



**YAPAY ZEKÂYA DAYALI ANLAMSAL
VIDEO İŞLEME YÖNTEMLERİNİN
TIPTA KULLANILABİLİRLİĞİNİN ARAŞTIRILMASI**

Hasan UCUZAL

BİYOİSTATİSTİK ve TIP BİLİŞİMİ ANABİLİM DALI

**Tez Danışmanı
Dr. Öğr. Üyesi Emek GÜLDOĞAN**

Yüksek Lisans Tezi – 2020

**T.C.
İNÖNÜ ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKÂYA DAYALI ANLAMSAL
VIDEO İŞLEME YÖNTEMLERİNİN TIPTA
KULLANILABİLİRLİĞİNİN ARAŞTIRILMASI**

Hasan UCUZAL

**Biyoistatistik ve Tıp Bilişimi Anabilim Dalı
Yüksek Lisans Tezi**

Tez Danışmanı

Dr. Öğr. Üyesi Emek GÜLDOĞAN

MALATYA

2020

İÇİNDEKİLER

ÖZET	vi
ABSTRACT.....	vii
SİMGELER VE KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ.....	xi
1.GİRİŞ	1
2.GENEL BİLGİLER	3
2.1.Yapay Zekâ Teknolojileri ve Güncel Uygulamaları.....	3
2.2. Makine Öğrenmesi.....	6
2.2.1. Denetimli Öğrenme.....	7
2.2.2. Denetimsiz Öğrenme	7
2.2.3. Takviyeli Öğrenme	7
2.2.4. Çevrimdışı Öğrenme.....	7
2.2.4. Çevrimiçi Öğrenme.....	7
2.3. Derin Öğrenme	8
2.3.1. Derin Öğrenme Mimarileri	9
2.3.2. Evrişimsel Sinir Ağları (CNN)	9
2.3.3. Tekrarlayan Sinir Ağları (RNN)	10
2.3.4. Uzun Kısa Vadeli Hafıza Ağları (LSTM).....	11
2.3.5. Sınırlı Bolzman Makineleri (RBM).....	12
2.3.6. Derin İnanç Ağları (DBN)	14
2.3.7. Önceden Eğitilmiş Ağlar	15
2.3.8. Derin Öğrenme Modelinin Başarımını Artırma Teknikleri.....	16
2.4. Görüntü İşleme	17

2.4.1. Görüntü İşlemedeki Temel Adımlar	18
2.4.2. Görüntü İşleme Kütüphaneleri ve Ön İşleme Yöntemleri	23
2.4.3. Görüntü İşleme Kütüphaneleri Özellik Çıkarma Yöntemleri.....	26
3. MATERYAL VE METOD.....	28
3.1. Materyal	28
3.1.1. Polip Görüntüleri	28
3.1.2. Araştırmanın Veri Seti	29
3.1.3. Cmake	30
3.1.4. Imaglab	30
3.1.5. Dlib	31
3.1.6. OpenCV	31
3.2. Metot.....	32
3.3. Görüntü Ön İşleme.....	32
3.4. Görüntülere Sınırlayıcı Kutu Çizilmesi ve Etiketlendirilmesi.....	33
3.5. Derin Öğrenme Modelinin Oluşturulması	35
3.6. Modelin Eğitimi	36
3.7 Masaüstü video işleme yazılımının geliştirilmesi.....	39
3.8. Performans Değerlendirme Ölçütleri.....	40
4. BULGULAR.....	44
5. TARTIŞMA	49
6. SONUÇ VE ÖNERİLER.....	52
KAYNAKLAR	53
EKLER.....	57
EK-1. Özgeçmiş.....	57
EK-2. Etik Kurul Almama Gerekçesi	59

TEŐEKKÖR

Tez alıřmam sırasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösterici ve destek olan deęerli danıřman hocam Dr. Öęr. Üyesi Emek GÜLDOĞAN'a akademik eęitimim süresince desteklerini esirgemeyen ve birikimleriyle bana yol gösteren deęerli hocalarım Prof. Dr. Saim YOLOĞLU, Prof. Dr. Cemil ÇOLAK ve Arř. Gör. Ahmet Kadir ARSLAN'a sonsuz saygı ve teşekkürlerimi sunarım.

Çalıřmalarım boyunca maddi manevi destekleriyle beni hiçbir zaman yalnız bırakmayan sevgili eřime ve aileme de sonsuz teşekkürler ederim.



ÖZET

YAPAY ZEKÂYA DAYALI ANLAMSAL VIDEO İŞLEME YÖNTEMLERİNİN TIPTA KULLANILABİLİRLİĞİNİN ARAŞTIRILMASI

Amaç: Nesne algılama veya tanıma, dijital görüntülerdeki nesneleri tanımlamayı içeren ilgili bilgisayarlı görü işlemlerinin bir koleksiyonunu tanımlayan genel bir terimdir. Son zamanlarda sağlık alanında nesne algılama uygulamalarının klinik karar destek sistemleri olarak kullanımına yönelik çalışmalar giderek önem kazanmaktadır. Gelişen bilgisayar ve makine öğrenmesi teknolojileri sayesinde klinik görüntü ve videolar (Bilgisayarlı tomografi, ultrason, vb.) üzerinden hastalık veya anomali tespiti bilgisayarlar tarafından otomatik olarak yapılabilir hale gelmiştir. Hesaplama maliyeti yüksek bu işlemlerin yüksek doğruluk ve hassasiyetle gerçekleştirilebilmesi için amaca yönelik derin öğrenme mimarileri geliştirilmiştir. Nesne tanıma işlemleri için sıklıkla kullanılan mimarilerden olan evrişimsel sinir ağları (Convolutional neural networks, CNN) derin, ileri beslemeli yapay sinir ağı sınıfıdır. Bu çalışmada uygun video/görüntü işleme teknikleri ve CNN mimarisi kullanılarak endoskopik video görüntüleri içerisinde bulunan poliplerin tespiti, tanımlanması, sınıflandırılması ve takibi gibi çeşitli yöntemler ile sağlık personelleri için kullanıcı dostu bir yazılımın geliştirilmesi amaçlanmıştır.

Materyal ve Metot: Çalışmada kullanılan veriseti, toplam 300 görüntüden oluşmaktadır. Bu görüntüler sindirim yolundaki anatomik dönüm noktaları, patolojik bulgular veya gastrointestinal prosedürler gibi her sınıf için yüzlerce görüntüden oluşan çeşitli sınıflara ait tıp doktorları (deneyimli endoskopistler) tarafından açıklanan ve doğrulanan görüntülerden oluşmaktadır. Görüntüler, araştırma ve eğitim amaçlı olarak açık erişimli olarak sunulan <https://datasets.simula.no/kvasir> internet adresinden temin edilmiştir. Modelleme aşamasında Dlib kütüphanesinde bulunan derin sinir ağları mimarilerinden CNN ve maksimum aralık nesne algılama yöntemi (Max-Margin Object Detection, MMOD) kullanılmıştır. Basit çapraz geçerlilik yöntemi (hold-out) kullanılarak veri seti %80 eğitim, %20 test olacak şekilde iki kısma ayrılmıştır. Model performansının değerlendirilmesinde ise kesinlik, duyarlılık, F1-skor, ortalama kesinlik (average precision, AP), ortalama kesinlik değerlerinin ortalaması (mean average precision, mAP), kesiştirilmiş bölgeler ölçütleri (intersection over union, IoU), en uygun konumlandırma kesinliği ve duyarlılığı (optimal localization recall precision, oLRP), ortalama en uygun LRP (Mean Optimal LRP, moLRP) kullanılmıştır.

Bulgular: Bu tez çalışmasının uygulamasında endoskopik poliplere ilişkin açık erişimli video görüntü veri seti üzerinde önceden açıklanan aşamalar gerçekleştirildiğinde, eğitim veri setinde incelenen bütün performans metrikleri 1 değerini alırken, test veri setinde ise kesinlik %98, duyarlılık %90, F1-skoru %94, AP ve mAP %89, oLRP ve moLRP %48 olarak hesaplanmıştır.

Sonuç: Hesaplanan performans ölçütlerine ait değerler dikkate alındığında, önerilen sistemin gastrointestinal poliplerin tanısında başarılı tahminler verdiği tespit edilmiştir.

Anahtar kelimeler: Nesne tanıma, derin öğrenme, karar destek sistemi, gastrointestinal polipler, evrişimsel sinir ağları

ABSTRACT

INVESTIGATION OF USABILITY OF ARTIFICIAL INTELLIGENCE SEMANTIC VIDEO PROCESSING METHODS IN MEDICINE

Aim: Object scanning or recognition is a general term that describes a collection of related computer vision processes that involve identifying objects in digital images. Recently, studies on the use of object recognition applications in the field of health as clinical decision support systems are gaining importance. Thanks to the developing computer and machine learning technologies, detection of disease or anomaly via clinical images and videos (computed tomography, ultrasound, etc.) has been made automatically by computers. To perform these operations having high calculation cost with high accuracy and precision, purposeful deep learning architectures have been developed. Convolutional neural networks (CNN), one of the frequently used architectures for object recognition processes, is a deep, feed forward neural network class. In this study, by using appropriate video/image processing techniques and CNN architecture, it is aimed to develop a user-friendly software for healthcare professionals with various methods such as detection, identification, classification and tracking of polyps contained in the endoscopic images.

Material and Methods: The dataset consisted of 300 images in total. These images are images described and validated by medical doctors (experienced endoscopists) of several classes, consisting of hundreds of images for each class, such as anatomical milestones, pathological findings, or gastrointestinal procedures in the digestive tract. The images were obtained from the web address <https://datasets.simula.no/kvasir>, which is open source for research and educational purposes. CNN and Max-Margin object detection method (MMOD), one of the deep neural network architectures in the Dlib library, was used in the modeling phase. The simple cross-validation (i.e., hold-out) method is used and the whole data is divided into two parts: 80% for training and 20% testing. In the evaluation of model performance, precision, recall, F1-score, average precision (AP), mean average precision (mAP), optimal localization recall precision (oLRP), mean optimal LRP, (moLRP) and intersection over union (IoU) were used.

Results: In the implementation of the study, when the previously described steps on the open access video image dataset related to the colonic polyps were performed, all performance metrics examined in the training dataset were 100%, while precision of 98%, recall of 94%, F1-score of 94%, AP of 89% and mAP of 89%, oLRP of 48% and moLRP of %48 were calculated on the testing dataset.

Conclusion: Considering the values of the calculated performance criteria, it was found that the proposed system gave successful predictions in the diagnosis of gastrointestinal polyps.

Keywords: Object recognition, deep learning, decision support system, gastrointestinal polyps, convolutional neural networks

SİMGELER VE KISALTMALAR DİZİNİ

CNN	: Evrişimli Sinir Ağları
AP	: Ortalama Hassasiyet
mAP	: Ortalama Kesinlik Değerinin Ortalaması
IoU	: Kesiştirilmiş Bölge
LRP	: Kesiştirilmiş Bölge
ASI	: Süper Yapay Zekâ
DL	: Derin Öğrenme
COVID-19	: Koronavirüs Hastalığı
DDN	: Derin Sinir Ağları
YZ	: Yapay Zekâ
ML	: Makine Öğrenmesi
BT	: Bilgisayarlı Tomografi
MR	: Manyetik Rezonans
RNN	: Tekarlanan Sinir Ağları
LSTM	: Uzun Vadeli Hafıza Ağları
RBM	: Sınırlı Boltzman Makineleri
DBN	: Derin İnanç Ağları
MLP	: Çok Katmanlı Algılayıcı
MMOD	: Max-Margin Nesne Algılama Yöntemi
SGD	: Stokastik Gradyan İnişi
GPU	: Grafik İşlemci

ŞEKİLLER DİZİNİ

Şekil No	Sayfa No
Şekil 2.1 Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki.....	3
Şekil 2.2 Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar.....	6
Şekil 2.3 Örnek CNN mimarisi	9
Şekil 2.4 RNN ağ mimarisi.....	10
Şekil 2.5 Standart bir RNN'ye ilişkin grafik.....	11
Şekil 2.6 Standart LSTM'ye ilişkin grafik	11
Şekil 2.7 RBM katmanlarına ilişkin grafik.....	12
Şekil 2.8 RBM'in tek girdi yolu ile grafik.....	13
Şekil 2.9 Ağırlıklandırılmış girdilerin kombinasyonlarına ilişkin grafik	13
Şekil 2.10 RBM'in çoklu girdi yolu ile grafik.....	14
Şekil 2.11 DBN mimarisinin gösterimi	15
Şekil 2.12 Görüntü işlemedeki temel adımlar	17
Şekil 2.13 Görüntü elde etme	18
Şekil 2.14 Görüntü zenginleştirmeye ilişkin gösterim	18
Şekil 2.15 Görüntü onarmaya ilişkin gösterim	19
Şekil 2.16 Renkli görüntü işlemeye ilişkin gösterim.....	19
Şekil 2.17 Çok çözünürlüklü görüntü işlemeye ilişkin gösterim.....	19
Şekil 2.18 Görüntü sıkıştırmaya ilişkin gösterim	20
Şekil 2.19 Morfolojik işlemlere ilişkin gösterim.....	20
Şekil 2.20 Görüntü bölümlmeye ilişkin gösterim	21
Şekil 2.21 Gösterim ve açıklamaya ilişkin gösterim	21
Şekil 2.22 Gösterim ve açıklama ilişkin gösterim	22
Şekil 3.1 Polipin gelişim süreci	28
Şekil 3.2 Endoskopi cihazı	28
Şekil 3.3 Endoskopi cihazından alınan görüntü	29
Şekil 3.4 Cmake aracının görünümü	30
Şekil 3.5 Imaglab aracının görünümü.....	31
Şekil 3.6 Polip ön işlemeye ilişkin gösterim	32

