHis veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16	Normal	0.9785	0.9715	0.9750	0.9751
	Tümör	0.9717	0.9786	0.9752	
	Ortalama	0.9751	0.9751	0.9751	
ResNet50 – VGG19	Normal	0.9716	0.9763	0.9739	0.9739
	Tümör	0.9761	0.9715	0.9738	
	Ortalama	0.9739	0.9739	0.9739	
ResNet50 – Xception	Normal	0.9783	0.9620	0.9701	0.9703
	Tümör	0.9627	0.9786	0.9706	
	Ortalama	0.9705	0.9703	0.9703	
VGG16 – VGG19	Normal	0.9786	0.9763	0.9774	0.9774
	Tümör	0.9763	0.9786	0.9775	
	Ortalama	0.9774	0.9774	0.9774	
VGG16 – Xception	Normal	0.9714	0.9691	0.9703	0.9703
	Tümör	0.9692	0.9715	0.9704	
	Ortalama	0.9703	0.9703	0.9703	
VGG19 – Xception	Normal	0.9518	0.9360	0.9438	0.9443
	Tümör	0.9370	0.9526	0.9447	
	Ortalama	0.9444	0.9443	0.9443	


Tablo 5.3'den görüldüğü gibi CAMELYON veri seti için en yüksek doğruluk oranına sahip model %96.95 ile VGG19 – ResNet50 hibrit modelidir. Daha sonra sırasıyla %96.83 ile VGG16 – Xception, %96.79 ile Xception – ResNet50, %96.62

ile VGG16 – VGG19, %96,37 ile VGG16 – ResNet50 ve %96,04 ile VGG19 – Xception ikili hibrit modelleri gelmektedir. Tablo 5.4’den görüldüğü gibi BreakHis veri seti için ise en yüksek doğruluk oranı %97.74 şeklinde VGG16 – VGG19 modeli ile elde edilmiştir. Daha sonra sırasıyla, %97.51 ile VGG16 – ResNet50, %97.39 ile VGG19 – ResNet50, %97.03 ile VGG16 – Xception, %97.03 ile Xception – ResNet50 ve %94.43 ile VGG19 – Xception ikili hibrit modelleri gelmektedir.


CAMELYON veri seti için ortalama F1 Skoru değer sıralaması 0.9695 ile VGG19 – ResNet50, 0.9683 ile VGG16 – Xception, 0.9679 ile ResNet50 – Xception, 0.9662 ile VGG16 – VGG19, 0.9637 ile VGG16 – ResNet50, 0.9604 ile VGG19 – Xception çiftleri şeklindedir. BreakHis veri seti için ise F1 Skoru sıralaması 0.9774 ile VGG16 – VGG19, 0.9751 ile VGG16 – ResNet50, 0.9739 ile VGG19 – ResNet50, 0.9703 ile VGG16 – Xception, 0.9703 ile Xception – ResNet50, 0.9443 ile VGG19 – Xception çiftleri şeklindedir.

5.4 Üçlü Hibrit Modeller İle Elde Edilen Deneysel Sonuçlar

Çalışmada kullanılmış ResNet50 – VGG16 – VGG19, ResNet50 – VGG16 – Xception, ResNet50 – VGG19 – Xception ve VGG16 – VGG19 – Xception üçlü hibrit modellerinin CAMELYON ve BreakHis veri setleri üzerindeki deneysel sonuçlarını gösteren karışıklık matrisleri Şekil 5.6’da ve Şekil 5.7’de ve performansları gösteren tablo Tablo 5.5’de ve Tablo 5.6’da verilmiştir



Şekil 5.6 Üçlü hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri



Şekil 5.7 Üçlü hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri

Tablo 5.5’den görüldüğü gibi CAMELYON veri seti için en yüksek doğruluk oranına sahip model %97.08 ile ResNet50 – VGG16 – Xception üçlü hibrit modelidir. Daha sonra sırasıyla %96.95 ile VGG16 – VGG19 – Xception, %96.66 ile ResNet50 – VGG19 – Xception, %96.16 ile VGG16 – VGG19 – ResNet50 modelleri gelmektedir. Tablo 5.6’dan görüldüğü gibi BreakHis veri seti için ise en yüksek doğruluk oranı %97.27 ile ResNet50 – VGG16 – VGG19 üçlü hibrit modeli ile elde edilmiştir. Daha sonra sırasıyla, %97.03 ile ResNet50 – VGG19 – Xception, %96.80 ile VGG16 – VGG19 – Xception, %96.56 ile ResNet50 – VGG16 – Xception hibrit modelleri gelmektedir.

