

Evrşimsel Sinir Ağları Kullanarak ÇKA Sınıflandırıcısı ile Mide Displazisinin Tespiti

Seda SAĞIROĞLU^{1*}, Seda ARSLAN TUNCER², Birgül KARAHAN³, İbrahim Hanifi ÖZERCAN⁴

¹ Yazılım Mühendisliği, Fen Bilimleri Enstitüsü, Fırat Üniversitesi, Elazığ, Türkiye

² Yazılım Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

³ Fethi Sekin Şehir Hastanesi, Tıbbi Patolog, Elazığ, Türkiye

⁴ Fırat Üniversitesi Tıp Fakültesi, Tıbbi Patolog, Elazığ, Türkiye

*¹ sesagiroluu@gmail.com, ² satuncer@firat.edu.tr ³ gri-36@hotmail.com, ⁴ ozercanih@yahoo

(Geliş/Received: 08/08/2023;

Kabul/Accepted: 22/03/2024)

Öz: Son yıllarda Dünya’da ve Türkiye’de yapılan araştırmalarda da görüldüğü üzere mide kanseri diğer kanser türlerine oranla ilk sıralarda yer almaktadır. Tespit edilme açısından da oldukça zorluk çekilen bir kanser türü olarak bilinmektedir. Mide displazisi, midenin iç yüzeyini kaplayan hücrelerin normal şekilde büyümesini ve gelişmesini durdurmasıdır. Bu hücreler, kontrolsüz bir şekilde büyümeye ve çoğalmaya başlarlar, sonrasında mide kanserine dönüşmektedirler. Bu hastalığı kansere dönüşmeden en aza indirgeyebilmek temel hedeftir. Mide displazisi düşük dereceli ve yüksek dereceli displazi olmak üzere iki şekilde ayrılır. Yüksek dereceli displazi, kanserin bir öncesidir. Bu yüzden mide displazinin tanı ve tedavisi için erken dönemde teşhis son derece önem taşımaktadır. Bu çalışmada, mide displazinin tespiti için derin öğrenme ve evrşimsel sinir ağları teknikleri kullanılarak displazi durumunun erken evrede tespiti amaçlanmaktadır. Çalışmada histopatolojik görüntüler üzerinde birden fazla Evrşimsel Sinir Ağları (ESA) modeli kullanılarak özellik çıkarma işlemi yapılmıştır. Hasta ve sağlıklı olmak üzere iki etiket sınıfına ayrılan veri derin öğrenme mimarileri ve sınıflandırıcılar yardımıyla karşılaştırılmıştır.

Anahtar kelimeler: Derin Öğrenme, Mide Displazi, Sınıflandırma, Evrşimsel Sinir Ağları(ESA), Çok Katmanlı Algılayıcı (ÇKA).

Detection of Stomach Dysplasia by MLP Classifier using Conventional Neural Networks

Abstract: As seen in research conducted in the world and in Turkey in recent years, stomach cancer ranks first compared to other types of cancer. It is known as a type of cancer that is very difficult to detect. Gastric dysplasia is when the cells lining the inner surface of the stomach stop growing and developing normally. These cells begin to grow and multiply uncontrollably, then turn into stomach cancer. The main goal is to minimize this disease before it turns into cancer. Gastric dysplasia is divided into two types: low-grade and high-grade dysplasia. High-grade dysplasia is a precursor to cancer. Therefore, early diagnosis is extremely important for the diagnosis and treatment of gastric dysplasia. This study aims to detect dysplasia at an early stage by using deep learning and convolutional neural networks techniques for the detection of gastric dysplasia. In the study, feature extraction was performed on histopathological images using multiple Convolutional Neural Networks (ESA) models. The data, divided into two label classes: patient and healthy, were compared with the help of deep learning architectures and classifiers.

Key words: Deep Learning, Gastric Dysplasia Classification, Convolutional Neural Networks (CNN), Multi-layer Perceptron (MLP).

1. Giriş

Mide kanseri, dünyada en sık görülen beş kanser türünden biridir [1]. Görülme sıklığı dünya genelinde büyük farklılıklar göstermektedir [1]. Mide kanseri, en sık Japonya ve Çin’de görülürken üçüncü sırayı Avrupa takip etmektedir. Amerika’da 2013 yılında 21.600 yeni mide kanseri vakası ve yaklaşık 10.990 mide kanserine bağlı yaşam kaybı olduğu tahmin edilmektedir. Ülkemizde 2020 yılında Dünya Sağlık Örgütü’ne göre yaklaşık 2 milyon kişiye mide kanseri teşhisi konulmuştur. Mide kanseri en sık görülen kanser türleri arasında yer alır. Erkeklerde 5. sırada, kadınlarda ise 6. sırada yer aldığı görülmektedir. Türkiye’de yapılan bir çalışmada mide kanseri teşhis konma yaşı ortalama 57 olarak tespit edilmiştir. Bölgelerin karşılaştırılması ile ülkemizin doğu bölgesinde kanser teşhisi konan hastaların sosyoekonomik durumu, batı bölgesine göre daha düşük bulunmuştur. Son 50 yıldaki araştırmalara bakıldığında mide kanseri oluşumu ve kansere bağlı yaşam kaybı oranlarında azalma görülmektedir. Bu azalmanın sebebi; tedavideki gelişmelerden ziyade, yaşam koşullarının iyileştirilmesi ve beslenme açısından düzenli, yeşil sebze ve meyve gibi gıdaların tüketilmesidir [2]. Mide kanserini iki ana başlık altında toplarsak biri çevresel faktörler diğeri ise genetik faktörlerdir. Bunlar içerisinde yaş

* Sorumlu yazar: sesagiroluu@gmail.com . Yazarların ORCID Numarası: ¹ 0000-0001-7319-8597, ² 0000-0001-6472-8306, ³ 0000-0003-0276-8219, ⁴ 0000-0002-8781-8838


ve cinsiyet gibi bazı faktörler arasında kuvvetli ve değiştirilemez bir ilişki vardır. Beslenme şekli, sigara kullanımı, alkol, aile geçmişi gibi bazı etkenler risk faktörünü oluşturmaktadır.