Şekil 3.7 Sınırlayıcı kutu ile tekli seçim.....	33
Şekil 3.8 Sınırlayıcı kutu ile çoklu seçim	33
Şekil 3.9 Sınırlayıcı kutuların seçim işlemi.....	34
Şekil 3.10 Sınırlayıcı kutuların etiketlendirmesi	34
Şekil 3.11 Sınırlayıcı kutuların kayıt işlemi	35
Şekil 3.12 Çalışmada kullanılan CNN mimarisi	35
Şekil 3.13 Modele ait görüntü piramidi.....	37
Şekil 3.14 Modele ait ısı haritalı görüntü piramidi.....	38
Şekil 3.15 CNN+MMOD ısı haritası.....	38
Şekil 3.16 Polipin belirlenmesi.....	38
Şekil 3.17 Video işleme yazılımı ile poliplerin bulunması	39
Şekil 3.18 Video kayıtlarının arşivlenmesi.....	40
Şekil 3.19 Polip sınırlayıcı kutularının gösterimi	41
Şekil 3.20 IoU hesaplama.....	42
Şekil 4.1 Eğitim kayıp değerleri	45
Şekil 4.2 Modelin yanlış pozitif – doğru pozitif tanılama değerleri.....	46
Şekil 4.3 Modelin yanlış negatif tanılama değerleri.....	46
Şekil 4.4 IoU değeri hesaplanmış polip’e ilişkin gösterim.....	47
Şekil 4.5 Performans değerlendirme ölçütlerinin grafiği	48
Şekil 4.6 Yazılım ara yüzüne ait gösterim.....	48

TABLULAR DİZİNİ

<u>Tablo No</u>	<u>Sayfa No</u>
Tablo 2.1 Özellik çıkarma algoritmaları (Açık kaynaklı).....	27
Tablo 3.1 Veri seti özellikleri.....	29
Tablo 4.1 CNN modelinin başlangıç parametre değerleri	44
Tablo 4.2 Tahmin Değerler	46
Tablo 4.3: Eğitim ve test görüntü veri setine ait ölçüt değerleri.....	47

1.GİRİŞ

Teknolojik gelişmeler sayesinde “Bilgi”nin yönetimi stratejik bir kaynak konumuna gelmiştir. Bilgiyi geliştirme ve yönetme yollarının arayışı bilişim sistemleri gibi yeni sistemlerin var olmasına neden olmuştur. Bilişim sistemleri günümüzde sağlık sektöründe hekimlere ve diğer sağlık personellerine klinik kararlara destek sağlaması açısından büyük rol oynamaktadır. Bu alanda kullanılan sistemlerden en önemlisi ise klinik karar destek sistemleridir.

Klinik karar destek sistemleri, hastanın yazı, ses, video ve görüntü gibi sağlıkla ilgili verilerini kullanarak, bilgisayar yazılımları ile hekimlere, hastalıkların teşhisi ve uygun tedavilerin verilmesinde destek sağlar. Böylece hastaya ait veriler klinik açıdan değerlendirilirken, ilgili karar destek yazılımı amaca uygun algoritmaları uygun seçenekler arasından en iyi olasılığı tahmin etmeye çalışarak hekime yardımcı olur. Bu sayede erken teşhisi ve uygun tedavilerin verilmesi ile ölümle yaşam arasındaki sonucun değişmesini neden olur.

Klinik karar destek sistemlerinde yapay zekâyı oluşturan makine öğrenmesi ve derin öğrenme ağları kullanılmaktadır. Yapay zekâ, insanın sahip olduğu davranışlar olan mantık yürütme, anlamlandırma, tanıma, öğrenme gibi birçok süreci yerine getirme yeteneğine sahip bilgisayar ya da bilgisayar kontrolündeki sistemlere verilen isimdir. Makine öğrenmesi ise çeşitli algoritmalar uygulanarak veriler üzerinden tahmin yapabilen ve çıkarımsal sonuçlar ortaya koyabilen bir sistemdir. Bu sistem birçok problemin çözümünde kullanılmakta olup ayrıca yeni algoritmik yaklaşımların geliştirmesi ile derin öğrenme ağlarının kullanılmasına da imkân sağlamıştır.

Derin Öğrenme, ardışık katmanlardan oluşan mimarının, her katmanında hesaplama yöntemleri kullanılarak verilerden bir öğrenme temsili elde etme ve veri kümelerindeki gizli kalmış özellikleri keşfetme tekniğidir. Bu tekniğin son yıllarda ilerlemesi ile derin öğrenme algoritmaları hızlı bir şekilde gelişerek video işleme, görüntü işleme, ses tanıma ve robotik gibi alanlarda kullanılmaya başlanmıştır. Bu alanların içerisinde video/görüntü işleme, klinik karar destek sistemlerinin geliştirilmesinde en önemli araştırma konularından biridir.

Derin öğrenme, derin sinirsel öğrenme veya derin sinir ağı olarak da bilinir. Makine öğrenmesinin bir bölümü olan derin öğrenme, makine öğrenimi sürecini

gerçekleştirmek için hiyerarşik düzeyde yapay sinir ağları kullanır. Yapay sinir ağlarında, insan beyni gibi, nöron düğümleri bir ağ gibi birbirine bağlı olarak inşa edilir. Derin öğrenmede, her seviye girdi verilerini biraz daha soyut ve bileşik bir temsile dönüştürme öğrenilir. Bir görüntü tanıma uygulamasında, ham girdi bir piksel matrisi olabilir; birinci temsili katman pikselleri soyutlayabilir ve kenarları kodlayabilir; ikinci katman kenar düzenlemelerini oluşturabilir ve kodlayabilir; üçüncü katman bir burnu ve gözleri kodlayabilir; ve dördüncü katman ise görüntünün bir yüz içerdiğini tanıyabilir. Daha da önemlisi, derin bir öğrenme süreci hangi özelliklerin hangi seviyeye en uygun şekilde yerleştirileceğini öğrenebilir. (Tabii ki bu, elle ayarlama ihtiyacını tamamen ortadan kaldırmaz; örneğin, değişen sayıda katman ve katman boyutu farklı derecelerde soyutlama sağlayabilir) (1).

Evrimsel Sinir Ağları, derin öğrenmedeki sinir ağlarının en önemlilerindendir. Bu ağlar görüntüler, sesler, metinler, videolar gibi karmaşık görevleri gerçekleştirebilir ve en yaygın olarak görsel görüntüleri analiz etmek için uygulanır. CNN, minimum ön işleme gerektirecek şekilde tasarlanmış çok katmanlı algılayıcıların bir uyarlamasını kullanır. Bilgisayarlı görüde, CNN'ler doğru bölümlmeyi sağlayan özellik hiyerarşilerini sağlayan güçlü görsel modeller olduğu bilinmektedir. Aynı zamanda CNN'lerin sınıflandırma tahminlerini diğer algoritmalarından nispeten daha hızlı gerçekleştirdikleri de bildirilmektedir (1).

Bu çalışmada video/görüntü işleme teknikleri ve derin öğrenme mimarileri kullanılarak görüntü içerisinde bulunan nesnelerin tespiti, tanımlanması, sınıflandırılması ve takibi gibi çeşitli yöntemler ile sağlık personelleri için kullanıcı dostu, bir yazılım geliştirilmiştir. Bu yazılımda açık kaynak video ve görüntü veri seti kullanılmış, video/görüntüyü tahmin edebilmek için yapay zekâ ve derin öğrenmeye yöntemlerine dayalı modeller oluşturulmuş, bilgisayar destekli tanı sistemleri geliştirilmiş ve sonuçlar değerlendirilmiştir. Yazılım geliştirilirken derin öğrenme mimarisinin oluşturmada C++, video/görüntü işleme aşamasında Python Programlama dili ve Dlib, OpenCV kütüphaneleri gibi teknolojilerden yararlanılmıştır. Böylelikle bu çalışma ile sağlık personellerinin, hastalığa yönelik klinik kararlar vermesine yardımcı olmasına ilaveten hastalık teşhisi, takibi ve gelişimi konularında da destek sağlaması hedeflenmiştir.


2.GENEL BİLGİLER

2.1.Yapay Zekâ Teknolojileri ve Güncel Uygulamaları

Yapay zekâ, insanın sahip olduğu davranışlar olan mantık yürütme, anlamlandırma, tanıma, öğrenme gibi birçok süreci yerine getirme yeteneğine sahip bilgisayar ya da bilgisayar kontrolündeki sistemlere verilen isimdir.

1950 yılında Alan Turing tarafından yayınlan bir makale ile makinelerin insanlar gibi düşünme yeteneğinin olup olmayacağı sorgulanmaya başlandı. Alan Turing'in önerdiği test ile bir makinenin zeki olup olmadığına karar verilebiliyordu. Bu test, yapay zekânın temellerini oluşturmuş ve günümüzde kullanılan birçok teknolojik yeniliğin başlamasına öncülük etmiştir. Bu teknolojilerden en önemlileri bulanık mantık, yapay sinir ağları, genetik algoritmalar, uzman sistemler ve karınca algoritmalarıdır.

Bugüne kadar yapılan çalışmalar sonucunda bu alan üç kısma ayrılmıştır (2). Birincisi dar yapay zekâdır; Belirli bir alana odaklanır ve yalnızca o alan için çözüm üretir. İkincisi genel yapay zekâdır; İnsansı özellikler göstermesi hedeflenen robotlarda uygulanır, görüntü tanıma, doğal dil işleme, ses tanıma, hareket etme, öğrenme, tahmin ve muhakeme gibi yapay zekânın tüm alt disiplinlerini başarıyla bütünleştiren çalışmaları kapsar (3). Üçüncüsü ise süper yapay zekâdır (ASI); uzak gelecekte insanın sahip olduğu tüm yeteneklere ve çok daha fazlasına sahip olacağı öngörülen yapay zekâ türüdür (4).



Şekil 2.1 Yapay zekâ, makine öğrenimi ve derin öğrenme arasındaki ilişki

Yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemleri birbiri ile ilişkili disiplinlerdir. Bu nedenle birbirleri arasındaki ilişkiyi iyi anlamak gerekir. Makine öğrenmesi, aslında yapay zekâ oluşturma'nın da bir yoludur. Derin öğrenme ise, yapay sinir ağlarını örnekleyerek oluşturulan makine öğrenmesinin alt disiplinlerinden biridir. Makine öğrenimi ve derin öğrenme yöntemleri ile veriler üzerinden tahmin yapabilen ve çıkarımsal sonuçlar ortaya koyabilen sistemler ve uygulamalar oluşturabilir.

Yapay zekâ, yeni bilgi/bilişim teknolojilerini kullanan birçok faaliyet sektörünün merkezinde yer almaktadır. Yapay zekânın kökleri yıllar öncesine dayanırken, günümüzde öğrenme, akıl yürütme ve uyum gibi özellikler ile donatılmış akıllı makinelerin öne çıkan yetenekleri herkes tarafından bilinmektedir. Bu yetenekler sayesinde yapay zekâ yöntemleri, giderek karmaşıklaşan hesaplama görevlerini çözmeyi öğrenirken, eşi görülmemiş bir performans seviyesine ulaşmaktadır. Böylece insanların ve toplumun gelecekteki gelişimi için çok önemli hale gelmektedir.

Yapay zekâ destekli sistemlerin karmaşıklığı, tasarım ve devreye alınması için neredeyse hiç insan müdahalesine ihtiyaç duyulmayacak kadar artmıştır. Bu tür sistemlerden türetilen kararlar insanların yaşamlarını önemli ölçüde etkilemektedir. Bu nedenle bu tür kararların yapay zekâ yöntemleriyle nasıl sağlandığını iyi anlamak gerekmektedir. İlk yapay zekâ sistemleri kolayca yorumlanabilirken, son yıllarda Derin Sinir Ağları (DNN) gibi kolayca yorumlanamayan karar destek sistemleri kullanılmaya başlanmıştır. DNN'ler gibi Derin Öğrenme (DL) modellerinin deneysel başarısı, etkili öğrenme algoritmaları ile dev parametrik alanlarının birleşiminden kaynaklanmaktadır. DNN'leri karmaşık kara kutu modelleri olarak kabul edilmesinin nedeni yüzlerce katman ve milyonlarca parametreden oluşmasıdır. Kara kutu Makine Öğrenimi modelleri, kritik bağlamlarda önemli tahminler yapmak için giderek daha fazla kullanıldığından, yapay zekâyı kullanan çeşitli araştırmacılar ve paydaşlardan şeffaflık talebi artmaktadır. Özellikle tıp gibi hassasiyet gerektiren alanlarda, tanıların desteklemesi için basit bir ikili tahminden çok daha fazla bilgiye ihtiyaç duyulmaktadır. Genel olarak, yapay zekâ için artan talep göz önüne alındığında, insanlar doğrudan yorumlanabilir, izlenebilir ve güvenilir tekniklerin uygulamasını talep etmektedir. Sadece performansa odaklanarak, sistemlerin giderek daha mantıksız olacağını düşünmek geleneksel olmakla birlikte, bir sistemin anlaşılmasındaki iyileşme, eksikliklerinin düzeltilmesine yol açabilir (5, 6)

Yapay zekâ teknolojilerinin tıp ve sađlık alanlarındaki kullanımı günden güne daha da artmaktadır. Özellikle COVID-19 salgını döneminde yapay zekâ, gerçek zamanlı veri analizi ile bu hastalığın önlenmesinde yardımcı olan güncellenmiş bilgiler sağlayabilir. Bu bilgiler doğrultusunda hastalıkların (örneğin, COVID-19) yayılmasını kolayca takip edebilen, yüksek riskli hastaları tanımlayabilen ve hastalıkları gerçek zamanlı olarak kontrol etmede fayda sağlayabilecek yapay zekâ sistemleri oluşturulabilir. Ayrıca, yapay zekâ ile hastaların önceki verileri analiz edilerek mortalite riski tahmin edebilir. Yapay zekâ, nüfus taraması, tıbbi yardım, bildirim ve enfeksiyon kontrolü hakkında önerilerle bu virüsle savaşmamıza yardımcı olabilmekle beraber, kanıta dayalı bir tıbbi araç olarak hastalıkların planlama, tedavi ve bildirilen sonuçları geliştirme potansiyeline sahiptir. Yapay zekâ teknolojilerinin tıpta kullanıldığı başlıca konular aşağıda özetlenebilir:


- Hastalıkların erken tespiti ve teşhisi,
- Tedaviyi izleme,
- Bireylerin iletişim takibi,
- Olguların ve mortalitenin öngörülmesi,
- İlaç ve aşılarda geliştirilmesi,
- Sağlık çalışanlarının iş yükünün azaltılması,
- Hastalıkların önlenmesi,
- Risk faktörleri arasındaki birliktelikleri saptama,
- Genomik, proteomik, metabolomik, lipidomik gibi omik teknolojilerinin veri analizlerinin yapımı,
- Hastalıklara yönelik biyobelirteçlerin tespit edilmesi,
- İnsanların çeşitli beden bölgelerinden hastalıkların teşhis edilmesi,
- Tıbbi görüntülerden hastalıkların ya da değişik nesnelerin tespiti, bölümlendirilmesi, sınıflandırılması vb. işlemlerin yapılması.