CAMELYON veri seti için F1 Skoru sıralaması 0.9708 ile ResNet50 – VGG16 – Xception, 0.9695 ile Xception – VGG16 – VGG19, 0.9666 ile ResNet50 – VGG19 – Xception, 0.9616 ile ResNet50 – VGG19 – VGG16, BreakHis veri seti için 0.9727 ile ResNet50 – VGG16 – VGG19, 0.9703 ile ResNet50 – VGG19 – Xception, 0.9680 ile VGG16 – VGG19 – Xception ve 0.9656 ile VGG16 – ResNet50 – Xception şeklindedir.

Tablo 5.5 Üçlü hibrit modellerin CAMELYON veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16 – VGG19	Normal	0.9453	0.9800	0.9623	0.9616
	Tümör	0.9792	0.9433	0.9609	
	Ortalama	0.9622	0.9616	0.9616	
ResNet50 – VGG16 – Xception	Normal	0.9578	0.9850	0.9712	0.9708
	Tümör	0.9845	0.9566	0.9704	
	Ortalama	0.9712	0.9708	0.9708	
ResNet50 – VGG19 – Xception	Normal	0.9494	0.9858	0.9672	0.9666
	Tümör	0.9852	0.9475	0.9660	
	Ortalama	0.9673	0.9666	0.9666	
VGG16 – VGG19 – Xception	Normal	0.9600	0.9800	0.9698	0.9695
	Tümör	0.9795	0.9591	0.9692	
	Ortalama	0.9697	0.9695	0.9695	

Tablo 5.6 Üçlü hibrit modellerin BreakHis veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16 – VGG19	Normal	0.9650	0.9810	0.9729	0.9727
	Tümör	0.9807	0.9644	0.9725	
	Ortalama	0.9728	0.9727	0.9727	
ResNet50 – VGG16 – Xception	Normal	0.9689	0.9620	0.9655	0.9656
	Tümör	0.9623	0.9691	0.9657	
	Ortalama	0.9656	0.9656	0.9656	
ResNet50 – VGG19 – Xception	Normal	0.9783	0.9620	0.9701	0.9703
	Tümör	0.9627	0.9786	0.9706	
	Ortalama	0.9705	0.9703	0.9703	
VGG16 – VGG19 – Xception	Normal	0.9759	0.9597	0.9677	0.9680
	Tümör	0.9603	0.9763	0.9682	
	Ortalama	0.9681	0.9680	0.9680	

5.5 Dörtlü Hibrit Model İle Elde Edilen Deneysel Sonuçlar

Çalışmada kullanılmış ResNet50 – VGG16 – VGG19 – Xception hibrit modelinin CAMELYON ve BreakHis veri setleri üzerindeki deneysel sonuçlarını gösteren karışıklık matrisleri Şekil 5.8’de ve Şekil 5.9’da ve performansları gösteren tablo Tablo 5.7’de ve Tablo 5.8’de verilmiştir.

ResNet – VGG16 – VGG19 – Xception hibrit modelinin CAMELYON veri seti üzerinde doğruluk oranı %96.83, BreakHis veri seti üzerinde ise %96.56 olarak hesaplanmıştır. F1 Skoru ise CAMELYON veri seti için 0.9683, BreakHis veri seti için 0.9656 şeklindedir.