Displazi, ileride kansere dönüşebilme ihtimali olan hücrelerin bozulmasıyla meydana gelir. Displazi'nin 2'li veya 3'lü sınıflandırmaları vardır. Çoğunlukla düşük dereceli ve yüksek dereceli displazi olmak üzere iki kısma ayrılır. Yüksek dereceli displazi, kanserin bir öncesi olarak görülmektedir.

Kanser şüphesi olan doku ışık mikroskobu altında incelenmektedir. Histopatolojik durum dokularda oluşan değişikliklerin çeşitli yöntemler aracılığıyla mikroskopta incelenmesine olanak sağlar. Mide kanserini erken evrede evrede saptayabilmek adına bazı görüntüleme yöntemleri vardır; Baryumlu Garfiler, Endoskopi, Bilgisayarlı Tomografi, Manyetik Rezonans Görüntüleme gibi bilgisayar destekli görüntüleme yöntemleri hasta üzerinde tanı konulması için oldukça önemlidir [3].

Derin öğrenme; makinelerin insan beyni gibi davranan, algılayabilen ve analiz yapabilen popüler makine öğrenmesi yaklaşımlardan biridir. Teknolojinin gelişmesi ve makine kapasitelerinin artmasıyla kullanımı günden güne artmaktadır. Derin öğrenme tıp, yüz tanıma, sürücüsüz araçlar, görüntü analizleri, konuşma, sanal yardımcıları, çeviri, duyu tanıma gibi birçok alanın çözümünde sıkça kullanılmaktadır. Karar destek sistemleri ile hekime yardımcı sistem olarak tıp alanında da kullanımı oldukça yaygındır. Mide displazi tanısı için histopatolojik görüntüler üzerinde önceden eğitilmiş ESA modelleri kullanılarak derin öğrenme algoritması aracılığıyla sınıflandırmaya dayanmaktadır.

Bu çalışmada mide displazisi görüntüleri kullanılarak elde edilen veriler, hasta ve sağlıklı olmak üzere iki etiket sınıfına ayrılmıştır. En iyi sınıflandırıcı performansını veren çok katmanlı algılayıcı (ÇKA) sınıflandırıcısı ile MobileNet derin öğrenme mimarisi kullanılarak elde edilmiştir.



Şekil 1. Mide histopatoloji görüntüleri kullanılarak önerilen karar destek sistemi

Yukarıda yer alan Şekil 1'de, mide displazisine ait histopatolojik görüntüler kullanılarak çalışmaya ait karar destek sistemine yer verilmiştir.

2. Literatür İncelemesi

Literatürde Mide displazi çalışmalarından çok mide kanseri ile ilgili çalışmalara rastlanmaktadır. Yapılan çalışmalarda mide kanseri tanısı için derin öğrenme tabanlı yaklaşımlarla alınan sonuçlar analiz edilmiştir.

Ikenoyama ve ark. ESA'ların erken evre mide kanseri için endoskopistlerle tanısal yeteneklerini karşılaştırdı. Tek atışlı çoklu kutu dedektörüne dayalı bir ESA modelini eğitmek için ilk olarak 2639 mide kanseri lezyonundan 13.584 endoskopik görüntü kullandılar. Daha sonra bu modelin performansı, bir test veri seti kullanılarak 67 endoskopist ile karşılaştırıldı. Bu model ve endoskopistler arasındaki deneysel sonuçların karşılaştırılmasından sonra önerilen ESA modelinin deneyimli endoskopistlerden (%31,9) açıkça daha yüksek bir duyarlılığa (%58,4) sahip olduğu bulundu. Ayrıca bu modelin teşhis süresinin, endoskopistlerinkine kıyasla önemli ölçüde daha kısa olduğu görülmüştür [4].

Hirasawa ve ark. 13.000'den fazla ÖzofagoGastroDuodenoskopi (ÖGD) görüntüsüyle eğitilmiş, derin öğrenmeye dayalı bir tanı sistemi önerdi. Sistem, Single Shot Detector (SSD) adı verilen derin bir sinir ağı mimarisini kullandı. ESA katmanlarına ince ayar yapmak için stokastik bir gradyan iniş stratejisi kullanırken algoritmasını değiştirmede. ESA, 77 mide kanseri lezyonunun 71'ini %92,2 hassasiyetle doğru bir şekilde tanıdı ve 161 kanserli olmayan lezyon mide kanseri olarak tespit etti ve %30,6'lık bir pozitif prediktif değerleri ile

sonuçlandı. Ayrıca çapı 6 mm ve üzeri olan 71 lezyonun 70'i (%98,6) ve tüm kanser hücrelerinin başlangıç yeri olan üst katmanından daha ileri yayılma göstermesi, kesin olarak tespit edilmiştir [5].