Yapay zekânın, geçerli olan ve daha önceden oluşturmuş verilerin yardımıyla gelecekteki virüs ve hastalıkların önlenmesi için fayda sağlayacağı, enfeksiyonun yayılım özelliklerini ve nedenlerini tanımlaması sayesinde de, salgınlara karşı savaşmak için koruyucu sağlık hizmetlerinin planlamasında önemli bir teknoloji haline geleceği öngörülmektedir (5-7)

2.2. Makine Öğrenmesi

Büyük boyuttaki verilerin elle analiz edilmesi çok zor ve zaman alıcı bir süreçtir. Makine öğrenme yöntemleri ile geçmişteki verilerden yararlanılarak bu sürecin çözülmesi mümkündür. Amerikan asıllı bilgisayar bilimcisi olan Arthur Samuel'in, 1959'da bir araya getirdiği makine öğrenmesi kavramı, bilgisayarın programlanmadan öğrenebileceğinin tanımı olarak kullanılmaktadır. Makine öğrenmesi, bilgisayar ile modellenen sistemlerin matematiksel işlemler yardımıyla verilerden çıkarımsal tahminler oluşturma sürecini ifade eder (8).

Makine öğrenimi ile insanlar verileri ve verilerden beklenen cevapları girerler ve böylece kurallar oluşur. Bu kurallar orijinal cevaplar üretmek üzere yeni eklenen verilere uygulanabilir. Bir makine öğrenme sistemi açıkça programlanmak yerine eğitilir.



Şekil 2.2 Makine öğrenmesi ve derin öğrenme arasındaki farklılıklar

Makine öğrenimi bilgisayar bilimi, istatistik ve veri biliminin kesiştiği yerde yaşar. Verileri ve kalıpları algılayıp onlardan öğrenebilecek, gelecekteki etkinliği tahmin edebilecek veya kararlar alabilecek şekilde işlemek için bu alanların her birinin öğelerini kullanır (10).

2.2.1. Denetimli Öğrenme

Denetimli makine öğreniminde, bir sistem etiketlenmiş verilerle eğitilir. Etiketler, her veri noktasını "elma" veya "portakal" gibi bir veya daha fazla grupta sınıflandırır. Sistem, eğitim verisi olarak bilinen bu verilerin nasıl yapılandırıldığını öğrenir ve bunu yeni veya "test" verileri kategorilerini tahmin etmek için kullanır (10).

2.2.2. Denetimsiz Öğrenme

Denetimsiz öğrenme etiketsiz öğrenmedir. Bu yöntemde, kümeler oluşturarak ve bu kümelere veri atayarak veri noktalarını birbirine daha fazla veya daha az benzeyen özelliklerinin tespit edilmesi amaçlanmaktadır (10).

2.2.3. Takviyeli Öğrenme

Takviyeli öğrenme deneyimlerden öğrenmeye odaklanır ve denetimsiz ve denetimli öğrenme arasındadır. Örneğin sistem bir oyunu kazanmak için ödüllendirme yöntemi kullanabilir. Temsilcinin amacı, bir oyunun kazanılmasında hangi hareketlerin önemli olduğu gibi kararlarının sonuçlarını öğrenmek ve bu öğrenmeyi ödüllendirmek için en üst düzeye çıkaran stratejiler bulmak için kullanmaktır (10).

2.2.4. Çevrimdışı Öğrenme

Çevrimdışı öğrenme sistemleri çevrimdışı bir ortamda eğitilir ve test edilir. Ardından eğitilmiş modeller canlı bir ortama uygulanmadan önce değiştirilmez. Sonraki herhangi bir eğitim, çevrimdışı bir ortamda gerçekleştirilecek, test edilecek ve daha sonra geleneksel yazılım değişiklik yöntemleri kullanılarak dağıtılır. Bu yaklaşım bugün kullanılan makine öğrenim sistemlerinde daha yaygındır, çünkü sistem herhangi bir kullanıcıyla etkileşime girmeden önce sistemin insan tarafından doğrulanması için bir fırsat verir (10).

2.2.4. Çevrimiçi Öğrenme

Bu sistemler dağıtımdan önce çevrimdışı bir ortamda eğitilir ve test edilir, ancak öğrenme algoritmaları dağıtımdan sonra eğitilmiş modele uygulanmaya devam eder. Bu sistemin performansının, gerçek dünyadaki verilere yanıt olarak gerçek zamanlı olarak iyileşmeye devam edebileceği anlamına gelir. Ayrıca, kullanıcıların bunlara maruz kalmadan önce modeldeki güncellemelerin sonuçlarını kontrol etme fırsatı olmadığı anlamına da gelir. Örneğin, birçok e-posta spam algılama sistemi, gelen e-posta ve kullanıcı kalıplarına yanıt olarak çevrimiçi öğrenme gerçekleştirir (10).

2.3. Derin Öğrenme

Makine öğrenmesi alanının (ML) bir alt alanı olan derin öğrenmenin, hesaplama gücünün büyük ölçüde artması ve büyük yeni veri kümelerinin gün geçtikçe çoğalması nedeniyle son yıllarda popülerliği artmıştır. Derin öğrenme alanı, görüntü sınıflandırması, nesne algılama, konuşma tanıma, dil çevirisi, doğal dil işleme ve oyun oynama da dâhil olmak üzere çeşitli karmaşık görevlerde çığır açan performanslar göstermiş ve göstermeye de devam etmektedir. Derin öğrenme modellerinin grafik işlem birimi üzerinde çalışabilme yetenekleri, büyük veri kümelerinin modellenmesi bakımından birçok klasik makine öğrenmesi yaklaşımından daha iyi performans göstermelerini sağlamıştır. Derin öğrenme sistemleri, birden çok veri türünü girdi olarak kabul edebilir ki bu durum özellikle aynı türden sağlık verileri için özel bir önem taşır (11).

Mevcut derin öğrenme algoritmalarının çoğu yapay sinir ağlarını denetimli öğrenme ile kullanır, burada ağırlık ve önyargılar bir kayıp fonksiyonunu en aza indirerek eğitim verilerinden öğrenilir. (örneğin, kök ortalama kare hatası, çapraz entropi, vb.). Eğitim sırasında, her ağırlık ve bias'a göre bir kayıp fonksiyonunun gradyanlarını hesaplamak için bir geri yayılma algoritması kullanılır. Bu gradyanlar daha sonra gradyanın tersi yönde ağırlıkları ve bias'ı güncellemek için optimizasyon algoritmalarında (örn. SGD) kullanılır. Farklı eğitim örneklerinde ağırlıkların ve bias'ın birkaç kez güncellenmesi, sonunda uygun şekilde eğitilmiş bir sinir ağı oluşacaktır. (12). Derin sinir ağları türleri arasında evrişimli sinir ağları (CNN), tekrarlayan sinir ağları (RNN), uzun kısa vadeli hafıza ağları (LSTM), sınırlı bolzman makineleri (RBM) ve derin inanç ağları (DBN) bulunur.


Tıbbi görüntü ve video verilerinin işlenmesinde Evrişimsel sinir ağları (CNN) derin öğrenme mimarisi sıklıkla kullanılmaktadır. CNN'lerin önemli bileşenleri evrişimsel katmanlar, maksimum havuzlama katmanları ve tam bağlantı katmanlardır. Giriş katmanı biçimi, giriş verileriyle aynı olmalıdır. Çıktı katmanı biçimi eğitim verisi ile aynı olmalıdır. (13). Son zamanlarda CNN gibi derin öğrenme algoritmaları, mamogramlarda meme kanserinin tespiti, bilgisayarlı tomografi (BT) ile akciğer metastazlarının segmentasyonu, rezonans (MR) görüntüleme ile beyin tümörü segmentasyonu, interstisyel akciğer hastalarının yüksek çözünürlüklü göğüs BT görüntülerinin sınıflandırılması gibi çeşitli klinik görevlerde karar destek sistemi olarak kullanılmaya başlanmıştır. (14)

2.3.1. Derin Öğrenme Mimarileri

Derin öğrenme, özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanını kullanır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak kullanır (15). Yapay sinir ağlarındaki katman sayılarının ve yapılarının değişimiyle birçok farklı türde derin öğrenme mimarileri oluşturulmuştur. Oluşturulan derin öğrenme mimariler aşağıdaki başlıklar altında sınıflandırılmıştır.

2.3.2. Evrimsel Sinir Ağları (CNN)

CNN'ler, özellikle bilgisayar görme görevleri için, derin öğrenme topluluğunda en başarılı ve yaygın olarak kullanılan mimariler arasındadır. CNN'ler ilk olarak Fukushima tarafından Hubel ve Wiesel tarafından önerilen görsel korteksin hiyerarşik alıcı alan modeline dayanarak “Neocognitron” üzerine yazdığı makalesinde önerilmiştir. Daha sonra, Waibel ve arkadaşları geçici reseptör alanlar arasında paylaşılan ağırlıkları olan CNN'leri tanıtmıştır. LeCun ve arkadaşları ise belge tanıma için gradyan temelli konvolüsyonel sinir ağı adında bir mimari geliştirmişlerdir. (16).



Şekil 2.3 Örnek CNN mimarisi


CNN'deki katmanlardaki birimler yerel olarak bağlıdır yani her birim, bir önceki katmanda yer alan alıcı alan olarak bilinen dar bir aralıktan ağırlıklı girdiler alır. Çok çözünürlüklü piramitler oluşturmak için katmanları istifler (stacking). Daha yüksek seviyedeki katmanlar, özellikleri giderek daha geniş olan alıcı alanlardan öğrenir. CNN'lerin temel hesaplama avantajı, bir katmandaki tüm alıcı alanların ağırlıkları paylaşmasıdır, bu da tam olarak bağlı sinir ağlarından çok daha az sayıda parametreye neden olur. En iyi bilinen CNN mimarilerinden bazıları şunlardır: AlexNet, VGGNet, ResNet, GoogLeNet, MobileNet ve DenseNet (16).

2.3.3. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan Sinir Ağı, dahili belleği olan ileri beslemeli sinir ağının genelleştirilmesidir. RNN, her bir veri girişi için aynı işlevi yerine getirdiği için doğası gereği tekrarlanırken, güncel girdinin çıkışı son bir hesaplamaya bağlıdır. Çıktı üretildikten sonra kopyalanır ve tekrarlayan ağa geri gönderilir. Bir karar vermek için mevcut girdiyi ve önceki girdiden öğrendiği çıktıyı dikkate alır.

RNN, zaman serileri ile başa çıkmak için özel olarak tasarlanmış bir sinir ağıdır. RNN'de, iki ardışık giriş arasındaki etkileşim, mevcut zaman adımlarından gelen çıktıların bir sonraki zaman adımlarına girdi olarak beslendiği karakteristik bir tekrarlayan yapı tarafından ele alınır. Sonuç olarak, RNN her iki bitişik zaman adımı arasındaki bağımlılığı “ezberlemek” için eşsiz bir yeteneğe sahiptir. (17).

İleri beslemeli sinir ağlarının aksine, RNN'ler, giriş dizilerini işlemek için dahili durumlarını (belleklerini) kullanabilir. Bu durum RNN'i el yazısı tanıma, konuşma tanıma, dil modelleme ve makine çevrimi gibi görevler için geçerli kılar. Diğer sinir ağlarında, tüm girdiler birbirinden bağımsızdır. Ancak RNN'de, tüm girdiler birbiriyle ilişkilidir (18).




Şekil 2.4 RNN ağ mimarisi


Şekil 2.4 deki RNN ağ mimarisi incelendiğinde ilk olarak, X_0 'ı giriş dizisinden alır ve daha sonra X_1 ile birlikte bir sonraki adım için giriş olan h_0 çıkışını verir. Bu nedenle, X_0 ve X_1 bir sonraki adımın girdisidir. Benzer şekilde, bir sonrakinden h_1 bir sonraki adım için X_2 ile girdi ve bu şekilde devam eder. Bu şekilde, eğitim sırasında içeriği hatırlamaya devam eder (18).