VGG16-VGG19-ResNet50-Xception

1170	30
46	1154

Şekil 5.8 Dörtlü hibrit modellerin CAMELYON veri seti üzerinde karışıklık matrisleri

VGG16-VGG19-ResNet50-Xception

409	13
16	406

Şekil 5.9 Dörtlü hibrit modellerin BreakHis veri seti üzerinde karışıklık matrisleri

Tablo 5.7 Dörtlü hibrit modellerin CAMELYON veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16 – VGG19 – Xception	Normal	0.9621	0.9750	0.9685	0.9683
	Tümör	0.9746	0.9616	0.9681	
	Ortalama	0.9684	0.9683	0.9683	

Tablo 5.8 Dörtlü hibrit modellerin BreakeHis veri seti üzerindeki sonuçları

Model Adı	Sınıf	Kesinlik	Duyarlılık	F1 Skoru	Doğruluk
ResNet50 – VGG16 – VGG19 – Xception	Normal	0.9623	0.9691	0.9657	0.9656
	Tümör	0.9689	0.9620	0.9655	
	Ortalama	0.9656	0.9656	0.9656	

5.6 Deney Sonuçlarının Değerlendirilmesi

Deney sonuçlarından görüldüğü gibi oluşturulan hibrit ESA modelleri ile büyük çoğunlukla tekil modellere kıyasla her iki veri seti için de daha üstün bir başarıml elde edilmiştir. Oluşturulan ikili, üçlü ve dörtlü hibrit ESA modelleri arasından en üstün başarıma sahip olanlar dikkate alındığında ise elde edilen başarıml değerlerinin her zaman tekil modeller ile elde edilen başarıml değerlerinden daha üstün olduğu görülmüştür.

Seçilen tekil modellerin hibrit kombinasyonları üzerinde yapılan başarıml analizleri sonucunda en üstün başarımlı CAMELYON veri seti için ResNet50 – VGG16 - Xception üçlü hibrit ESA modelinin, BreakeHis veri seti için ise VGG16 – VGG19 ikili hibrit ESA modelinin sağladığı görülmektedir. Bu sonuçlar değerlendirildiğinde hibrit model oluşturulması için seçilecek tekil model sayısının artmasının her zaman başarımlı arttırmadığı sonucu ortaya çıkmaktadır.

Benzer şekilde hibrit model oluşturulurken en iyi tekil başarımlı sahip modellerin kullanılmasının her zaman daha iyi başarıml sağlamadığı görülmüştür. Örneğin Tablo 5.5' te CAMELYON veri seti için verilen üçlü hibrit model karşılaştırmalarında görüldüğü gibi, en iyi ilk üç tekil model başarımlı sırasıyla VGG19, VGG16 ve ResNet50 modelleri ile elde edilmiş olmasına karşın VGG16 – ResNet50 – Xception hibrit modeli ile ResNet50 – VGG16 – VGG19 hibrit modeline kıyasla daha yüksek bir başarıml elde edilmiştir.

Ayrıca, bir veri seti için en üstün başarımlı sergileyen hibrit ESA modeli kombinasyonunun başka bir veri seti için aynı başarımlı her zaman sağlayamadığı görülmüştür. Bu durum hibrit model kombinasyonunun veri setine özgü olarak belirlenmesi gerektiği sonucunu ortaya çıkarmıştır.

Bu sonuçlar değerlendirildiğinde, hibrit model yapısının uygulamaya özgü olarak belirlenmesi gerektiği ve bu çalışmada gerçekleştirildiği gibi ön analizler yapılarak en uygun hibrit modelin seçilmesinin daha yüksek başarıma sahip hibrit modellerin belirlenmesi adına gerekli olduğu görülmüştür.



6 SONUÇ VE ÖNERİLER

Bu tez çalışmasında doku bazlı patoloji görüntüleri üzerinden derin özellik füzyonu yöntemine dayalı hibrit ESA modeli kullanılarak meme kanseri teşhisi uygulaması gerçekleştirilmiştir. Çalışmada hibrit ESA modeli oluşturulurken VGG16, VGG19, ResNet50 ve Xception ön eğitilmiş ESA modelleri kullanılmıştır. En iyi hibrit model yapısının belirlenebilmesi için bu tekli modellerin bir araya getirilerek ikili, üçlü ve dörtlü hibrit kombinasyonları elde edilmiş ve oluşturulmuş hibrit modellerin CAMELYON ve BreakHis meme dokusu histopatoloji görüntüleri üzerinde başarımları analiz edilmiştir. Gerçekleştirilen başarımların analizleri sonucunda en üstün teşhis başarımları CAMELYON veri seti için %97.08 doğruluk oranına sahip ResNet50 – VGG16 – Xception, BreakHis veri seti için ise %97.75 doğruluk oranına sahip VGG16 – VGG19 hibrit ESA modelleri ile elde edilmiştir.