Sakai ve ark. kanser ve kanser olmayan iki tür kategorinin ayrıntılı doku bilgisini kullanarak ince ayarlı bir transfer ESA modeli önerdi. Erken mide kanserlerinin yakın yerlerini gösterme, duyarlılık ve özgüllük açısından dengeli bir doğruluk elde etme yeteneğine sahiptir. Deneysel sonuçlar, eğitilmiş modellerinin doğruluğunun, duyarlılığının ve özgüllüğünün sırasıyla %87,6, %80,0, %94,8 olduğunu ve %93,4'lük yüksek bir pozitif prediktif değerleri ile doğru saptamanın mümkün olduğunu böylece kusuru telafi ettiğini gösterdi [6].

2019 yılında Cao ve ark. mide kanserinin saptanmasını gerçekleştirmek ve kanser çekirdeğinin segmentasyonu için maske bölgesi tabanlı bir ESA yöntemi geliştirdi. Model iki bölümden oluşmaktadır. İlk bölümde, tüm görüntü temel ESA tarafından taranarak, ilgi bölgeleri oluşturmak için bölge teklif ağına beslenen özellik haritaları oluşturuldu. Ardından ikinci kısım sınırlayıcı kutular ve maskeler üretti. Sonuçlar, bu yöntemin %61,2'lik bir oranla ortalama kesinlik değerine sahip bir test sonucu elde ettiğini doğruladı [7].

Li ve ark. erken mide kanseri teşhisi için ESA'ya dayalı bir sistem ve olağanüstü bir doğruluk (%90,91), duyarlılık (%91,18) ve özgüllük (%90,64) ile dar bant görüntülemeli, büyüteçli endoskopinin bir kombinasyonunu kullandılar [8].

Shibata ve ark. ayrıca endoskopik görüntülerde mide kanseri lezyonlarını otomatik olarak saptamak ve segmentlere ayırmak için ESA'yı kullanan bir yöntem önerdi. ESA omurgası olarak artık bir ağ ResNet kullandılar; dal maskesi, tamamen evrişimli bir ağın yedi evrişim katmanından oluşmaktadır. Performans değerlendirmesi olarak beş kat çapraz doğrulama kullanıldığında bu modelin duyarlılığı %96,0 olmuştur. Mide kanseri bölgesinin segmentasyonunun değerlendirilmesinde ortalama zar indeksi %71 olarak belirlendi. Önerilen yöntem mide kanserinin saptanması ve gastrointestinal endoskopide kanserli bölgenin analizi için faydalı olmuştur [9].

Zhang ve ark. kronik atrofik gastrit tanı oranını iyileştirmek için DenseNet121 kullanarak, CAG-Net adında bir ESA oluşturdu. Modeli eğitmek ve doğrulamak için beş katlı çapraz doğrulama kullanıldı. 3042 atrofik gastrit görüntüsü ve 2428 normal görüntü kullanıldı. Modelin tanısallığı, duyarlılığı ve özgüllüğü sırasıyla; 0,942, 0,945 ve 0,940 idi. Hafif, orta ve şiddetli atrofik gastrit tespit oranları sırasıyla; %93, %95 ve %99 elde edildi [10].


Shi ve ark. gastrik epitelyal rejenerasyon değişikliğini displaziden ayırt etmek için bir derin öğrenme yöntemi geliştirdi. Endoskopik numunelerin 897 tam slayt görüntüsü üzerinde eğitim, dahili doğrulama ve harici doğrulama gruplarına ayrıldı. Model performansını tahmin etmek için deneylerin doğruluk, duyarlılık, özgüllük pozitif ve negatif prediktif değerleri hesaplanarak ölçülen tanılama performansı %97 bağımsız harici doğrulama kohortunda, model makro ortalama doğruluğu 0,67'den 0,82'ye yükseltti [11].

Yapılan literatür çalışmaları karşılaştırıldığında çalışmamız hem yüksek doğruluk oranı hem de daha gelişmiş modeller kullanarak başarı göstermiştir. Aynı zamanda kendi verilerimizi kullanmamız çalışma için bir artı oluşturmuştur.

3. Materyal Metot

3.1. Materyal

Çalışmada, Elazığ Fethi Sekin Şehir Hastanesi'ne ait patoloji arşivinde bulunan 2019 Ocak ayı ile 2020 Mart ayları arasında kullanılan 2 grup veri kullanılmıştır. 1. grup, değerlendirilen ve "reaktif atipik değişiklikler" olarak raporlanan 492 biyopsi örneklerine ait. 2. grup " mide displazisi" olarak raporlanan 501 mide antrum endoskopik biyopsi örneklerine ait H-E boyalı kesitlerden oluşmaktadır. Her iki gruba ait örnekler en az 4 saat boyunca nötr tamponlu %10 formalin içinde sabitlenmiş, %70 etanolde yıkanmış, standart yöntemlerle işlenmiş, parafine gömülmüş, 5 um'lik kesitler halinde kesilerek, hematoksilin ve eozin ile boyanmıştır. H-E boyalı kesitler gastropatoloji alanında deneyimli uzman patolog tarafından ışık mikroskobu ile taranarak Olympus DP26 kamera sistemi ile dijital ortama aktarılmıştır. Toplam 993 görüntü elde edilmiştir.



Şekil 2. Reaktif Atipik ve Mide Displazisine ait örnek görüntüler

Yukarı da yer alan Şekil 2’ de her iki gruba ait (a) reaktif atipik değişiklikler (b) mide displazisi olarak raporlanan biyopsi örneklerine ait görüntüler yer almaktadır.