2.3.4. Uzun Kısa Vadeli Hafıza Ağları (LSTM)

LSTM bir çeşit RNN'dir. Eşsiz tasarımıyla zaman serisi verileri için güçlü bir derin öğrenme yöntemidir. Genellikle, RNN, uzun veri dizilerinin öğrenilmesinde ortaya çıkan degradeleri yok etme probleminden muzdariptir. LSTM, belirli bilgileri ne zaman unutacağını belirlemek için bellek hücrelerini tanıtarak çözebilir. Bir LSTM ağı, giriş katmanını, gizli katmanlar ve çıkış katmanından oluşur. LSTM'nin ana özellikleri, gizli katmanlarındaki geleneksel nöron düğümleri yerine bellek blokları içeren bellek hücreleridir. Her blok, kendine bağlı birkaç bellek hücresine ve giriş, çıkış ve unutma kapılarına sahip üç çarpım ünitesine sahiptir. Bu kapılar, hücreler üzerinde sürekli yazma, okuma ve sıfırlama işlemleri sağlar (19).



Şekil 2.5 Standart bir RNN'ye ilişkin grafik




Şekil 2.6 Standart LSTM'ye ilişkin grafik (20)

Uzun Kısa Vadeli Hafıza Ağları ile oluşturulmuş tek katmanlı yinelenen modül Şekil 2.5'de ve birbiriyle etkileşen dört katmanlı yinelenen modül ise Şekil 2.6'de görülmektedir.

2.3.5. Sınırlı Boltzman Makineleri (RBM)

Sınırlı Boltzmann Makineleri (RBM) en popüler olasılıksal öğrenme yöntemlerinden biri olarak ortaya çıkmıştır. RBM'ler öğrenme teorisindeki ilerlemelerle birleştiğinde kontrastlı ıraksama, kalıcı ve paralel bağlama gibi uygulanabilirlikleri çeşitli görevlerle genişletilmiştir. Başarılı olsa da, bu modellerin çoğu ilişkisel veriler bağlamında değil, genellikle düz bir özellik temsili (vektörler, matrisler, tensörler) ile kullanılmıştır (21).

RBM'ler iki katmana sahiptir ilk katman girdi katmanı ve ikinci katman gizli katman olacak şekilde tanımlanmıştır. Daireler, nöronlara benzer bir yapıya sahip olup düğüm adı verilen bağlantılardan oluşur. Düğümler katmanlar arasındaki bağlantıları sağlar fakat aynı katmadaki düğümler arasında bağlantı bulunmaz (22).




Şekil 2.7 RBM katmanlarına ilişkin grafik (22)

Yani, katman içi iletişim yoktur. Katmanda bulunan her düğüm, rastgele kararlar vererek bir hesaplama yapar.


Girdi düğüm katmanındaki düğümlerin hepsi, öğrenilmesi gereken veri kümesindeki öğeden düşük seviyeli olan bir özellik alır. Gizli katmanın birinci düğümünde, x değeri bir ağırlıkla çarpılarak önyargı değeri ile toplanır. Bu iki işlemin sonucu, x girişi verildiğinde, düğümün çıkışını veya içinden geçen sinyalin gücünü üreten bir aktivasyon fonksiyonuna beslenir (9).

$$\text{Aktivasyon fonksiyonu } ((\text{ağırlık } w * \text{giriş } x) + \text{önyargı } b) = \text{çıkış } a$$




Şekil 2.8 RBM'in tek girdi yolu ile grafik (22)

Girdilerin gizli düğümdeki birleşimi gözden geçirildiğinde, x değerleri w ağırlık değeri çarpılır, oluşan bu değerler toplanarak önyargı değeri eklenir ve hesaplanan değer düğümün sonucuna ulaşmak için bir aktivasyon fonksiyonundan geçirilir (22).



Şekil 2.9 Ağırlıklandırılmış girdilerin kombinasyonlarına ilişkin grafik (22)

Gizli düğümlerin her biri için x değeri, w ağırlığı ile çarpılır. Böylece her bir x girişinin üç ağırlığı, oniki ağırlık toplamını oluşturmaktadır. (22).




Şekil 2.10 RBM'in çoklu girdi yolu ile grafik (22)

Her gizli düğüm, ilgili ağırlıklarla çarpılmış olan dört girişten oluşur. Bu değerlerin toplamı sapma değerine eklenir ve hesaplanan sonuç değeri gizli düğüm için sonuç üreten aktivasyon algoritması ile kullanılır (22).

2.3.6. Derin İnanç Ağları (DBN)

Derin inanç ağları (DBN), Hinton ve arkadaşları tarafından bir yaklaşım olarak önerilmiştir. DBN'ler Yığılmış RBM'lerden ve derin ağdaki bir sınıflandırıcıdan oluşur. DBN'nin eğitim işlemi, gözetimsiz ve denetimli bir öğrenme aşamasından oluşur. Yığılmış RBM parçaları, bir DBN modeli oluşturmak için bir sınıflandırma katmanının içine yerleştirilir. DBN eğitimi, açgözlü bir algoritma kullanarak RBM'lerin gözetimsiz eğitimi ile başlar ve önceki RBM'nin çıkışı, bir sonraki RBM'nin girdisidir. Son olarak, denetimli eğitim DBN sınıflandırma katmanında gerçekleştirilir. Geoffrey Hinton tarafından tanıtılan, Derin inanç ağları (DBN), önceki bölümde verilen RBM'lerin yığını olarak tanımlanmaktadır. Her RBM katmanı hem önceki hem de sonraki katmanlarla bağlıdır.

Genel olarak, DBN ve çok katmanlı algılayıcı (MLP) arasındaki büyük fark, DBN'nin katman katman denetimsiz eğitim yoluyla verilerden özellik öğrenimi yapabilmesidir. Bununla birlikte, MLP özellik öğrenme yapamaz ve genellikle sınıflandırma için kullanılır. DBN'ler ve MLP'ler arasındaki benzerlik, tamamen bağlı ağlar olmaları ve denetimli öğrenme için geri yayılma algoritmaları kullanmalarıdır (11).



Şekil 2.11 DBN mimarisinin gösterimi (11)

2.3.7. Önceden Eğitilmiş Ağlar

AlexNet, GoogleNet, ResNet50, VGG16, VGG19 ve Inception-V4 gibi ağlar derin mimariye sahip önceden eğitilmiş ağlardan bir kısmıdır.

AlexNet, 2012 yılında yayınlanmıştır ve 2012 ILSVRC'yi kazanan ilk CNN mimarileri arasındadır. Bu mimari yaklaşık 22.000 kategoriden 224x224x3 boyutlarında yaklaşık 15 milyon RGB görüntü verisi, 7 katman ve 60 milyon parametreden oluşmaktadır. Bu ağın mimarisi LeNet'in mimarisine daha derin olması dışında çok benzerlik göstermektedir. Boyutu 11x11, 5x5, 3x3 olan filtrelerden ve her biri 4096 katmandan oluşan 2 tam bağlantılı katman ile 3x3 maksimum havuzlamadan oluşur. Optimizasyon açısından, hızı 6 kat arttırdığı tespit edilen tanh aktivasyonu yerine ReLU aktivasyonu kullanılmıştır (23).

GoogLeNet, VGG'nin 138 milyon parametresine göre yaklaşık 5 milyonluk parametreden oluşmaktadır. Her katmanın birden fazla filtre boyutu vardır (1x1, 3x3, 5x5) ve hangi filtrenin güncelleneceği geriye yayılım tarafından kararlaştırılır. Her modül ayrıca 3x3 maksimum havuzlama katmanı içerir. Her evrişim katmanından önce, özellik haritasının derinliğini azaltmak için 1x1 evrişim darboğazı tabakası bulunur. Sonuçları optimize etmek için ise 1x1 kıvrımları ReLU aktivasyonu kullanılır (23).

ResNet-50 modeli 49 kıvrımlı katman ve ağıın üstünde tamamen bağılı bir katman ve 16 artık deęerli blok ierir. Evriřimsel katmanların filtreleri oęunlukla 3×3 ekirdek byklğndedir. Ayrıca, her evriřimsel katmandan sonra yığıın normalizasyonu ve ReLU aktivasyon fonksiyonu kullanılır. Son olarak, tahmin skorlarını retmek iin softmax aktivasyonlu tamamen bağılı bir sinir ağı uygulanır (24).

VGG-16 dięer geleneksel sinir ağılarından daha derin bir mimariye sahiptir ve daha iyi temsil kabiliyeti vardır. VGG-16'nın yapısında 13 evriřimsel katman, 5 havuzlama katmanı ve $224 \times 224 \times 3$ giriř boyutuna sahip 3 tam bağılantılı katman vardır. VGG-16 bařlangıta grnt iřleme iin nerildięinden, giriř verileri  kanallı rneklerden oluřur (25).

VGG-19, ImageNet veritabanından bir milyondan fazla resim zerinde eęitilmiř evrimsel bir sinir ağıdır. Ağı, 19 kat derinlięindedir ve ok eřitli grntler iin zengin zellik gsterimlerini ğrendięi iin grntleri klavye, fare, kurřun kalem ve birok hayvan gibi 1000 nesne kategorisine bařarıyla ayırabilmektedir (26).

Inception V4 mimarisi, Inception mimarisini kalan bağılantılarla birleřtirir. Amacı, bařlangı ağılarının eęitimini hızlandırmaktır. Bařlangı modl, bir havuzlama katmanından ve birlikte istiflenen kıvrım katmanlarından oluřur. Kıvrımlar eřitli boyutlarda 1×1 , 3×3 ve 5×5 'tir. Bařlangı modlnn dięer bir gze arpan zellięi, 1×1 kıvrım olan darboęaz tabakasının kullanılmasıdır. Darboęaz katmanı hesaplama gereksinimlerinin azaltılmasına yardımcı olur (27).

2.3.8. Derin ğrenme Modelinin Bařarımını Artırma Teknikleri


Derin ğrenme ve Makine ğreniminde daha iyi sonular elde etmek iin birok yntem kullanılmaktadır. Bu yntemler kullanılarak modelin bařarımında kayda deęer artıřlar gzlenmektedir.

- Veri Artırma (Data Augmentatiton)
- Sentetik Veri retme (Synthetic Data Generation)
- Grlt Ekleme (Adding Noise)
- Seyretme (Dropout)
- Seyrek-Yoęun-Seyrek Eęitim (Dense-Sparse-Dense Training)
- Erken Durdurma (Early Stopping)
- Transfer ğrenme (Transfer Learning)

2.4. Görüntü İşleme

Görüntü işleme, görüntülerden faydalı bilgiler çıkarmak ve gelişmiş görüntüler elde etmek için, görüntü üzerinde farklı yöntemler ve teknikler uygulanarak dijital hale dönüştürme işlemidir.

Görüntü işleme (image processing), sayısal görüntü verilerini, bilgisayar veya yazılım yardımıyla hedeflenen duruma uygun biçimde değiştirmeye yönelik yapılan bilgisayar çalışmaları olarak tanımlanabilir. Bir başka deyişle görüntü işleme, fotoğraf gibi mevcut görüntüleri değiştirmek ya da yorumlamak olarak açıklanabilir. Görüntü analizi ise, hedeflenen amaca yönelik, ihtiyaç duyulan sayısal verilerin, eldeki verilerden elde edilme işlemi olarak özetlenebilir (28).



Şekil 2.12 Görüntü işlemedeki temel adımlar

2.4.1. Görüntü İşlemedeki Temel Adımlar

Görüntü İşlemenin temel adımları aşağıda detaylı bir şekilde açıklanmıştır (29).

Görüntü Elde Etme:

Dijital görüntü işlemenin temel adımlarının ilk adımı veya sürecidir. Görüntü elde etme, hali hazırda dijital biçimde olan veya sayısal kamera ile elde edilen bir görüntüyü ifade eder. Genellikle görüntü elde etme aşaması, ölçekleme vb. gibi ön işlemeyi içerir.



Şekil 2.13 Görüntü elde etme

Görüntü Filtreleme ve Zenginleştirme:

Görüntü zenginleştirme, dijital görüntü işlemenin en basit ve çekici alanlarından biridir. Temel olarak, zenginleştirme tekniklerinin arkasındaki fikir, gizlenmiş ayrıntıları ortaya çıkarmak veya görüntüdeki ilgi duyulan belirli özellikleri vurgulamaktır (Değişen parlaklık ve karşıtlık (kontrast) vb.).



Şekil 2.14 Görüntü zenginleştirmeye ilişkin gösterim

Görüntü Onarma:


Görüntü onarma, görüntü üzerinde iyileştirme yapmaya yarayan bir yöntemdir. Bu yöntem, öznel olan görüntü zenginleştirmenin aksine, objektiftir, yani onarım teknikleri görüntü bozulmasının matematiksel veya olasılıklı modellerine dayandırılmaktadır.



Şekil 2.15 Görüntü onarmaya ilişkin gösterim

Renkli Görüntü İşleme:

Renkli görüntü işleme, dijital görüntülerin internet üzerinden kullanımındaki önemli artış nedeniyle önemini kazanan bir alandır. Buna, dijital alanda renk modelleme ve işleme de dâhildir.



Şekil 2.16 Renkli görüntü işlemeye ilişkin gösterim

Dalgacık ve Çok Çözünürlüklü İşleme:

Dalgacıklar, görüntüleri çeşitli çözünürlüklerde temsil etmenin temelidir. Veri sıkıştırma ve piramidal gösterim için görüntüler art arda daha küçük bölgelere bölünür.



Şekil 2.17 Çok çözünürlüklü görüntü işlemeye ilişkin gösterim

Sıkıştırma:


Sıkıştırma, bir görüntüyü kaydetmek için gereken depolamayı veya onu iletmek için bant genişliğini azaltma teknikleriyle ilgilidir. Özellikle internet kullanımında verilerin sıkıştırılması çok gereklidir.



Şekil 2.18 Görüntü sıkıştırmaya ilişkin gösterim

Morfolojik İşlemler:


Morfolojik işleme, şeklin temsilinde ve açıklamasında yararlı olan görüntü bileşenlerini çıkarmak için kullanılan bir yöntemdir.