Yapılan analizlerde hibrit model oluşturulması için seçilecek tekil model sayısının artmasının her zaman başarımları arttırmadığı, en iyi tekil başarımlara sahip modellerin kullanılmasının her zaman daha iyi başarımlar sağlamadığı ve bir veri seti için en üstün başarımları sergileyen hibrit ESA modeli kombinasyonunun başka bir veri seti için aynı başarımları her zaman sağlayamadığı sonuçları ortaya çıkmıştır.

Bu sonuçlar değerlendirildiğinde, kullanılacak hibrit model yapısının uygulamaya özgü olarak belirlenmesi gerektiği ve bu çalışmada gerçekleştirildiği gibi ön analizler yapılarak en uygun hibrit model yapısının seçilmesinin daha yüksek başarımlara sahip hibrit modellerin belirlenmesi adına gerekli olduğu görülmüştür.

Bu tezin devamı olacak çalışmalarda hibrit modellerin performansını daha da arttırmak adına yeni derin özellik füzyonu yöntemleri geliştirilmesi ve farklı veri setlerinde test edilmesi planlanmaktadır.

- Abedhaliem, A. H., Wahed, M. E., Atiea, M. A., & Metwally, M. S. (2022). A Hybrid Approach for Classification Breast Cancer Histopathology Images. *Frontiers in Scientific Research and Technology*.
- Afonso, L. C., Rosa, G. H., Pereira, C. R., Weber, S. A., Hook, C., Albuquerque, V. H., & Papa, J. P. (2019). A recurrence plot-based approach for Parkinson's disease identification. *Future Generation Computer Systems*, 94, 282-292.
- Ahuja, S., & Angra, S. (2017). Machine learning and its Applications: A Review. *In Big Data Analytics and Computational Intelligence*. IEEE.
- Aksac, A., Demetrick, D., Ozyer, T., & Alhajj, R. (2019). BreCaHAD: a dataset for breast cancer histopathological annotation and diagnosis. *BMC Research Notes*.
- Al-Dulaimi, K., Chandran, V., Nguyen, K., Banks, J., & Tomeo-Reyes, I. (2019). Benchmarking hep-2 specimen cells classification using linear discriminant analysis on higher order spectra features of cell shape. *Pattern Recogn Letters*, 534–541.
- Altaf, M. M. (2021). A hybrid deep learning model for breast cancer diagnosis based on transfer learning and pulse-coupled neural networks. *Mathematical Biosciences and Engineering*, 18(5), 5029-5046.
- Alzubaidi, L., Zhang, J., Humaidi, A., Al-dujaili, A., Duan, Y., Al-Shamma, O., . . . Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*.
- Amrit, C., Paauw, T., Aly, R., & Lavric, M. (2017). dentifying child abuse through text mining and machine learning. *Expert Syst Applications*, 402-418.
- Aresta, G., Araújo, T., Kwok, S., Chennamsetty, S. S., Safwan, M., Alex, V., . . . Ludwig, F. (2019). BACH: Grand challenge on breast cancer histology images. *Medical Image Analysis*, 122-139.

- Arya, M., Mittal, N., & Singh, G. (2018). Clustering Techniques on Pap-smear Images for the Detection of Cervical Cancer. *Journal of Biology and Today's World*, 7, 30-35.
- Avendi, M. R., Kheradvar, A., & Jafarkhani, H. (2016). A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI. *Medical Image Analysis*, 30, 108-119.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation Learning: A Review and New Perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 1798-1828.
- Burhenne, L., Wood, S., D'Orsi, C., Feig, S., & ark., v. (2000). Potential contribution of computer-aided detection to the sensitivity of screening mammography. *Radiology*, 215, 554-562.
- CADUCEUS: An Experimental Expert System for Medical Diagnosis. (1986). In *The AI Business: Commercial Uses of Artificial Intelligence* (pp. 67-80). MIT Press.
- Chen, X.-W., & Lin, X. (2014). Big Data Deep Learning: Challenges and Perspectives. *IEEE Access*, 2, 514-525.
- Chollet, F. (2017). Xception: Deep Learning With Depthwise Separable Convolutions. *IEEE Conference on Computer Vision and Pattern Recognition* (pp. 1251-1258). IEEE.
- CIFAR-10 and CIFAR-100 datasets.* (n.d.). Retrieved from <https://www.cs.toronto.edu/~kriz/cifar.html>
- Crawford, M., Khoshgoftaar, T., Prusa, J., Richter, A., & Al Najada, H. (2015). H. Survey of review spam detection using machine learning techniques. *J Big Data*.
- Dabral, I., Singh, M., & Kumar, K. (2021). Cancer Detection Using Convolutional Neural Network. *ICDLAIR2019*.
- Dandıl, E., Selvi, A., Çevik, K., Yıldırım, M., & Uzun, S. (2021). A Hybrid Method Based on Feature Fusion for Breast Cancer Classification using