3.2. Metot

Son zamanlarda görüntü sınıflandırması için derin öğrenme teknikleri kullanılmaktadır. ESA; evrişim katmanı, havuzlama ve tamamen bağlı katmandan oluşan çok katmanlı bir sinir ağıdır. Evrişim katmanı, giriş verileri üzerinde evrişim işlemi gerçekleştiren ESA'nın temel yapısıdır. Evrişim, iki matris, yani alıcı alan ve çekirdek arasındaki bir iç çarpım işlemi temsil etmektedir. Genel olarak çekirdek uzamsal olarak giriş verilerinden daha küçüktür. Çekirdek alıcı alan üzerinde kaymakta ve giriş verilerinin bir özellik haritasını oluşturmaktadır. Havuzlama katmanının buradaki görevi, özellik haritasının uzamsal boyutunu düşürmektir. Bir dizi çıktıyı yakındaki özellik değerlerinin istatistiklerine göre tek bir değerle değiştirmektedir. En yaygın kullanılan havuzlama tekniği maksimum havuzlamadır. Bir dizi özelliği maksimum değeriyle değiştirmektedir. Tamamen bağlı katman, tüm nöronların birbirini takip eden her katman nöronuna bağlı olduğu çok katmanlı bir algılayıcıdır. Bu katman, özellikleri çıktıya haritalamak için tercih edilmektedir [12].

Bu çalışmada histopatolojik görüntülerden elde edilen, önceden eğitilmiş ESA mimarileri ile mide displazisi tespiti gerçekleştirilecektir. Mide displazi durumunu tahmin edebilmek için VGG16, VGG19, MobileNet, NasNet ve ResNet ESA mimarilerden faydalanılmaktadır. Aşağıda kullanılan mimariler açıklanmaktadır.

3.2.1. VGG-16

VGG-16, basit bir ağ modeli olup öncesindeki modellerden en önemli farkı evrişim katmanlarının 2’li ya da 3’lü olarak kullanılmasıdır. Tam bağlantı (FC) katmanında $7 \times 7 \times 512 = 4096$ nöronlu bir öznitelik vektörüne dönüştürülür. İki FC katmanı çıkışında 1000 sınıflı softmax başarımı hesaplanır ve milyonlarca parametre hesabı yapabilmektedir. Diğer modellerde olduğu gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken kanal sayısı artmaktadır [13]. Yapılan bu çalışmada VGG-16’nın katmanlı mimarisi kullanılarak model eğitimi yapılmıştır. Kullanılan mimarinin yapısı aşağıdaki şekildeki Şekil 3’te gösterilmiştir.



Şekil 3. VGG-16 katman yapısı

3.2.2. VGG-19

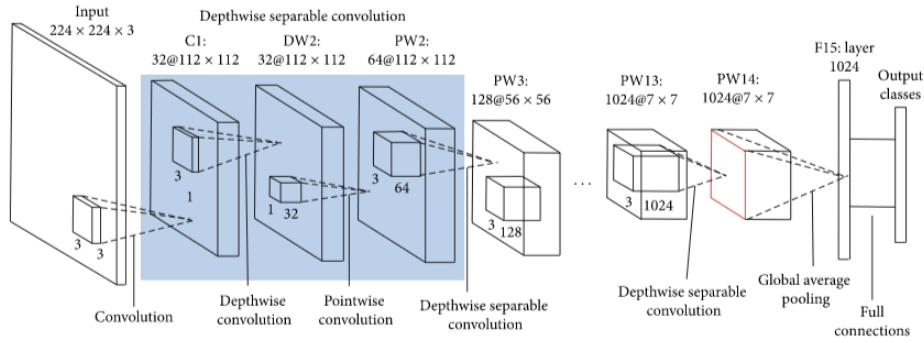
VGG19, ILSVRC 2014 yarışmasında ikinci olan topluluk tarafından VGGNet olarak adlandırılıyor. Simonyan ve Zisserman tarafından geliştirildi. VGG 19, 5 ortaklama katmanı ve 3 tam bağlı katmanda sona eren 16 evrişim katmanından meydana gelmektedir. ReLU, aktivasyon fonksiyonlarıyla tanımlı bir derin öğrenme modelidir. Modelde bilgi çok önemli değere sahiptir çünkü ESA'da maksimum ortaklama katmanı kullanılıp, önceki katmanın çok sayıda piksel değeri işlemden atılır ve sadece en yüksek değeri tutulur [13].

3.2.3. ResNet

ResNet, daha önceki mimarilerden daha derin bir yapısı olan ve 152 katmandan oluşan bir mimaridir. ImageNet yarışmasında 2015 yılında çok düşük hata oranı elde ederek kazanan olmuştur. Bu oran, insan hata oranını geçerek büyük bir başarı anlamına gelmektedir. Mimariyi oluşturan Residual bloklarda, x girişi konvolüsyon-ReLU konvolüsyon serisinden sonra bir $F(x)$ sonucu üretmektedir. ResNet'in evrişimsel sinir ağlarıyla birlikte görüntü işleme ve görüntü tanıma gibi birçok soruna yüksek teknolojik çözümler sunmuştur [14].