Şekil 2.19 Morfolojik işlemlere ilişkin gösterim

Bölümleme:

Bölümleme süreci bir görüntüyü temel parçalarına veya nesnelere ayırır. Genel olarak, bölümleme dijital görüntü işlemedeki en zorlu tekniklerden biridir. Bölümleme sürecinde, nesnelerin ayrı ayrı tanımlanması gerektiğinden görüntü problemlerinin çözümünde uzun soluklu bir çalışma gerekmektedir.



Şekil 2.20 Görüntü bölümlmeye ilişkin gösterim

Gösterim ve Açıklama:

Gösterim ve açıklama bir bölgenin sınırını veya bölgenin tüm noktalarını oluşturan, genellikle ham piksel verileri olan bir bölümleme aşamasının çıktısını takip eder. Bir gösterimi seçmek, ham verileri sonraki bilgisayar işlemleri için uygun bir forma dönüştürmek için çözümün bir parçasıdır. Açıklama, bazı nicel bilgilerle sonuçlanan veya bir nesne sınıfını diğerinden ayırmak için temel olan öznelitliklerin çıkarılmasıyla ilgilidir.

- Sınır Gösterimi → Köşeler ve bükülmeler gibi dış şekil özelliklerine odaklanır.
- Bölgesel Gösterim → Doku ve iskelet şekli gibi iç özelliklere odaklanır.




Şekil 2.21 Gösterim ve açıklamaya ilişkin gösterim



Şekil 2.22 Gösterim ve açıklama ilişkin gösterim

Özellik eşleme, yararlı bilgilerin çıkarılmasına yardımcı olur. Aynı görüntüler farklı açılardan bulunabilir.



Şekil 2.23 Özellik eşlemeye ilişkin gösterim

Nesne algılama:

Bilgisayarlı görü alanındaki en temel ve zorlu sorunlardan biri olan nesne algılama, doğal görüntülerde çok sayıda önceden tanımlanmış kategoriden nesne örneklerini bulmaya çalışır (30).



Şekil 2.24 Nesne algılamaya ilişkin gösterim

2.4.2. Görüntü İşleme Kütüphaneleri ve Ön İşleme Yöntemleri

Bu bölümde günümüzde en yaygın olarak kullanılan açık kaynaklı görüntü işleme kütüphaneleri ve ön işleme yöntemlerine değinilmiştir.

OpenCV: Bilgisayarla görme, makine öğrenimi ve görüntü işleme için büyük bir açık kaynak kütüphanesidir ve günümüzün sistemlerinde çok önemli olan gerçek zamanlı işlemlerde önemli bir rol oynamaktadır. Bu kütüphane kullanarak nesneleri, insan yüzlerini ve hatta el yazısını tanımlamak için görüntüler ve videolar işlenebilir. Numpy gibi çeşitli kütüphanelerle entegre edildiğinde, OpenCV, matris ve dizi yapısını işleyebilir. Görüntü desenini ve çeşitli özelliklerini tanımlamak için vektör uzayını kullanır ve bu özellikler üzerinde matematiksel işlemler yapar. C++ dilinde oluşturulan OpenCV kütüphanesinin C, Python ve Java dillerinde de dağıtımları bulunmakta ve Windows, Linux, Mac OS, iOS ve Android gibi platformları desteklemektedir (31). OpenCV kütüphanesinde yapılması mümkün olan ön işleme teknikleri aşağıda verilmiştir:

- Renk alanlarını değiştirme
- Görüntülerin geometrik dönüşümleri
- Görüntü eşik
- Görüntüleri düzeltme
- Morfolojik dönüşümler
- Görüntü degradeleri
- Canny kenar algılama
- Görüntü piramitleri
- Konturlar
- Histogramlar
- Görüntü dönüşümleri
- Şablon eşleme
- Hough line dönüşümü
- Hough circle dönüşümü
- Havza algoritması ile görüntü bölütleme
- GrabCut algoritmasını kullanarak etkileşimli ön plan çıkarma

Scikit-image: Python programlama dili için açık kaynaklı bir görüntü işleme kütüphanesidir. Bölümleme, geometrik dönüşümler, renk alanı manipülasyonu, filtreleme, morfoloji, özellik algılama gibi algoritmalar içerir. NumPy ve Scipy gibi sayısal ve bilimsel kütüphaneler ile birlikte çalışmak için tasarlanmıştır (32). Scikit-image kütüphanesinde yapılabilecek ön işleme teknikleri aşağıda verilmiştir:

- Renk alanları dönüşümü
- Görüntüler ve örnek verilerin testi
- NumPy dizilerinde çalışan ilkeller (çizgiler, metin vb.) çizme
- Histogramlar
- Konturlar
- Görüntü eşitleme
- Görüntü özellik algılama ve çıkarma (örn. doku analizi, köşeler, vb.)
- Görüntü filtreleme - Bileme, kenar bulma, sıralama filtreleri, eşik vb.
- Grafik teorik işlemleri (örn. en kısa yollar)
- Görüntü özelliklerinin ölçümü (örn. benzerlik)
- Morfolojik işlemler, (örn. açma veya iskeletleme)
- Restorasyon algoritmaları, (örn. dekonvolüsyon algoritmaları, denoising)
- Görüntüyü birden çok bölgeye bölme
- Geometrik ve diğer dönüşümler, (örn. döndürme veya radon dönüşümü)

Dlib: Gerçek dünya sorunlarını çözmek için C ++ 'da karmaşık yazılımlar oluşturmak için makine öğrenme algoritmaları ve araçlar içeren modern bir C ++ araç takımıdır. Hem endüstride hem de akademik çevrede robotik, gömülü cihazlar, cep telefonları ve büyük yüksek performanslı bilgi işlem ortamları dahil olmak üzere çok çeşitli alanlarda kullanılır (33).

- Renk dönüşümü
- Ölçeklendirme ve döndürme
- Görüntü filtreleme
- Görüntü piramitleri
- Histogramlar

- Konturlar
- Kenarlar ve eşikler
- Görüntü özellik algılama ve çıkarma
- Görüntü özelliklerinin ölçümü
- Morfolojik işlemler
- Restorasyon algoritmaları
- Geometrik ve diğer dönüşümler

Matlab: Bir çok görüntü kütüphanesini içinde barındıran bir yazılım ve teknik bilgi işlem için yüksek performanslı bir dildir. Hesaplama, görselleştirme ve programlamayı, problemlerin ve çözümlerin bilindik matematiksel gösterimde ifade edildiği, kullanımı kolay bir ortamda bütünleştirir. Tipik kullanım alanları şunlardır:

- Matematik ve hesaplama
- Algoritma geliştirme
- Modelleme simülasyon ve prototipleme
- Veri toplama ve veri analizi
- Görüntü geliştirme
- Morfolojik operatörler
- Görüntü çapak alma
- 3D görselleştirme
- 3D işleme
- 3D bölümleme
- Kenar algılama
- Görüntü bölgesi analizi
- Hough dönüşümü
- İstatistiksel işlevler
- Renk alanı dönüşümleri
- Görüntü bölümleme
- Havza bölümleme

BoofCV: Gerçek zamanlı bilgisayar görme ve robotik uygulamaları için açık kaynaklı bir Java kütüphanesidir. Kullanım kolaylığı ve yüksek performans için sıfırdan yazılan bilgisayar görüş sistemi oluşturmak için gereken temel ve gelişmiş özellikleri sağlar. İşlevsellik, görüntü sabitleme gibi üst düzey işlemler için optimize edilmiş düşük düzey görüntü işleme rutinlerini içerir (34).

- Görüntü dönüşümü
- Görüntü türevleri
- Eşik
- İkili işlemler
- Renk alanı
- İnterpolasyon
- Görüntü deformasyonu
- Görüntü bulanıklığı
- Artırma
- Gürültü giderme
- Fourier dönüşümü
- Dalgacık ayrışması
- Ayrık - kayan görüntü piramidi
- Ölçek alanı görüntüsü
- Eşit dikdörtgen

2.4.3. Görüntü İşleme Kütüphaneleri Özellik Çıkarma Yöntemleri

Derin öğrenme modelleri özellik çıkarma yöntemi algoritmalarında da kullanılabilir. En çok kullanılan özellik çıkarma tekniklerinden bazıları şunlardır.

- Yönelimli gradyanların histogramı (HOG)
- Hızlandırılmış sağlam özellikler (SURF)
- Yerel ikili örüntüler (LBP)
- Haar dalgacıkları
- Ölçek Değişmez Özellik Dönüşümü (SIFT)
- Renk histogramları

Özellikler çıkarıldıktan sonra, doğru nesne tanıma veya nesne algılama için makine öğrenme modelleri oluşturmak için kullanılabilirler.

Tablo 2.1 Özellik çıkarma algoritmaları (Açık kaynaklı)


	<i>HOG</i>	<i>SURF</i>	<i>LBF</i>	<i>HAAR</i>	<i>SIFT</i>
OpenCV	X	X	X	X	X
Scikit-image	X		X	X	
Dlib	X	X	X	X	
Matlab	X	X	X	X	X
Boofcv	X	X			X

3. MATERYAL VE METOD

3.1. Materyal

3.1.1. Polip Görüntüleri

Polipler, bağırsak içindeki mukozal büyüme olarak saptanabilen lezyonlardır. Polipler düz, yükseltilmiş veya pedinküle edilmiştir ve renk ve yüzey desenleri (pattern) ile normal mukozadan ayırt edilebilir. Çoğu bağırsak polipleri zararsızdır, ancak bazıları kansere dönüşme potansiyeline sahiptir. Bu nedenle kolorektal kanserin gelişmesini önlemek için poliplerin saptanması ve çıkarılması önemlidir (35).




Şekil 3.1 Polipin gelişim süreci (36)

Polip Görüntüleri Şekil 3,2’de gösterilen endoskopi cihazlarından elde edilmektedir.



Şekil 3.2 Endoskopi cihazı (37)

Çalışmada kullanılan polip görüntülerinin örneği Şekil 3.3’de gösterilmiştir



Şekil 3.3 Endoskopi cihazından alınan görüntü

3.1.2. Araştırmanın Veri Seti

Kvasir veri seti Norveç’te bulunan Vestre Viken Sağlık vakfına bağlı Bærum Hastanesi tarafından toplanmış ve Norveç Kanser Kayıt Merkezindeki uzmanlar tarafından kontrol edilmiştir. Veri seti toplam 4000 görüntü ve 8 sınıftan oluşmakta olup her sınıfta 500 görüntü bulunmaktadır. Bu görüntüler sindirim yolundaki anatomik dönüm noktaları, patolojik bulgular veya endoskopik prosedürler gibi her sınıf için yüzlerce görüntüden oluşan çeşitli sınıflara ait tıp doktorları (deneyimli endoskopistler) tarafından açıklanan ve doğrulanan görüntülerden oluşmaktadır. Görüntüler araştırma ve eğitim amaçlı olarak açık kaynaklı sunulan <https://datasets.simula.no/kvasir> web adresinden temin edilmiştir (35). Veri setinin genel özellikleri tablo 3.1’de verilmiştir.


Tablo 3.1 Veri seti özellikleri

Dosya Formatı	jpg
Kullanılan Yöntem	Basit Geçerlilik (Hold-out)
Veri Seti Türü	Açık Kaynaklı
Eğitim Görüntü Sayısı	276
Test Görüntü Sayısı	69
Toplam Görüntü Sayısı	345
Genişlik	350 piksel
Yükseklik	350 piksel
Yatay Çözünürlük	96 dpi
Dikey Çözünürlük	96 dpi

Çalışmamızda Kvasir veri setinde bulunan polip sınıfına ait JPG görüntü sıkıştırma formatında toplam 345 görüntü kullanılmıştır. Kullanılan bu görüntü veri seti Hold-out (%80 eğitim -%20 test) yöntemi kullanılarak 276'sı Eğitim ve 69'u test olacak şekilde ayrılmıştır.

3.1.3. Cmake

CMake, derleme işlemini bir işletim sisteminde ve derleyiciden bağımsız bir şekilde yöneten, genişletilebilir, açık kaynaklı bir sistemdir. Birçok çapraz platform sisteminden farklı olarak, CMake yerel yapı ortamıyla birlikte kullanılmak üzere tasarlanmıştır. Kaynak dizine yerleştirilen basit yapılandırma dosyasını (CMakeLists.txt), normal şekilde kullanılan standart derleme dosyalarını oluşturmak için kullanır (38).




Şekil 3.4 Cmake aracının görünümü

3.1.4. Imaglab

Imaglab, nesne sınırlama kutularına ve isteğe bağlı olarak parça konumlarına sahip görüntülere açıklama eklemek için basit bir grafik araçtır. Genellikle, bir nesne

detektörünü eğitmek istediğinizde kullanırsınız, çünkü gerekli eğitim veri setini kolayca oluşturmanıza izin verir (33). Dlib Kütüphanesi ile birlikte gelmektedir. Imglab aracı C++ programlama dili ile yazıldığından kullanılabilmesi için derlenmesi gerekmektedir.



Şekil 3.5 Imglab aracının görünümü

3.1.5. Dlib

Dlib kütüphanesi, C++ dilinde yazılmış, hızlı ve karmaşık yazılımlar oluşturmak için makine öğrenme algoritmalarını ve araçlarını içeren bir yazılımdır. Hem endüstride hem de akademik çevrede robotik, gömülü cihazlar, cep telefonları ve büyük yüksek performanslı bilgi işlem ortamları dâhil olmak üzere çok çeşitli alanlarda kullanılır.