- Histopathological Images. *European Journal of Science and Technology*, 129-137.
- de Carvalho Filho, A. O., Silva, A. C., de Paiva, A. C., Nunes, R. A., & Gattass, M. (2017). Computer-Aided Diagnosis of Lung Nodules in Computed Tomography by Using Phylogenetic Diversity, Genetic Algorithm, and SVM. *Journal of Digital Imaging*, 30, 812-822.
- Deldjoo, Y., Elahi, M., Cremonesi, P., Garzotto, F., Piazzolla, P., & Quadrana, M. (2016). Content-Based Video Recommendation System Based On Stylistic Visual Features. *J Data Semantic*, 99–113.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Li, F.-F. (2009). ImageNet: a Large-Scale Hierarchical Image Database. *IEEE Conference on Computer Vision and Pattern Recognition*, 248-255.
- Deniz, E., Şengür, A., Kadiroğlu, Z., Guo, Y., Bajaj, V., & Budak, Ü. (2018). Transfer Learning Based Histopathologic Image Classification For Breast Cancer Detection. *Health Information Science and Systems*.
- Ding, P., Li, J., Wang, L., Wen, M., & Guan, Y. (2020). HYBRID-CNN: An Efficient Scheme for Abnormal Flow Detection in the SDN-Based Smart Grid. *Security and Communication Networks*.
- Dogra, A. (2019). A Brief Review of Breast Cancer Detection via Computer Aided Deep Learning Methods. *International Journal of Engineering Research*, 8(12), 326-331.
- Dridi, S. (2021). *Unsupervised Learning - A systematic Literature Review*.
- Dua, D., & Graff, C. (2019). *UCI Machine Learning Repository*. Retrieved from Breast Cancer Wisconsin (Diagnostic) Data Set: <http://archive.ics.uci.edu/ml>
- Dünya Sağlık Örgütü. (2021, 03 26). *Dünya Sağlık Örgütü*. (Dünya Sağlık Örgütü) Retrieved Ocak 3, 2022, from <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>

- Dünya Sağlık Örgütü. (2022, Ocak 3). *Dünya Sağlık Örgütü*. (Dünya Sağlık Örgütü) Retrieved Ocak 3, 2022, from <https://www.who.int/news-room/fact-sheets/detail/cancer>
- Ehtesham, B. B., Veta, M., Johannes van Diest, P., van Ginneken, B., Karssemeijer, N., Litjens, G., . . . Bult, P. B. (2017). Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. *JAMA*, *318*(22), 2199-2210.
- El-Baz, A., Beache, G. M., Gimelfarb, G., Suzuki, K., Okada, K., Elnakib, A., . . . Abdollahi, B. (2013). Computer-aided diagnosis systems for lung cancer: challenges and methodologies. *International Journal of Biomedical Imaging*.
- Erdem, E., & Tolga, A. (2021). Göğüs Kanseri Histopatolojik Görüntü Sınıflandırması. *BİLİŞİM TEKNOLOJİLERİ DERGİSİ*, 87-94.
- Fang, W., Love, P., Luo, H., & Ding, L. (2020). Computer Vision For Behaviour-Based Safety In Construction: A Review and Future Directions. *Advanced Engineering Informatics*.
- Fatahi, M. (2014). MNIST Handwritten Digits Description and Using.
- Firmino, M., Morais, A. H., Mendoça, R. M., Dantas, M. R., Hekis, H. R., & Valentim, R. (2014). Computer-aided detection system for lung cancer in computed tomography scans: Review and future prospects. *Biomedical Engineering Online*, *13*(41).
- Freeman, W. (1975). *Mass Action in the Nervous System*. New York: Academic Press.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., . . . Cai, J. (2018). Recent Advances In Convolutional Neural Networks. *Pattern Recognition*, 354-377.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). Unsupervised learning. *The Elements of Statistical Learning*, 485-585.
- Haykin, S. (1998). *Neural Networks: a Comprehensive Foundation*. Prentice Hall.