3.2.4. MobileNet

MobileNet, mobil vizyon uygulamaları için basit ama verimli ve hesaplama açısından da çok yoğun olmayan evrişimli sinir ağıdır. MobileNet; nesne algılama, ince taneli sınıflandırmalar, yüz nitelikleri ve yerelleştirmeyi içeren birçok gerçek dünya uygulamasında yaygın olarak kullanılmaktadır. Modelde amaç, parametre ve hesaplama sayısını azaltırken aynı zamanda performansını mümkün olduğunca korumaktır [15]. Aşağıda MobileNet'in yapısı, Şekil 4'te gösterildiği gibi derinlemesine ayrılabilir filtrelere dayanmaktadır.



Şekil 4. MobileNet ağ yapısı [16]

3.2.5. NasNet


NASNet, eğitilecek veri kümesi için evrişimsel sinir ağı mimarisinin eğitim işlemi sırasında oluşturulmasını sağlar. Temel olarak filtre boyutu, çıkış kanalları, katman sayısı vb. parametrelerin en iyi birleşimini aramaktadır.

Her arama işleminden sonraki ödül, veri seti üzerinde aranan mimarinin doğruluğuna göre hesaplanmaktadır. NASNet'te genel mimari önceden tanımlanmış olsa da hücreler önceden tanımlanmamıştır. NASNet ağındaki bulunan hücreler normal hücre ve indirgeme hücresidir. Normal hücreler, aynı boyutta bir özellik haritası döndüren evrişimli hücrelerdir. Azaltma hücreleri, özellik haritası yüksekliği ve genişliğinin iki kat azaltıldığı bir özellik haritası döndüren evrişimli hücrelerdir [17].

Çalışmada VGG16, VGG19, ResNet, MobileNet ve NasNet modelleri kullanılarak yapılan özellik çıkarma sonucu elde edilen özellikler, DVM, KNN ve ÇKA sınıflandırıcıları kullanılarak üç ayrı sınıfa ayrılmıştır.

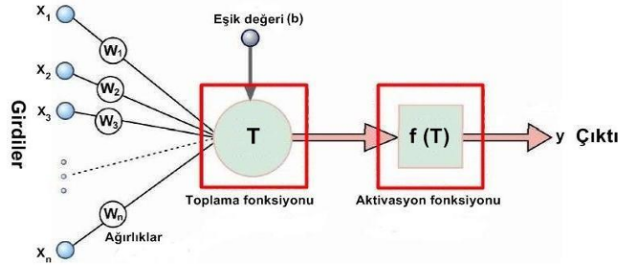
3.2.6. Çok Katmanlı Algılayıcı

ÇKA, Evrişimsel Sinir Ağları'na olan ilgiyi hızlı bir şekilde arttırarak yaygın bir kullanım alanına sahiptir. ÇKA'nın ortaya çıkışı XOR problemini çözmek amacıyla ortaya çıkmıştır. Aşağıda yer alan Şekil 5'te ÇKA modelinin giriş, ara ve çıkış katman yapısı gösterilmiştir.



Şekil 5. ÇKA yapısı

ÇKA; girdi katmanı, gizli katman ve çıkış katmanı olmak üzere en az 3 katmandan oluşmaktadır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin ESA'ya tanıtılmasını sağlamaktadır. Çıktı katmanı ağ içerisinde işlenen bilginin dışarıya iletiildiği katmandır. Eğitimde kullanılan hataları geriye doğru azaltmaya çalışan ve öğrenen hata yayma modelini ortaya koymaktadır. Öğrenme algoritmaları içinde en çok geriye yayılım algoritması tercih edilmektedir. ÇKA ağları danışmalı öğrenme stratejileri kapsamında eğitim sırasında hem girdiler hem de girdilere karşılık ağırlık üretmesi gereken çıktılar ağına tanıtılmaktadır. Girdi-gizli, gizli-çıkış katmanı ve ağırlıklar ilk önce rastgele seçilmektedir. Giriş sinyalleri, ileri yönde katmandan katmana yayılmaktadır. Eğitim sırasında ağırlık ürettiği çıktılar ile beklenen çıktılar arasındaki fark ağırlık ağırlıklarına dağıtılmakta ve zaman içinde bu farkın en aza indirgenmesi amaçlanmaktadır. Çıktının, istenen nöron cevabından farklı olması durumunda hatalar ileri besleme aktarım işlevinin türeviyle aynı bağlantılar aracılığı ile geriye doğru yayılmakta ve ağırlıklarla değiştirilmektedir. Bilgi akışı, ileri beslemeli modellerde olduğu gibi ileri yönde sağlanırken geri beslemeli ağlarda öğrenme işlemi çift yönlü hafıza işleme sürecine dayanmaktadır [18].



Şekil 6. Aktivasyon fonksiyonu [18].

Yukarıda Şekil 6'da yer alan modelde aktivasyon fonksiyonu olarak herhangi bir matematiksel fonksiyon kullanılabilir. Temel olarak giriş değerleri, w ağırlıkları temsil eder ve ağırlık çıkışına aktarılan değere aktivasyon işlemi uygulanmış olur.