Dlib kütüphanesi, içerisinde birçok makine öğrenme algoritması barındırır. Ayrıca bu kütüphane ile görüntü işleme algoritmaları olan HOG, FHOg, SURF yöntemlerinin yanı sıra, sayısal hesaplama, paralel işleme gibi fonksiyonları da bulunmaktadır (33).

3.1.6. OpenCV

Daha önce görüntü ön işleme bölümünde açıklanan OpenCV Kütüphanesi, bunlara ek olarak hem klasik hem de son teknoloji bilgisayarlı görü ve makine öğrenme algoritmalarının kapsamlı bir setini içeren 2500'den fazla optimize algoritmaya sahiptir. Bu algoritmalar yüzleri algılama ve tanıma, nesneleri tanımlama, videolardaki insan eylemlerini sınıflandırma, kamera hareketlerini izleme, hareketli nesneleri izleme,

nesnelerin 3B modellerini çıkarma, stereo kameralardan 3B nokta bulutları üretme, yüksek çözünürlük üretmek için görüntüleri birleştirme amaçları için kullanılabilir (39).

3.2. Metot


Bu tez çalışmasında kullanılan yöntemler 5 aşamada incelenebilir. Bunlar;

1. Görüntü ön işleme,
 2. Görüntülere sınırlayıcı kutu çizilmesi ve etiketlendirilmesi,
 3. Derin öğrenme modelinin oluşturulması,
 4. Modelin eğitimi,
 5. Masaüstü video işleme yazılımının geliştirilmesi,
- aşamalarını içermektedir.

3.3. Görüntü Ön İşleme

Veri seti içerisindeki görüntülerde endoskop ucunun bağırsak uzunluğu içindeki mevcut konumunun belirlenmesine yardımcı olan yeşil veya siyah kutular bulunmaktadır. Bu kutular görüntünün bütünü için herhangi bir anlam ifade etmediğinden dolayı görüntü içerisinde kırılarak kaldırılmıştır. Ayrıca 720x576'dan 1920x1072 piksele kadar farklı çözünürlüğe sahip görüntülerin 350x350 piksele dönüştürülmesi işlemi uygulanmıştır. Bu işlem ile standartlaştırılmış görüntüler elde edilmiştir.

Veri setindeki görüntülerin aynı boyutlara sahip olmasını önemlidir. Çünkü CNN giriş katmanı, her görüntü için bir piramit oluşturur. Bu piramit, herhangi bir boyuttaki bir nesnenin algılanmasını sağlar ve böylece CNN modeli, görüntü veri setindeki daha büyük veya daha küçük nesneleri algılamayı öğrenir.



Şekil 3.6 Polip ön işlemeye ilişkin gösterim

3.4. Görüntülere Sınırlayıcı Kutu Çizilmesi ve Etiketlendirilmesi

Ön işleme yapılan görüntülere sınırlayıcı kutu çizilmesi ve etiketleme işlemine başlamak için Imglab aracı ile XML veri kümesi oluşturulmuştur. Veri kümesini oluşturmak için aşağıdaki komutlar kullanılmıştır.

```
imglab -c training.xml train
```


```
imglab -c testing.xml test
```

Oluşturulan XML veri kümesindeki görüntülere sınırlayıcı kutu çizilmesi ve etiketleme yapılabilmesi için Imglab grafik arayüzüne erişmek gerekmektedir. Ara yüze erişmek için aşağıdaki komutlar kullanılmıştır.


```
imglab training.xml
```

```
imglab testing.xml
```

Imglab aracı klasör içerisinde bulunan görüntülerin listesini içeren bir pencere açılmış ve sınırlayıcı bir kutu çizilmesi ve her görüntüye ilişkin kutular için etiketleme yapılmıştır.




Şekil 3.7 Sınırlayıcı kutu ile tekli seçim




Şekil 3.8 Sınırlayıcı kutu ile çoklu seçim

Imglab aracı ile sınırlayıcı kutu oluşturmak için Şekil 3.7’de belirtilen sol taraftaki listeden görüntü seçilmiştir.




Şekil 3.9 Sınırlayıcı kutuların seçim işlemi

Seçilen görüntüye etiket eklemek için görüntünün üst bölümündeki “Label” alanı kullanılmıştır.



Şekil 3.10 Sınırlayıcı kutuların etiketlendirmesi

Tüm görüntüler için sınırlayıcı kutu çizilmesi ve etiketleme işlemi bittikten sonra, “File” menüsü altındaki “Save” butonu kullanılarak XML dosyası içine kayıt işlemi gerçekleştirilmiştir.




Şekil 3.11 Sınırlayıcı kutuların kayıt işlemi

3.5. Derin Öğrenme Modelinin Oluşturulması

Çalışmamızda Dlib Kütüphanesinde bulunan derin sinir ağları mimarilerinden Konvolüsyonel Sinir Ağları (CNN) ve Max-Margin nesne algılama yöntemi (MMOD) kullanılmıştır. Bu yöntem az miktarda eğitim verisinden yüksek kaliteli detektörler üretmektedir. Böylece binlerce görüntüye ihtiyaç duymadan çok az veri ile doğru sonuçlar elde edilebilmektedir.

CNN çoğunlukla görsel nesnelerin analiz edilmesinde kullanılan derin ve ileri beslemeli yapay sinir ağlarıdır. Bu ağlar, minimum ön işleme ile doğrudan görüntülerden nesne algılama için tasarlanmıştır.

Bu tez çalışmasında özel birçok katmanlı sinir ağına sahip Lenet (40) mimarisi kullanılmıştır.



Şekil 3.12 Çalışmada kullanılan CNN mimarisi

MMOD, görüntülerdeki nesnelerin algılanmasını öğrenmek için kullanılan bir yöntemdir. Bu yöntemde eğitim aşamasında detektör görüntüdeki her pencereyi alır ve yanlış algılamaları ve gözden kaçan algılamaları dengelemeyi amaçlayan uygun bir amaç fonksiyon ile puanlanır. MMOD yöntemi ile herhangi bir alt örnekleme gerçekleştirmez, bunun yerine tüm alt pencereleri optimize eder.

MMOD'daki kayıp şu şekilde hesaplanır

$$\Delta = (y, y_i) = L_{miss}(\# \text{ of missed detections}) + L_{fa}(\# \text{ of false alarms})$$

$Y \rightarrow$ nesnenin algılanan tanımını,

$y_i \rightarrow$ bu nesnenin gerçek adını,


$L_{miss} \rightarrow$ eksik algılama kaybını,

$L_{fa} \rightarrow$ yanlış algılama kaybını ifade etmektedir.

3.6. Modelin Eğitimi


Dlib kütüphanesi ile C++ programlama dilinde oluşturulan CNN+MMOD modelinin eğitim sırasındaki adımlarda kullanılan yöntemler şunlardır.

Veri setindeki görüntüler alınarak her görüntü için görüntü piramidi oluşturulmuştur. Oluşturulan piramit görüntüsü ile detektörlerin beklediği ölçekte nesnelerin bulunması sağlanmıştır. Böylece normal görüntüden bir kaç kat büyük olan görüntü piramidi dikdörtgen bir yapıda olduğu için CNN kullanılarak GPU üzerinde yüksek hızlarda çalışmasını ve işlenmesini kolay hale getirmiştir.




Şekil 3.13 Modele ait görüntü piramidi

CNN, görüntü piramidini girdi olarak almış, evrişim katmanlarını kullanarak yeni bir görüntü kümesi çıkarmıştır. Görüntü kümesinin polip içerebilecek her yerinde ısı haritası oluşturulmuştur. Isı haritasındaki parlak kırmızı renkteki bölgeler CNN'nin polip içerdiğini koyu mavi renkteki bölgeler ise polip içermediğini düşündüğü yerlerdir. Isı haritası görüntü piramidinin üzerine yerleştirildiğinde polipi doğru bir şekilde tespit ettiği görülmüştür.




Şekil 3.14 Modele ait ısı haritalı görüntü piramidi

CNN çıkışındaki tüm sıcak noktalar bulunduktan sonra maksimum olmayan bastırma yöntemi uygulanmış ve belirlenen sıcak noktalara karşılık gelen bölümler çıkarılmıştır. Böylece CNN + MMOD kullanılarak polipleri tanıyan bir model oluşturulmuştur.



Şekil 3.15 CNN+MMOD ısı haritası




Şekil 3.16 Polipin belirlenmesi

3.7 Masaüstü video işleme yazılımının geliştirilmesi


Video işleme yazılımı Python dilinde Dlib ve OpenCV kütüphaneleri kullanılarak geliştirilmiştir. Yazılımda, C++ programlama dilinde oluşturulan CNN+MMOD tarafından eğitilen model kullanılmıştır.

Video işleme yazılımı yüklenen video veya kameradan alınan görüntüleri çerçevelere ayırmış ve boyutlarını düşürülmüştür. Çerçevelere ayrılan görüntüler, modelimize ait CNN detektörleri tarafından taranmıştır. Böylece video görüntüleri içerisindeki polipler bulunmuş ve konumları belirlenmiştir. Konumlar kırmızı bir çerçeve içerisinde alınarak görünürlüğü sağlanmıştır.



Şekil 3.17 Video işleme yazılımı ile poliplerin bulunması

Video işleme yazılımında video kayıt özelliği de bulunmaktadır. Böylece işlenen videoların aynı zamanda arşivlenmesinde sağlanmıştır.



Şekil 3.18 Video kayıtlarının arşivlenmesi

3.8. Performans Değerlendirme Ölçütleri

Doğru Pozitif = True Positive (TP)

Yanlış Pozitif = False Positive (FP)

Doğru Negatif = True Negative (TN)

Yanlış Negatif = False negative (FN)

Kesinlik (Precision) : Doğru tahmin edilen pozitif örneklerin toplam tahmin edilen pozitif örneklere oranıdır.

$$Kesinlik = \frac{TP}{TP + FP}$$

Duyarlılık (Recall): Doğru tahmin edilen pozitif örneklerin gerçek sınıftaki tüm örneklere oranıdır.

$$Duyarlılık = \frac{TP}{TP + FN}$$

F1-Skor: Kesinlik ve Duyarlılığın ağırlıklı ortalamasıdır. Bu nedenle, f1-score hem yanlış pozitifleri hem de yanlış negatifleri dikkate alır.

$$F1 - Skor = \frac{2 * duyarlılık * kesinlik}{duyarlılık + kesinlik}$$

Ortalama Kesinlik (Average Precision; AP): Ortalama kesinlik, sıralı alım sonuçları için geri çağırma ve hassasiyeti birleştiren bir ölçüdür.


$$AP = \sum (duyarlılık_n - duyarlılık_{n-1}) P_{interp}(duyarlılık_{n+1})$$

$$P_{interp}(duyarlılık_{n+1}) = \max_{\tilde{r} \geq r_{n+1}} p(\tilde{r})$$

Ortalama Kesinlik Ölçütü (Mean Average Precision; mAP): mAP Algılama algoritmalarını değerlendirmek için kullanılır. MAP metriği, algılanan sınırlayıcı kutuların hassas ve geri çağırma ürünüdür. MAP değeri 0 ile 1 arasında değişir. Sayı ne kadar yüksek olursa o kadar iyidir. MAP, her sınıf için ayrı ayrı ortalama kesinlik (AP) ve ardından sınıf üzerindeki ortalama hesaplanarak bulunabilir. Bir algılama, yalnızca mAP değeri 0.5'in üzerindeyse doğru pozitif olarak kabul edilir.

$$mAP = \frac{1}{N} \sum_i AP_i$$


IoU (Intersection over Union – Kesiştirilmiş Bölge): Veri kümesindeki nesne dedektörünün doğruluğunu ölçmek için kullanılan bir değerlendirme metriğidir.



Şekil 3.19 Polip sınırlayıcı kutularının gösterimi

Yukarıdaki şekilde nesne detektörleri tarafından polip görüntüsünün tahmin edildiği görülüyor. Kırmızı ile gösterilen bölge gerçekte sınırlayıcı kutunun bulunduğu alanı yeşil ile gösterilen bölge ise tahmin edilen sınırlayıcı kutunun bulunduğu alanı göstermektedir.

IoU, Tahmin edilen sınırlayıcı kutu ile gerçekteki sınırlayıcı kutunun kesiştikleri alanın bu iki sınırlayıcının birleştikleri alana bölümü ile hesaplanır. $IoU > 0.5$ üzeri bir değere sahipse iyi bir tahmin olduğu söylenebilir.



Şekil 3.20 IoU hesaplama

LRP (Localization Recall Precision - Konumlandırma Kesinliği ve Duyarlılığı) : Her nokta için konumlandırma, kesinlik ve duyarlılık hatalarından oluşan bir performans puanı belirleyerek geri çağırma hassasiyeti (RP) eğrisinde hareket eder (bu bir RP noktasının LRP puanıdır) ve son olarak detektörün ulaşabileceği en iyi yapılandırmayı bulur (ulaşılabilir minimum LRP oLRP'dir).

$$LRP_{FP}(X, Y_S) := 1 - Precision = 1 - \frac{N_{TP}}{|Y_S|} = \frac{N_{FP}}{|Y_S|}, \quad w_{FP} = |Y_S|$$

$$LRP_{FN}(X, Y_S) := 1 - Recall = 1 - \frac{N_{TP}}{|X|} = \frac{N_{FN}}{|X|}, \quad w_{FN} = |X|$$

$$LRP(X, Y_S) := \frac{1}{N_{TP} + N_{FP} + N_{FN}} \left(\sum_{i=1}^{N_{TP}} \frac{1 - IoU(x_i, y_{xi})}{1 - \tau} + N_{FP} + N_{FN} \right)$$

$$oLRP := \min_S LRP(X, Y_S)$$



4. BULGULAR

Çalışmamızda kullanılan görüntüler 276'sı eğitim ve 69'u test olacak şekilde ayrılmıştır. Ayrılan görüntüler 350x350 piksel çözünürlüğüne düşürülerek standartlaşma sağlanmış ve CNN modeli için uygun hale getirmiştir. CNN derin öğrenme mimarisi ve MMOD yöntemi ile model oluşturulmuş ve bu model ile yazılım yapılarak görüntü içerisindeki poliplerin bulunması sağlanmıştır.