- Haykin, S. (2009). *Neural networks and learning machines*. Upper Saddle River, NJ: Pearson Education.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770-778). IEEE.
- Heidenreich, A., Desgrandschamps, F., & Terrier, F. (2002). Modern approach of diagnosis and management of acute flank pain: review of all imaging modalities. *European Urology*, 41(4), 351-362.
- Hendee, W. R. (1983). The impact of future technology on oncologic diagnosis: Oncologic imaging and diagnosis. *Oncology intelligence*, 9(12), 1851-1865.
- Joseph, A., Abdullahi, M., Junaidu, S., Ibrahim, H., & Chiroma, H. (2022). Improved Multi-Classification of Breast Cancer Histopathological Images Using Handcrafted Features and Deep Neural Network (dense layer). *Intelligent Systems with Applications*.
- Karp, R. M. (1972). Reducibility among Combinatorial Problems. *The IBM Research Symposia Series*. Boston, MA: Springer.
- Kawagishi, M., Chen, B., Furukawa, D., Sekiguchi, H., Sakai, K., Kubo, T., . . . Togashi, K. (2017). A study of computer-aided diagnosis for pulmonary nodule: comparison between classification accuracies using calculated image features and imaging findings annotated by radiologists. *International Journal of Computer Assisted Radiology and Surgery*, 12, 767-776.
- Kotsiantis, S. (2007). Supervised Machine Learning: A Review of Classification Techniques. *Informatica Journal*, 249-268.
- Krizhevsky, A., Hinton, G., & ark, v. (2009). Learning multiple layers of features from tiny images. *Citeseer*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). Imagenet Classification With Deep Convolutional Neural Networks. *ACM*, (pp. 84-90).

- Längkvist, M., Jendeberg, J., Thunberg, P., Loutfi, A., & Lidén, M. (2018). Computer aided detection of ureteral stones in thin slice computed tomography volumes using Convolutional Neural Networks. *Computers in Biology and Medicine*, 97, 153-160.
- Latif, J., Xiao, C., Imran, A., & Tu, S. (2019). Medical Imaging using Machine Learning and Deep Learning Algorithms: A Review. *2019 International Conference on Computing*. IEEE.
- LeCun, Y., & ark., v. (1995). Learning Algorithms For Classification: A Comparison on Handwritten Digit Recognition. *Neural Networks: The Statistical Mechanics Perspective*, 261-276.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436–444.
- Li, F., Tran, L., Thung, K.-H., Ji, S., Shen, D., & Li, J. (2015). A Robust Deep Model for Improved Classification of AD/MCI Patients. *IEEE journal of biomedical and health informatics*, 19(5), 1610–1616.
- Liang, M., Tang, W., Xu, D. M., Jirapatnakul, A. C., Reeves, A. P., Henschke, C. I., & Yankelevitz, D. (2016). Low-Dose CT Screening for Lung Cancer: Computer-aided Detection of Missed Lung Cancers. *Radiology*, 281(1), 279-288.
- Liang, M., Tang, W., Xu, D. M., Jirapatnakul, A. C., Reeves, A. P., Henschke, C. I., & Yankelevitz, D. (2016). Low-dose CT screening for lung cancer: Computer-aided detection of missed lung cancers. *Radiology*, 281(1), 279-288.
- Løberg, M., Lousdal, M. L., Bretthauer, M., & Kalager, M. (2015). Benefits and harms of mammography screening. *Breast Cancer Res*, 17(63), 1-12.
- Miller, R. A., Pople, H. E., & Myers, J. D. (1985). INTERNIST-I, An Experimental Computer-Based Diagnostic Consultant for General Internal Medicine. *New England Journal of Medicine*, 307(8), 468-476.
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236–1246.