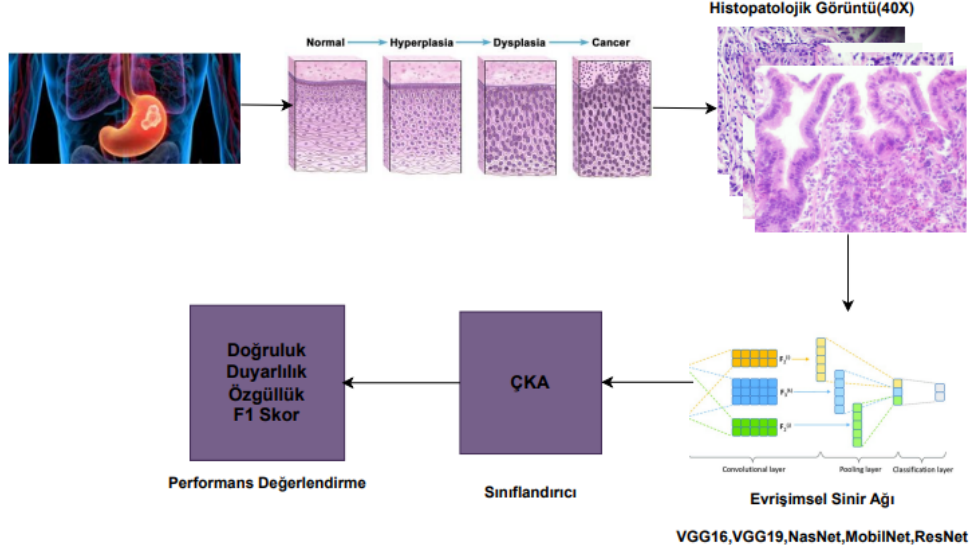
4. Uygulama

Bu bölümde kullanılan veri özellikleri, uygulamada kullanılan yöntem, ölçüm değerleri ve performans değerlendirme metriklerinden bahsedilmektedir. Son aşamada çalışmanın uygulama sonuçlarına yer verilmiştir.

4.1. Uygulama Çalışmaları

Görüntüler, 40X büyütülmüş histopatolojik dokular üzerinde işlemler gerçekleştirilmiştir. Bu çalışmada, 492 sağlıklı ve 501 hastadan alınan toplam 993 histopatolojik görüntüler üzerinden, veri iki etiket sınıfına ayrılmıştır. Modelin eğitimi için Python programlama dili kullanıldı. Modeli tanımlamak ve eğitmek için keras ve numpy derin öğrenme kütüphanelerinden faydalanıldı. Eğitim tur sayısı (epoch) deneysel çalışmalar sonucunda 43,45 ve 46 olarak belirlenerek model eğitimleri yapıldı. ÇKA sınıflandırıcısı için 46 epoch kullanıldı. Epoch sayısı arttıkça modelin başarımının da arttığı görüldü. Aktivasyon değeri için Rectified Linear Unit (ReLU) fonksiyonu kullanıldı. Görüntü boyutu 244*224*3 olacak şekilde boyutlandırılmıştır. Görüntüler, numpy matrisi içerisine alınmıştır, 0 veya 1 olarak etiketleme işlemi yapılmıştır. Sınıflandırma aşamasında kullanılan ESA mimarileri,

matrisde yer alan pixel değerleri üzerinde işlemlerini yürütmektedir. Çalışma için toplamda 993 displazi görüntüsünün, %30 test ve %70 eğitim için kullanılmıştır. Bu çalışma için gerçekleştirilen yöntem yapılandırılmasına Şekil 7’de yer verilmiştir.



Şekil 7. Derin öğrenme yöntemleri ile mide displazilerinin histopatolojik görüntü üzerinden tespiti için akış diyagramı

Derin öğrenme modellerinin iyi performans göstermesi ve eğitilmesi için büyük veri setleri gereklidir. Bununla birlikte, biyomedikal alanındaki en büyük zorluklardan biri, uzman tarafından etiketlenmiş klinik veri eksikliğidir. Küçük veri kümeleri kullanarak derin öğrenme modellerini eğitmek için, büyük bir veri kümesinde geliştirilen ağırlığın mevcut modele aktarılması yakın zamanda uygulanan yaygın bir tekniktir. Bir ESA, verileri analiz etmek için denetimli öğrenme birimi algoritması olan algılayıcıları kullanan özellikli bir yapay sinir ağı türüdür.

4.2. Performans Metrikleri

Makine öğrenmesi, derin öğrenme vb. algoritmaları değerlendirip tahmin sonuçları çıkartabilmek adına farklı performans metrikleri kullanılır. Modelin etkinliğini değerlendirmek ve karşılaştırmak için kullanılan kritik araçlardır. Bu metrikler sayesinde model performansı için ön görülebilir bir değerlendirme yapmamıza olanak sağlar. Karmaşıklık matrisi, sınıflandırma modellerinin performansını değerlendirmek için kullanılan bir tablodur. Gerçek ve tahmin edilen sınıfların dört farklı durumunu içerir: doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif. Bu matris, modelin doğru ve yanlış tahminlerini göstererek hataları analiz etmeyi sağlar [19].

		Gerçek Sınıf Değeri	
		Pozitif	Negatif
Tahmin Değeri	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 8. Karışıklık matrisi ve performans değerlendirme metrikleri

Karmaşıklık matrisinde gerçek sınıf değeri ile tahmin değerlerinin performans ölçütü hesaplamaları yapılmıştır. Karmaşıklık matrisi Şekil 8'deki gibi verilmiştir. Kullanılan performans metriklerine ait ifadeler eşitlik (1) – (3) ile ulaşılabilir:

- TP (True Positive – Doğru Pozitif): Gerçekte doğruyken doğru olarak tahmin edilmesi
- FN (False Negative – Yanlış Negatif): Gerçekte doğruyken yanlış olarak tahmin edilmesi
- FP (False Positive – Yanlış Pozitif): Gerçekte yanlışken doğru olarak tahmin edilmesi
- TN (True Negative – Doğru Negatif): Gerçekte yanlışken yanlış olarak tahmin edilmesi

$$\text{Doğruluk (Accuracy): } (TN + TP) / \text{TOPLAM} \quad (1)$$

$$\text{Duyarlılık / Doğru Pozitif Oranı (True Positive Rate – Sensivity): } TP / (TP+FP) \quad (2)$$

$$\text{Seçicilik / Özgüllük (True Negative Rate – Specifity): } TN / (TN+FP) \quad (3)$$