CNN modelinin başlangıç parametre değerleri Tablo 4.1'de verilmiştir. Yazılımda uygulanan yöntemler ve sonuçlar bulgularla aşağıda açıklanmıştır. Bu değerlerin ayrıntıları aşağıdaki Tablo 4.1'de verilmiştir.


Tablo 4.1 CNN modelinin başlangıç parametre değerleri

Parametre	Değer
Net Layer (Ağ Katmanı)	21
Net size (Ağ Boyutu)	0.955304 MB
Overlaps_nms	(0.1, 0.1)
Overlaps_ignore	(0.5, 0.95)
İterations without progress threshold (İlerleme eşiği olmayan tekrarlamaları)	50000
Test iterations without progress threshold (İlerleme eşiği olmayan test tekrarlamaları)	1000
Optimization algorithm (Optimizasyon algoritması)	SGD (Stochastic gradient descent)
Learning rate (Öğrenme Oranı)	0.0001
Min learning rate (En Küçük Öğrenme Oranı)	0.0001
Learning rate shrink factor (Öğrenme oranı küçültme faktörü)	0.1
Weight decay (Ağırlık kaybı)	0.0001
Momentum	0.9
Truth match IOU thresh	0.5
Loss per miss	1
Loss per FA	1

CNN+MMOD ile oluşturulan modelin testinde, test verisi olarak 69 polip görüntüsü ve 71 sınırlayıcı kutu oluşturulmuştur. Modelin eğitim ve test işlemleri Intel® Xeon® E5-1630 v3 (8 Core, 3.70 GHz) işlemci, 32 GB hafıza ve NVIDIA GeForce GTX1080 Ti 11GB ekran kartı üzerinde gerçekleştirilmiştir. Eğitim yaklaşık olarak 21 saat sürmüş ve 140581 iterasyonda tamamlanmıştır.

CNN ağı, 21 katman ve 5x5 filtre boyutlarında evrişimlerden oluşturularak eğitilmiştir. Başlangıç değeri olarak öğrenme hızı küçültme faktörü (Learning rate shrink factor) 0.1 seçilmiş ve 127915 iterasyona kadar devam etmiştir. Minimum öğrenme hızına (Min. learning rate) 0.0001'e ulaştığında eğitim tamamlanmıştır.

Modelin eğitimi tamamlandığında test kayıp değeri 0.46462 ve eğitim kayıp değeri 0.01058 elde edilmiştir. Sonuçlar Şekil 4.1'deki grafikte verilmiştir.




Şekil 4.1 Eğitim kayıp değerleri

Belirlenen referans niteliğindeki sınır kutuları ile modelin tahmin ettiği sınır kutularının bir örneği Şekil 4.2 ve 4.3’de verilmiş olup test verilerine ait 69 polip görüntüsü ve 71 sınır kutusunun tahmin sonuçları Tablo 4.2’ de verilmiştir.


Tablo 4.2 Tahmin Değerler

Tahmin	Sınır Kutusu
Doğru Pozitif	64
Yanlış Pozitif	1
Yanlış Negatif	7

Tahmin değerleri hesaplanırken test verilerine ait görüntülerin kontrolleri yapılmıştır. Şekil 4.2. ve Şekil 4.3’de kırmızı kutularla referans sınır kutularını, mavi kutular ise modelin tahmin ettiği kutuları göstermektedir. 1 numaralı kutu yanlış pozitif 2 numaralı kutu doğru pozitif ve 3 numaralı kutu ise yanlış negatiftir.



Şekil 4.2 Modelin yanlış pozitif (1) – doğru pozitif (2) tanılama değerleri



Şekil 4.3 Modelin yanlış negatif (3) tanılama değerleri

Modelin tanılama performansı, daha önce bölüm 3.8’de belirtilen değerlendirme ölçütlerine göre hesaplanmıştır. Hesaplamada nesne tespiti için yeni bir performans ölçütü olan konumlandırma kesinlik ve duyarlılığı (Localization Recall Precision, LRP) kullanılmıştır. LRP hesaplaması için eğitim ve test verilerine ilişkin elde edilen IoU değeri kullanılmıştır.




Şekil 4.4 IoU değeri hesaplanmış polip'e ilişkin gösterim

Hesaplama sonucunda tek nesne sınıfı olduğu için AP değeri mAP ile ve oLRP değeri moLRP ile aynı sonuçları vermiştir. Eğitim ve test görüntü veri setine ait ölçüt değerleri Tablo 4.3'te verilmiştir.


Tablo 4.3: Eğitim ve test görüntü veri setine ait ölçüt değerleri

Ölçüt	Eğitim	Test
Precision	1	0.9846
Recall	1	0.9014
F1-Score	1	0.9412
AP	1	0.8942
mAP	1	0.8942
oLRP ($\tau=0.5$)	0.4064	0.4862
moLRP ($\tau=0.5$)	0.4064	0.4862



Şekil 4.5 Performans değerlendirme ölçütlerinin grafiği

Yazılım ara yüzünde, video formatında veya herhangi bir kameradan alınan anlık video görüntüleri CNN+MMOD modeli ile işlenerek polip bulunan bölgeler belirlenmiş ve sınır kutuları çizilmiştir. Ayrıca tahmin edilen sınır kutusuna ait koordinat değerlerine ara yüzün üst kısmında yer verilmiştir.



Şekil 4.6 Yazılım ara yüzüne ait gösterim

5. TARTIŞMA

Tıbbi görüntü işleme, yapay zekâ uygulamalarının tıpta en önemli bileşenlerinden biridir ve derin öğrenmenin gelişimi bu alana büyük katkılar sağlamıştır. Tıbbi görüntü işlemede başlıca üç tür amaç (sınıflandırma, algılama ve bölümleme) olup, bunlar birbirleri ile yakından ilişkilidir. Özellikle nesne algılama, birçok tıbbi görüntü işleme görevinin temelini oluşturmaktadır. Son yıllarda derin öğrenme alanındaki gelişmeler, modellerin nesne algılama performansına büyük katkı sağlamaktadır. Nesne algılama modellerinin çoğu yaya algılama ve araç algılama gibi genel görüntü alanı için tasarlanmıştır. Fakat tıbbi görüntüler, genel resimlerden önemli ölçüde farklı özelliklere sahiptir. Genel görüntü alanındaki modeller tıbbi görüntü alanına doğrudan uygulanması durumunda, bu farklılıklar düşük model performansına neden olabilir. Lezyonların veya ilgili nesnelerin tespiti genellikle semantik bölümleme veya hastalık teşhisi gibi takip işlemleri içindir. Bu nesne algılama görevlerindeki algılama hedeflerinin büyük bir kısmının bazı ortak özellikleri vardır (boyut, şekil, bulanık sınır, tek hedef, vb.). Bu nedenle, tıbbi görüntülerin işlenmesinde kullanılan yöntemler ilave hesaplama zamanı gerektirebilir. Tıbbi görüntülerin bir başka özelliği, elde edilmesinin maliyetli olması ve eğitim görüntülerinin genel resimler kadar yeterli sayıda olmaması gibi sorunları içermesidir. Hastalıklara ilişkin çoğu tıbbi veri setindeki görüntü sayısı genellikle az olabilmektedir; bu nedenle eğitim verilerinin tüm hastalıklara ait olası bütün durumları kapsamaması zordur. Ayrıca, tıbbi donanımların ve çalışma ortamının neden olduğu farklılıklar nedeniyle, farklı hastanelerde veya aynı hastanede çekilen görüntüler, farklı veri dağılımına ve yapısına sahip olabilir (41).

Bu çalışmada video/görüntü işleme teknikleri ve derin öğrenme mimarileri kullanılarak tıbbi görüntülerde bulunan nesnelerin tespiti, tanımlanması, sınıflandırılması ve takibi sağlanarak sağlık personelleri için kullanıcı dostu bir yazılım geliştirilmiştir. Bu kapsamda, açık kaynak video görüntü veri seti kullanılmış olup, ilgili video görüntü üzerindeki nesneleri algılamak için yapay zekâ ve derin öğrenmeye yöntemlerine dayalı modeller oluşturulmuş, bilgisayar destekli tanı sistemleri geliştirilmiş ve deneysel sonuçlar değerlendirilmiştir. Böylelikle bu çalışma ile sağlık personellerinin, hastalığa yönelik klinik kararlar vermesine yardımcı olmasına ilaveten hastalık teşhisi, takibi ve gelişimi konularında da destek sağlaması hedeflenmiştir. Bu çalışmada, deneysel bulgular kapsamında endoskopik poliplere ilişkin açık erişimli video görüntü veri seti incelenmiş, modeller oluşturulmuş ve poliplere doğru tanı koyabilecek bir klinik karar destek yazılımı

geliştirilmiştir. Bu kapsamda, tıbbi video görüntülerine ön işleme yöntemleri uygulanmış, nesne sınırlama kutusu ve etiketleme yapılarak derin öğrenmeye dayalı polip tanıma modelleri oluşturulmuştur. Bu tez çalışmasının uygulamasında endoskopik poliplere ilişkin açık erişimli video görüntü veri seti üzerinde önceden açıklanan aşamalar gerçekleştirildiğinde, eğitim veri setinde incelenen bütün performans metrikleri 1 değerini alırken, test veri setinde ise kesinlik %98, duyarlılık %90, F1 skoru %94, AP ve mAP %89, oLRP ve moLRP ise %48 olarak hesaplanmıştır. Hesaplanan performans ölçütlerine ait değerler dikkate alındığında, önerilen sistemin endoskopik poliplerin tanısında başarılı tahminler verdiği tespit edilmiştir.

Mevcut polip algılama yöntemlerinin çeşitli eksikliklerinden söz edilmektedir. Bunlardan birisi, manuel olarak çıkarılan özelliklere bağlıdır ve bu aşamanın tamamlanması önemli miktarda ön işleme gerektirmesi ve diğeri de çoğu geleneksel yöntemin, özellikle değişken boyutlu poliplerin kolonoskopi görüntülerindeki yerlerinin belirlenememesidir (42). Bu tez araştırmasında sözü edilen eksiklikleri gidermek için derin öğrenme mimarilerinden CNN'e dayanan model kullanılmış ve ilgili modelin hiperparametreleri en uygun hale getirilerek endoskopik poliplerin tansında kullanılabilecek bir araç önerilmiştir.

Gastrointestinal polip, sindirim organlarındaki dokuların anormal büyümesi olarak adlandırılmakta olup, bu poliplerin endoskopi videosu veya görüntüsünden tanımlanması, ileride gastrointestinal kanser riskini azaltmak için oldukça önemlidir. Kolorektal poliplerin erken teşhisi ve rezeksiyonu, insidans ve mortalite oranını etkili bir şekilde azaltabilir. Kolorektal kanser, dünyadaki üç büyük maligniteden birini sıralayan yaygın bir gastrointestinal malignitedir. Yaşam standartlarının ve beslenme alışkanlıkları ile ilgili sorunların iyileştirilmesi ile kolorektal kanser insidansı ve mortalitesi yükseliş eğilimi göstermektedir. Kolorektal kanser çoğunlukla adenom polip malign değişiminden kaynaklanır, bu nedenle erken teşhis önemli klinik öneme sahiptir. Gastrointestinal polip'in son aşamalarından biri, hem erkeklerde hem de kadınlarda görülen en yaygın hastalıklardan olan kolorektal kanserdir. Günümüzde, kanserlerin çoğu türleri, birincil büyümeleri daha erken aşamalarda tespit edilebilirse tedavi edilebilir. Poliplerin daha erken aşamalarda doğru tespiti ile gastrointestinal kanserler de başarıyla önlenabilir. Poliplerin teşhisi için yaygın olarak kullanılan tıbbi bir yöntem video endoskopidir. Doktorlar/operatörler endoskopi sırasında iç kısımları görmek için küçük bir kamera kullanırlar. Endoskopinin yorucu süreci sırasında, radyologlar polipleri vakaların neredeyse % 27'sini tespit edememektedir ve poliplerin

yanlış teşhisi gelecekte malign tümörlere dönüşebilir. Bu bağlamda bu çakışmanın çıktıları, gastrointestinal poliplerin tanılanmasında kullanılabilecek niteliktedir.

Bu bölümde son iki yılda yayımlanan gastrointestinal poliplerin tanısında kullanılan yapay zekâ yöntemlerini inceleyen çeşitli çalışmalardan söz edilmiştir. Bir araştırmada, gastrointestinal polip tespitine destek olarak endoskopik video karelerinin renk dalgacık ve evrişimli sinir ağı özelliklerine dayalı bilgisayar tabanlı bir sistem önerilmiştir. Bu kapsamda endoskopik videodan gastrointestinal polipleri tespit etmek ve sınıflamak için önerilen sistemin, farklı açık veri tabanlarından alınan veri setlerinde mevcut yöntemlerden daha iyi performans gösterdiği saptanmıştır (43).

Güncel bir çalışmada, önceden eğitilmiş modellerden Alexnet, ResNet50, VGG16, VGG19 kullanılarak uygun bir polip tanı yöntemi önerilmektedir. Ayrıca, bu araştırmada, sınıflandırma için sezgisel özellikleri toplamak için temel bileşen analizi ve minimum artıklık maksimum alaka düzeyi yöntemi ise boyut indirgeme için kullanılmıştır. Açık veri setleri üzerinde yapılan analizler sonucunda, %99.59 doğruluk, %99.74 duyarlılık, %99.44 özgüllük değerleri bulunmuş ve radyologlar için gerçek zamanlı endoskopi sırasında poliplerin teşhisinde etkili olabileceği önerilmiştir (44).