- NAEEM, M., RIZVI, S., & Coronato, A. (2020). A Gentle Introduction to Reinforcement Learning and Its Application in Different Fields. *IEEE Access*, 209320-209344.
- Nahid, A.-A., & Kong, Y. (2017). Involvement of Machine Learning for Breast Cancer Image Classification: A Survey. *Computational and Mathematical Methods in Medicine*, 2017, 29.
- Nishio, M., & Nagashima, C. (2017). Computer-aided Diagnosis for Lung Cancer: Usefulness of Nodule Heterogeneity. *Academic Radiology*, 24(3), 328-336.
- Nomura, Y., Higaki, T., Fujita, M., Miki, S., Awaya, Y., Nakanishi, T., . . . Awai, K. (2017). Effects of Iterative Reconstruction Algorithms on Computer-assisted Detection (CAD) Software for Lung Nodules in Ultra-low-dose CT for Lung Cancer Screening. *Academic Radiology*, 24(2), 124-130.
- Nomura, Y., Higaki, T., Fujita, M., Miki, S., Awaya, Y., Nakanishi, T., . . . Awai, K. (2017). Effects of Iterative Reconstruction Algorithms on Computer-assisted Detection (CAD) Software for Lung Nodules in Ultra-low-dose CT for Lung Cancer Screening. *Academic Radiology*, 24(2), 124-130.
- Nover, A. B., Jagtap, S., Anjum, W., Yegingil, H., Shih, W. Y., Shih, W.-H., & Brooks, A. D. (2009). Modern Breast Cancer Detection: A Technological Review. *International Journal of Biomedical Imaging*, 2009.
- Palaz, D., Magimai-Doss, M., & Collobert, R. (2019). End-to-End Acoustic Modeling Using Convolutional Neural Networks For HMM-Based Automatic Speech Recognition. *Speech Communication*, 15-32.
- Park, Y., & Lek, S. (2016). Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. In *Developments in Environmental Modelling* (pp. 123-140).
- Patil, A., Tamboli, D., Meena, S., Anand, D., & Sethi, A. (2019). Breast Cancer Histopathology Image Classification and Localization using Multiple Instance Learning. *2019 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE* (pp. 1-4). IEEE.

- Plissiti, M. E., Dimitrakopoulos, P., Sfikas, G. a., Krikoni, O., & Charchanti, A. (2018). Sipakmed: A New Dataset for Feature and Image Based Classification of Normal and Pathological Cervical Cells in Pap Smear Images. *2018 25th IEEE International Conference on Image Processing (ICIP)*, (pp. 3144-3148).
- Rahaman, M., Li, C., Yao, Y., Kulwa, F., Wu, X., Li, X., & Wang, Q. (2021). DeepCervix: A deep learning-based framework for the classification of cervical cells using hybrid deep feature fusion techniques. *Computers in Biology and Medicine*, 104649.
- Sadoughi, F., Kazemy, Z., Hamedan, F., Owji, L., Rahmanikatifari, M., & Azadboni, T. T. (2018). Artificial intelligence methods for the diagnosis of breast cancer by image processing: a review. *Breast Cancer (Dove Med Press)*, 10, 219-230.
- Seyidbayli, C., & Ulu, C. (2022). PERFORMANCE COMPARISON OF TRANSFER LEARNING BASED CONVOLUTIONAL NEURAL NETWORK MODELS FOR BREAST CANCER CLASSIFICATION. *INTERNATIONAL ISTANBUL CONGRESS OF MULTIDISCIPLINARY SCIENTIFIC RESEARCH*, (s. 33). Istanbul.
- Shepherd, G., & Koch, C. (1990). Introduction to Synaptic Circuits. In G. Shepherd, *The Synaptic Organization* (pp. 3-31). New York: Oxford University Press.
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., . . . Summers, R. M. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, 35, 1285-1298.
- Shortliffe, E. H., & Buchanan, B. G. (1975). A model of inexact reasoning in medicine. *Mathematical Biosciences*, 23(3-4), 351-379.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv*.

- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks For Large-Scale Image Recognition. *arXiv*.
- Singh, S., Gupta, P., & Sharma, M. (2011). Breast Cancer Detection and Classification of Histopathological Images. *International Journal of Engineering Science and Technology*.
- Song, J., Qin, S., & Zhang, P. (2016). Chinese text categorization based on deep belief networks. *2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS)*, (pp. 1-5).
- Spanhol, F., Soares de Oliveira, L., Petitjean, C., & Heutte, L. (2015). A Dataset for Breast Cancer Histopathological Image Classification. *IEEE transactions on bio-medical engineering*, 63.
- Srinivasan, K., Garg, L., Datta, D., Alaboudi, A., Zaman, N., Agarwal, R., & Thomas, A. (2021). Performance Comparison of Deep CNN Models for Detecting Driver's Distraction. *Computers, Materials & Continua*, 4109–4124.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*. Boston, MA.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015). Going Deeper With Convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (s. 1-9). IEEE.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning*, (pp. 6105-6114).
- Tearney, G. J., Brezinski, M. E., Bouma, B. E., Boppart, S. A., Pitris, C., Southern, J. F., & Fujimoto, J. G. (1997). In Vivo Endoscopic Optical Biopsy with Optical Coherence Tomography. *Science*, 276(5321), 2037-2039.
- Vo-Le, C., Son, N. H., Van Muoi, P., & Phuong, N. H. (2021). Breast Cancer Detection from Histopathological Biopsy Images Using Transfer Learning.

2020 IEEE Eighth International Conference on Communications and Electronics (ICCE), (pp. 408-412).

- Wang, H., Tian, J., Zhang, C., Luo, Y., Wang, X., & Li, J. (2020). An improved deep learning approach and its applications on colonic polyp images detection. *BMC Medical Imaging*.
- Wang, J., Liu, Q., Xie, H., Yang, Z., & Zhou, H. (2020). Boosted EfficientNet: Detection of Lymph Node Metastases in Breast Cancer Using Convolutional Neural Network. *ArXiv*.
- Wang, Z., Dong, N., Dai, W., Rosario, S., & Xing, E. (2018). Classification of Breast Cancer Histopathological Images using Convolutional Neural Networks with Hierarchical Loss and Global Pooling.
- Wei, J., He, J., Chen, K., Zhou, Y., & Tang, Z. (2017). Collaborative filtering and deep learning based recommendation system for cold start items. *Expert Systems with Applications*, 69, 29-39.
- Xie, G.-S., Zhang, X.-Y., Yan, S., & Liu, C.-L. (2017). Hybrid CNN and Dictionary-Based Models for Scene Recognition and Domain Adaptation. *IEEE Transactions on Circuits and Systems for Video Technology*, 1263-1274.
- Yan, R., Ren, F., Zihao, W., Wang, L., Zhang, T., Liu, Y., . . . Zhang, F. (2020). Breast Cancer Histopathological Image Classification Using A Hybrid Deep Neural Network. *Methods*, 52-60.
- Yanase, J., & Triantaphyllou, E. (2019). A systematic survey of computer-aided diagnosis in medicine: Past and present developments. *Expert Systems With Applications*, 138.
- Zeiler, M., & Fergus, R. (2014). Visualizing and Understanding Convolutional Networks. *European Conference on Computer Vision*, (pp. 818-833).
- Zhu, C., Song, F., Wang, Y., Dong, H., Guo, Y., & Liu, J. (2019). Breast cancer histopathology image classification through assembling multiple compact CNNs. *BMC Medical Informatics and Decision Making*.

Zou, L., Yu, S., Meng, T., Zhang, Z., Liang, X., & Xie, Y. (2019). A Technical Review of Convolutional Neural Network-Based Mammographic Breast Cancer Diagnosis. *Computational and Mathematical Methods in Medicine*, 2019, 1-16.



Konferans Bildirileri

1. Seyidbayli, C., Ulu, C., (2022) Performance Comparison Of Transfer Learning Based Convolutional Neural Network Models For Breast Cancer Classification, International Istanbul Congress Of Multidisciplinary Scientific Research, 2022, 33