4.3. Uygulama Sonuçları

Bu çalışmada, Mide displazi ayırt etmek için hibrit bir ESA-Sınıflandırıcı modeli önerilmiştir. Yöntem, önceden eğitilmiş ESA modellerinden görüntülerin sağlam hiyerarşik özelliklerini elde etmeye ve bunları makine öğrenmesi algoritması aracılığıyla sınıflandırmaya dayanmaktadır. Bu modelde ESA, girdi verilerinden öznelik çıkarımı gerçekleştirirken, sınıflandırıcı ayıklanan öznelikleri sınıflandırır. Önceden eğitilmiş ESA modellerinin son havuzlama katmanından sonra softmax katmanı yerine DVM, KNN ve ÇKA kullanıldı. Önerilen model, önceden eğitilmiş ESA modellerine kıyasla daha iyi performans göstermektedir. Tablo 1'de ÇKA sınıflandırıcısından elde edilen sınıflandırma performans sonuçlarını göstermektedir.

Tablo 1 analiz edildiğinde, MobileNet ile çıkarılan özelliklerin ÇKA kullanılarak daha yüksek doğrulukla sınıflandırdığı görülmektedir. Kullanılan 5 ESA model ile elde edilen özellikler ÇKA sınıflandırıcısı ile sınıflandırıldığında en yüksek doğruluk, hassasiyet ve özgüllük ve f1 değerine ÇKA sınıflandırıcısı ile MobileNet modeli (%91,95 Doğruluk(Acc), %91,01 Duyarlılık(Sen), %92,72 Özgüllük(Spe), %91,01 F1 Skor) ulaşmıştır. Şekil 8'de MobileNet - ÇKA kullanarak elde edilen sonuçlara ait karmaşıklık matrisini göstermektedir.

Gerçek Sınıf Değeri	Normal	40.70 %	4.02 %
	Displazi	4.02 %	51.26 %
		Normal	Displazi
		Tahmin Değeri	

Şekil 9. ÇKA sınıflandırıcısı ile sınıflandırılmış MobileNet modelinin karmaşıklık matrisi

Şekil 9'da modelin görüntüler üzerinde gerçekleştirmiş olduğu tahminler değerleri ve gerçek sınıf değeri yüzdeleri yer almaktadır. Tablo 1'de en yüksek sınıflandırıcı ve model sonuçlarına yer verilmiştir.

Tablo 1. ÇKA sınıflandırıcısından elde edilen sonuçlar


Sınıflandırıcı	Model	Doğruluk(%)	Duyarlılık(%)	Özgüllük(%)	F1 Skor(%)
ÇKA	VGG16	86,43	81,44	91,17	85,40
	VGG19	84,92	88,18	80,89	86,60
	ResNet50	70,85	70,52	71,15	69,79
	MobileNet	91,95	91,01	92,72	91,01
	NasNet	89,44	87,50	91,57	89,65

Tablo 2’de KNN ve DVM sınıflandırıcılarının en yüksek performans gösteren MobileNet ve NasNet modellerinin sonuçlarına yer verilmiştir.

Tablo 2. KNN ve DVM sınıflandırıcısından elde edilen sonuçlar

Sınıflandırıcı	Model	Doğruluk(%)	Duyarlılık(%)	Özgüllük(%)	F1 Skor(%)
KNN	MobileNet	84,42	83,50	85,29	83,93
DVM	NasNet	89,44	91,01	88,18	88,52

Şekil 10’da, ÇKA sınıflandırıcısı ile sınıflandırılmış VGG16, VGG19, MobileNet, NasNet, ResNet50 modellerinin doğruluk, duyarlılık, özgüllük ve F1 sonuç grafiği aşağıda verilmiştir.



Şekil 10. Doğruluk, Duyarlılık, Özgüllük, F1 skor metriklerine ait sınıflandırma sonuç grafiği

5. Sonuç

Bu çalışmada, mide displazisi tanısı için histopatolojik görüntüler üzerinde çalışılmış, ESA yardımıyla hastalığın tespiti amaçlanmıştır. Mide kanseri diğer kanser türlerine oranla görülme sıklığı olarak ilk sıralarda yer alıp, tespit edilme açısından da oldukça zorluk çekilen bir kanser türü olarak bilinmektedir. Zorluk çekilmesinin nedenlerinden biri belirtilerin başka hastalıklarla karıştırılmasıdır. Bu durum da hastalığın erken evrede tespitini zorlaştırmaktadır. Bu yüzden mide displazinin tanı ve tedavisi için erken dönemde teşhis büyük önem taşımaktadır. Bu çalışmada mide displazisinin tespiti için derin öğrenme ve ESA teknikleri kullanılarak hastalığın erken evrede tespiti amaçlanmaktadır.

Yapılan analizlerde kullanılan veri görüntüleri üzerinde en başarılı derin öğrenme modeli MobileNet ile birlikte eğitilen ÇKA sınıflandırıcısından (%91,95 Doğruluk (Accuracy), %91,01 Duyarlılık (Sensitivity), %92,72 Özgüllük (Specificity), %91,01 F₁ Skor) elde edilmiştir. Derin öğrenme yöntemleri sayesinde erken dönemde mide displazisi tanısı konulabileceğini göstermiştir. Yapılan çalışma klinik ortamda hekime yardımcı olacak ve ileriki çalışmalara ışık tutacaktır.