Diğer bir araştırmada, kolonoskopinin polipleri belirlemede en etkili yol olarak görülmesi ve olası belirsizliklerin sonuçları etkileyebilmesi sorununu çözmek için kolorektal poliplerin bilgisayar tarafından otomatik olarak algılanması ve segmentasyonu için tamamen evrişimsel bir densenet yöntemi ortaya konulmaktadır. Kolorektal poliplerin segmentasyonunda katman sayısı 78 ($N = 78$) olduğunda, doğruluk% 97,1 ve ortalama IOU ise % 83,4 olarak hesaplanmıştır. Deneysel sonuçlar, katmanların kademeli olarak artmasıyla tüm parametrelerin belirli bir iyileşme gösterdiğini ve önerilen modelin birçok değerlendirme ölçütüne göre kolorektal poliplerin segmentasyonu üzerinde iyi bir etki yaptığını ortaya koymuştur (45).

6. SONUÇ VE ÖNERİLER

Sonuç olarak, bu çalışmanın temel çıktıları ve katkıları aşağıdaki gibi sıralanabilir.

- İncelenen açık kaynak video veri setinden çıkarılan özellikler ve oluşturulan derin öğrenme modeli ile endoskopik poliplerin bilgisayar destekli tanı yöntemi tasarlanmıştır.
- Sınırlı görüntülerle polip tespiti için ince ayarlanmış bir model seçmek ve oluşturmak için kapsamlı aşamalar açıklanarak tanı konulmuştur.
- Performans değerlendirme ölçütlerine göre endoskopik poliplerin tahmininde oldukça başarılı sonuçlar elde edilmiştir.
- Önerilen bilgisayar destekli sistemin klinisyenlere tanı, tedavi ve izlem sürecinde klinik olarak destek sağlayabilecektir.

Sonraki araştırmalarda, aşağıda belirtilen konuların incelenmesi önerilebilir:

- Önceden eğitilmiş ağlardan Alexnet, ResNet50, VGG16, VGG19 vb. modelleri endoskopik poliplerin tanısında başarılı sonuçlar verip vermemesi incelenebilir.
- Evrişimsel sinir ağları mimarilerinden LeNet, GoogLeNet vb. modellerine ilişkin tahminleri topluluk öğrenme yöntemleri ile ele alınarak daha yüksek performans metrikleri elde edilebilir.
- Modellerin hiperparametrelerinin optimizasyonunda farklı yöntemler kullanılabilir.
- Çeşitli modellere ilişkin tahminler topluluk öğrenme yöntemleri ile birleştirilebilir.
- Bu çalışmada önerilen sistemin mobil uygulamaları (android, ios, vb.) geliştirilebilir.
- Bu araştırma kapsamında incelenen poliplerin tahmininde diğer derin öğrenme mimarilerine dayalı olarak oluşturulacak olan modeller kullanılabilir.
- Önerilen yaklaşımın tıbbi video görüntü verilerinden gastrointestinal poliplerin tanısında başarılı tahminler vermesi nedeniyle diğer tıbbi hastalıklara ait video görüntülerinden de tanı konulmasına yönelik uygulamalar gerçekleştirilebilir.

KAYNAKLAR

1. Dheir IM, Mettleq ASA, Elsharif AA, Abu-Naser SS. Classifying Nuts Types Using Convolutional Neural Network. *International Journal of Academic Information Systems Research* 2020, 3(12): 12-8.
2. Konar A. *Computational intelligence: principles, techniques and applications*, Springer Science & Business Media 2006.
3. Goertzel B, Pennachin C. *Artificial general intelligence*, Springer 2007.
4. Kurzweil R. *The age of spiritual machines: When computers exceed human intelligence*, Penguin 2000.
5. Arrieta AB, Díaz-Rodríguez N, Del Ser J, Bennetot A, Tabik S, Barbado A, García S, Gil-López S, Molina D, Benjamins R. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion* 2020, 5882-115.
6. Vinuesa R, Azizpour H, Leite I, Balaam M, Dignum V, Domisch S, Felländer A, Langhans SD, Tegmark M, Nerini FF. The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature communications* 2020, 11(1): 1-10.
7. Vaishya R, Javaid M, Khan IH, Haleem A. Artificial Intelligence (AI) applications for COVID-19 pandemic. *Diabetes Metab Syndr* 2020, 14(4): 337-9.
8. Wu W, Alvarez J, Liu C, Sun H-M. Bot detection using unsupervised machine learning. *Microsystem Technologies* 2018, 24(1): 209-17.
9. <https://medium.com/@odayibasi/makine-%C3%B6%C4%9Frenmesi-nedir-eac85d27d438> 21.04.2020
10. Society R. *Machine Learning: The Power and Promise of Computers that Learn by Example: an Introduction*, Royal Society 2017.
11. Yu J, Liu G. Knowledge-based deep belief network for machining roughness prediction and knowledge discovery. *Comput Ind* 2020, 121(7): 103262.
12. Liang D, Cheng J, Ke Z, Ying L. Deep magnetic resonance image reconstruction: Inverse problems meet neural networks. *IEEE Signal Process Mag* 2020, 37(1): 141-51.
13. Yasaka K, Akai H, Kunimatsu A, Kiryu S, Abe O. Deep learning with convolutional neural network in radiology. *Jpn J Radiol* 2018, 36(4): 257-72.

14. Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, Kadoury S, Tang A. Deep learning: a primer for radiologists. *Radiographics* 2017, 37(7): 2113-31.
15. Deng L, Yu D. Deep learning: methods and applications. *Foundations trends in signal processing* 2014, 7(3–4): 197-387.
16. Minaee S, Boykov Y, Porikli F, Plaza A, Kehtarnavaz N, Terzopoulos D. Image segmentation using deep learning: A survey. *arXiv preprint arXiv:05566* 2020.
17. Wang Q, Bu S, He Z. Achieving Predictive and Proactive Maintenance for High-Speed Railway Power Equipment with LSTM-RNN. *IEEE Trans Industr Inform* 2020, 16(10): 6509 - 17.
18. <https://towardsdatascience.com/understanding-rnn-and-lstm-f7cdf6dfc14e>
18.04.2020
19. Li P, Abdel-Aty M, Yuan J. Real-time crash risk prediction on arterials based on LSTM-CNN. *Accident Analysis Prevention* 2020, 135(9): 105371.
20. 12.05.2020
21. Kaur N, Kunapuli G, Natarajan S. Non-parametric learning of lifted Restricted Boltzmann Machines. *Int J Approx Reason* 2020, 120(3): 33-47.
22. <https://devhunteryz.wordpress.com/2018/07/25/kisitli-boltzmann-makineleri/>
18.04.2020
23. Ajit A, Acharya K, Samanta A, editors. A Review of Convolutional Neural Networks. 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE); 2020: IEEE.
24. Al-Masni MA, Kim D-H, Kim T-S. Multiple skin lesions diagnostics via integrated deep convolutional networks for segmentation and classification. *Comput Methods Programs Biomed* 2020, 190(10): 105351.
25. Mao W, Ding L, Tian S, Liang X. Online detection for bearing incipient fault based on deep transfer learning. *Measurement* 2020, 152(6): 107278.
26. Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M. Imagenet large scale visual recognition challenge. *Int J Comput Vis* 2015, 115(3): 211-52.
27. Too EC, Yujian L, Njuki S, Yingchun L. A comparative study of fine-tuning deep learning models for plant disease identification. *Comput Electron Agric* 2019, 161(7): 272-9.

28. İnce Ö, Senel I, Yılmaz F. Image Processing and Analysis in Health: Advantages, Challenges, Threats and Examples. *Archives of Health Science and Research* 2020, 7(1): 66-74.
29. <https://medium.com/futframe-ai/fundamental-steps-of-digital-image-processing-d7518d6bb23c> 20.02.2020
30. Liu L, Ouyang W, Wang X, Fieguth P, Chen J, Liu X, Pietikäinen M. Deep learning for generic object detection: A survey. *Int J Comput Vis* 2020, 128(2): 261-318.
31. <https://www.geeksforgeeks.org/opencv-overview/> 22.04.2020
32. <https://en.wikipedia.org/wiki/Scikit-image> 21.04.2020
33. <http://dlib.net/> 15.03.2020
34. <https://boofcv.org/index.php?title=BoofCV>About> 15.02.2020
35. Pogorelov K, Randel KR, Griwodz C, Eskeland SL, de Lange T, Johansen D, Spampinato C, Dang-Nguyen D-T, Lux M, Schmidt PT, editors. Kvasir: A multi-class image dataset for computer aided gastrointestinal disease detection. Proceedings of the 8th ACM on Multimedia Systems Conference; 2017.
36. <https://www.kolonrektum.com/kolon-ve-rektum-polipleri> 06.06.2020
37. <http://www.hasvet.com.tr/urundetay/fujifilm-epx3500hd-endoskopi-sistemi> 27.04.2020
38. <https://cmake.org/overview/> 24.04.2020
39. Bradski G. The OpenCV Library. *Dr Dobb's Journal of Software Tools* 2000.
40. <http://yann.lecun.com/exdb/lenet/> 27.04.2020
41. Li Z, Dong M, Wen S, Hu X, Zhou P, Zeng Z. CLU-CNNs: Object detection for medical images. *Neurocomputing* 2019, 350(6): 53-9.
42. Li J, Zhang J, Chang D, Hu Y. Computer-Assisted Detection of Colonic Polyps Using Improved Faster R-CNN. *Chinese Journal of Electronics* 2019, 28(4): 718-24.
43. Billah M, Waheed S. Minimum redundancy maximum relevance (mRMR) based feature selection from endoscopic images for automatic gastrointestinal polyp detection. *Multimed Tools Appl* 2020, 791-11.
44. Hasan MM, Islam N, Rahman MM. Gastrointestinal polyp detection through a fusion of contourlet transform and Neural features. *Journal of King Saud University-Computer Information Sciences* 2020, In Press.

45. Yu J, Pan H, Yin Q, Bian X, Cui Q, editors. Fully convolutional DenseNets for polyp segmentation in colonoscopy. 2019 IEEE 35th International Conference on Data Engineering Workshops (ICDEW); 2019: IEEE.



EKLER

EK-1. Özgeçmiş

ÖZGEÇMİŞ

Adı Soyadı : Hasan UCUZAL

Doğum Yeri ve Tarihi : MALATYA -1979

Elektronik posta : hasanucuzal@gmail.com

İletişim Adresi : İnönü Üniversitesi Kampüs Battalgazi/Malatya

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Yazılım Mühendisliği	Fırat Üniversitesi	2018 -.....
Lisans	İşletme - işletmecilik	Anadolu Üniversitesi	2008 - 2014
Y. Lisans	Biyoistatistik ve Tıp Bilişimi AD	İnönü Üniversitesi	2018 - 2020

Yayınlar :

1. Ucuzal, H., Arslan, A. K., & Çolak, C. (2019, September). Deep learning based-classification of dementia in magnetic resonance imaging scans. In *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-6). IEEE.
2. Ucuzal, H., YAŞAR, Ş., & Çolak, C. (2019, October). Classification of brain tumor types by deep learning with convolutional neural network on magnetic resonance images using a developed web-based interface. In *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5). IEEE.
3. Ucuzal, H., Çiçek, İ. B., Arslan, A. K., & Çolak, C. (2019, October). A Web-Based Application for Identifying Objects In Images: Object Recognition

Software. In *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5). IEEE.

Projeler:

1. TÜSEB projesi - Polikistik Over Sendromunun Alt Gruplarının Belirlenmesi için Deneysel Metabolomik Verilerin Derin Öğrenme Yaklaşımları ile Analizi
2. BAP projesi - Covid-19 Tanısına Yönelik Tıbbi Görüntülere Dayalı Yapay Zeka Tabanlı Klinik Karar Destek Sistemlerinin Geliştirilmesi
3. BAP projesi - İnönü Üniversitesi Turgut Özal Tıp Merkezinde Koroner Arter Bypass Operasyonu Yapılan Hastalarda Gelişen Postoperatif Atriyal Fibrilasyonun Tıbbi Bilgi Keşfi Süreci ile Tahmini



EK-2. Etik Kurul Almama Gerekçesi



Evrak Tarih ve Sayısı: 10/07/2019-E.53041

T.C.
İNÖNÜ ÜNİVERSİTESİ REKTÖRLÜĞÜ

Tıp Fakültesi Dekanlığı
Biyostatistik ve Tıp Bilişimi Anabilim Dalı Başkanlığı



Sayı : 58137357-100
Konu : Hasan UCUZAL Tez Öneri Formu

SAĞLIK BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Anabilim dalımız yüksek lisans programı 38173842009 numaralı öğrencisi Hasan UCUZAL'ın tez öneri formu ektedir. Ayrıca söz konusu tez çalışmasında açık kaynak erişimli video/görüntü veri setleri kullanılacağı için etik kurul izni gerektirmemektedir.
Gereğini arz ederim

e-imzalıdır
Prof.Dr. Saim YOLOĞLU
Anabilim Dalı Başkanı

Ek: 1 Adet

Tıp Fakültesi Dekanlığı
Telefon No: 3410660 Faks No: 3410036
E-Posta: biyoistatistik@inonu.edu.tr İnternet Adresi:
<https://www.inonu.edu.tr/tr/cms/biyoistatistik>

Bilgi İçin: İpek BALIKCI
Unvan: Öğretim Elemanı
Telefon No: 3410660

Bu belge 5070 sayılı Elektronik İmza Kanununun 5. Maddesi gereğince güvenli elektronik imza ile imzalanmıştır.