Çalışma veri sayısı açısından büyük klinik veriler ile çalıştırılmıştır. Ancak modelin doğruluğunu yükseltebilmek için daha çok veriyle daha iyi sonuçlar alınabileceği düşünülmektedir. Önerilen ESA modeli ile eğitimler tekrar gerçekleştirilebilir. Bu doğrultuda elde edilen deneysel sonuçlar, mevcut çalışmada elde edilen sonuçlarla karşılaştırılabilir.

Kaynaklar

- [1] Buran, T., & Şahin, M. (2020). Mide Kanseri'nde Erken Tanı Hayat Kurtarır. *Celal Bayar Üniversitesi Sağlık Bilimleri Enstitüsü Dergisi*, 7(4), 567-570.
- [2] Alacalı, M. (2012). Mide kanseri, mide kanseri taramaları ve mide kanserinden korunma. *Ankara Medical Journal*, 12(4), 195-198. Haupt RL, Haupt SE. *Practical Genetic Algorithms*. 2nd ed. New York, NY, USA: Wiley, 2004.
- [3] Sarı, R. Mide Kanseri Tanı ve Tedavi Planlamasında Görüntüleme Yöntemlerinin Yeri, *Gastrointestinal Sistem Kanserlerinin Cerrahisi*, (2020), 67-68.
- [4] Ikenoyama Y, Hirasawa T, Ishioka M, Namikawa K, Yoshimizu S, Horiuchi Y, & Tada T. (2021). Detecting early gastric cancer: Comparison between the diagnostic ability of convolutional neural networks and endoscopists. *Digestive Endoscopy*, 33(1), 141-150.
- [5] Hirasawa T, Aoyama K, Tanimoto T, Ishihara S, Shichijo S, Ozawa T, & Tada T. (2018). Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images. *Gastric Cancer*, 21(4), 653-660.
- [6] Sakai Y, Takemoto S, Hori K, Nishimura M, Ikematsu H, Yano T, & Yokota H. (2018, Temmuz). Aktarıcı bir evrişimsel sinir ağı kullanarak endoskopik görüntülerde erken mide kanserinin otomatik tespiti. 2018 yılında 40. Yıllık Uluslararası IEEE Mühendislik ve Tıp ve Biyoloji Topluluğu Konferansı (EMBC) (s. 4138-4141). IEEE.
- [7] Pang X, Zhao Z, & Weng Y. (2021). The role and impact of deep learning methods in computer-aided diagnosis using gastrointestinal endoscopy. *Diagnostics*, 11(4), 694.
- [8] Li, L, Chen Y, Shen Z, Zhang X, Sang J, Ding Y, & Yu C. (2020). Convolutional neural network for the diagnosis of early gastric cancer based on magnifying narrow band imaging. *Gastric Cancer*, 23(1), 126-132.
- [9] Shibata, T, Teramoto A, Yamada H, Ohmiya N., Saito K., & Fujita, H. (2020). Automated detection and segmentation of early gastric cancer from endoscopic images using mask R-CNN. *Applied Sciences*, 10(11), 3842
- [10] Zhang, X., Hu, W., Chen, F., Liu, J., Yang, Y., Wang, L., ... & Si, J. (2017). Gastric precancerous diseases classification using CNN with a concise model. *PloS one*, 12(9), e0185508.
- [11] Shi, Z, Zhu, C, Zhang, Y. et al. Deep learning for automatic diagnosis of gastric dysplasia using whole-slide histopathology images in endoscopic specimens. *Gastric Cancer* 25, 751–760 (2022).
- [12] Das S. «medium,» 2017. Available: medium.com/analytics-vidhya/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5.
- [13] <https://medium.com/analytics-vidhya/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5>, Erişim Tarihi : 2023, Konu: CNN Architectures
- [14] Yan, Z, Liu, H, Li, T, Li, J, & Wang, Y. (2022). Two dimensional correlation spectroscopy combined with ResNet: Efficient method to identify bolete species compared to traditional machine learning. *LWT*, 162, 113490
- [15] <https://medium.com/@godeep48/an-overview-on-mobilenet-an-efficient-mobile-vision-cnn-f301141db94d>. Erişim Tarihi:2023.
- [16] Wang W, Li Y, Zou T, Wang X, You J, Luo Y. "Dense-MobileNet Modelleri Üzerinden Yeni Bir Görüntü Sınıflandırma Yaklaşımı", *Mobil Bilgi Sistemleri*, cilt. 2020, Makale Kimliği 7602384, 8 sayfa, 2020
- [17] Şafak, E, and Barışçı, N. (2022). Hafif Evrişimsel Sinir Ağları Kullanılarak Sahte Yüz Görüntülerinin Tespiti. *El-Cezeri*, 9(4), 1282-1289.
- [18] Metin, N, Karadağ, K, and Terzioğlu, M. K. (2020). MLP/RBF Ağ Mimarileriyle Hibrit MGARCH-ANN Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 78-93.
- [19] Durmuş, M, Ergen, B, Çelebi, A, and Türkoğlu, M. (2023). Panoramik Diş Görüntülerinde Derin Evrişimsel Sinir Ağına Dayalı Gömülü Diş Tespiti ve Segmentasyonu. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 38(3), 713-724.