



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Öznitelik Çıkarım Yöntemleri Kullanılarak Akciğer Tomografi Görüntülerinde Covid-19 Sınıflandırılması

Pelin GÖRGEL^a, Nurşah DİNCER^{b*}

^a Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, İstanbul Üniversitesi-Cerrahpaşa, İstanbul, TÜRKİYE

^b Bilgisayar Teknolojileri Bölümü, Trabzon Meslek Yüksekokulu, Karadeniz Teknik Üniversitesi, Trabzon, TÜRKİYE

* Corresponding author's e-mail address: mustafaayildiz@duzce.edu.tr
DOI: 10.29130/dubited.1282669

ÖZ

Covid-19 (Coronavirus Hastalığı 2019), yeni bir solunum yolu hastalığıdır ve ilk görülme yeri Çin'in Wuhan şehri olmuştur. Hastalık çok hızlı bir şekilde dünyanın birçok ülkesine yayılarak çok fazla insan ölümüne neden olmuştur. Bu sebeple de pandemi olarak duyurulmuştur [1]. Bulaşıcılık yönü yüksek olan Covid-19'un yaygın görülen belirtilerinin başında ateş, kuru öksürük, yorgunluk, kas ağrısı ve nefes darlığı gelmektedir [2]. Hastalığın salgın şeklinde olması sebebiyle hastalığın erken teşhisi büyük önem taşımaktadır. Hastalığın hızlı ve doğru teşhisi amacıyla doktorlar için yardımcı araçlar kullanmak oldukça fayda sağlamaktadır. Diğer akciğer hastalıklarında olduğu gibi Covid-19'un teşhisinde de tıbbi görüntüleme teknikleri sıklıkla kullanılmaktadır. Pandemi döneminde Covid-19 tespitinde X-ray ve bilgisayarlı tomografi görüntüleme teknikleri önemli birer yardımcı haline gelmiştir. Bu çalışmada hastalıklı ve sağlıklı akciğer tomografi görüntülerine görüntü işleme ve yapay zekâ teknikleri uygulanarak farklı öznitelikler çıkarılmış ve Covid-19 teşhisi amacıyla sınıflandırma yapılmıştır.

Anahtar Kelimeler: Görüntü işleme, Covid-19, yapay zekâ, bilgisayarlı tomografi, zernike moment, destek vektör makinesi

Classification of Covid-19 Using Different Feature Extraction Methods

ABSTRACT

Covid-19 (Coronavirus Disease 2019) is a new respiratory disease and the first place of occurrence was the city of Wuhan, China. The disease spread very quickly to many countries of the world, causing many deaths. For this reason, it has been announced as a pandemic [1]. The most common symptoms of Covid-19, which is highly contagious, are fever, dry cough, fatigue, muscle pain and shortness of breath [2]. Due to the epidemic form of the disease, early diagnosis of the disease is of great importance. It is very beneficial for doctors to use auxiliary tools for the rapid and accurate diagnosis of the disease. As in other lung diseases, medical imaging techniques are frequently used in the diagnosis of Covid-19. During the pandemic period, X-ray and computed tomography imaging techniques have become important aids in detecting Covid-19. In this study, different features were extracted by applying image processing and artificial intelligence techniques to diseased and healthy lung tomography images, and classification was made for the purpose of Covid-19 diagnosis.

Keywords: image processing, Covid-19, artificial intelligence, computed tomography, zernike moment, support vector machine

I. GİRİŞ

Covid-19 başlangıç noktası olan Çin'de dahil olmak üzere dünya çapında milyonlarca ölüme sebep olmuş ciddi bir akciğer hastalığıdır. Bulaşıcılığının yüksek olması bu hastalığı salgın boyutuna getirmiştir. Diğer ciddi rahatsızlıklarda olduğu gibi Covid-19'u tespit etmede de görüntüleme tekniklerinin kullanımının önemi büyüktür. Hastalığın görüldüğü akciğer bölgesinden alınan görüntüler virüsün varlığının ve bulunduğu bölgelerin tespitinde oldukça fayda sağlamaktadır [3]. Yapılan bu çalışmada da akciğerden elde edilen bilgisayarlı tomografi (BT) görüntüleri kullanılarak görüntüleri Covid-19 ve Normal şeklinde sınıflandırabilmek amaçlanmıştır. Benzer amaçlarla akciğer görüntüleri kullanarak yapılan çalışmalara da ayrıca bu bölümde yer verilmiştir.

Litaretürde hastalık tespiti için akciğer görüntülerini kullanarak yapılmış çalışmalar bulunmaktadır. Afify ve ark., koronavirüs olmayan görüntüleri tespit etmek amacıyla bir bilgisayar destekli tanı (CAD) sistemi önermiştir. Araştırmada kullanılan veri seti, 200 görüntüden oluşmakta olup, bu görüntülerin %90'ı eğitim amacıyla kullanılmış ve geri kalan %10'u ise test için ayrılmıştır. Önerdikleri sistem, virüs yaygınlığını düzenlemek için beş aşama içeren bir yapıya sahiptir. İlk aşamada, görüntüler eşikleme tabanlı akciğer segmentasyonu yaparak ön işleme sürecinden geçirilmiştir. Sonraki aşamada, segmentasyondan elde edilen sonuç görüntülerine, genetik algoritma kullanılarak altmış dört farklı özneliğin belirlenmesi için öznelik çıkarma tekniği uygulanmıştır. Bu şekilde, üstün özellikleri tanımlamak amaçlanmıştır. Son olarak, K-en Yakın Komşu (K Nearest Neighbor - KNN) ve Karar Ağacı (Decision Tree - DT) yöntemleri Covid-19 sınıflandırması için kullanılmıştır. $K = 3$ değeri ile KNN sınıflandırıcısı BT görüntülere uygulandığında %100, karar ağacı yöntemiyle de %95 doğruluk oranına ulaşmıştır [4].

Challab ve Mardukhi, Covid-19 tanısında kullanılmak üzere Uzun Kısa Süreli Bellek (LSTM) adı verilen bir derin öğrenme algoritmasıyla Destek Vektör Makineleri (SVM) gibi farklı makine öğrenimi metodolojilerini birleştiren bir algılama sistemi geliştirmişlerdir. Çalışmada, merkezi momentler, Gabor Dalgacıları ve GLCM gibi çeşitli ortak görüntü öznelikleri üzerinde tartışmalar yapılmıştır. SVM parametrelerinin optimum alt kümelerini seçme işlemi, Karınca Kolonisi Optimizasyonu (Ant Colony Optimization) ve Karınca Aslan Optimizasyonu (Ant Lion Optimization) yöntemleri ile gerçekleştirilmiş ve F1 skor %85.67, kesinlik %84.27, hassaslık %87.38, özgüllük %87.38 ve doğruluk %90.18 değerlerine ulaşılmıştır [5].

Hasan ve ark., Covid-19 vakalarını tespit etmek amacıyla iki farklı model tanıtmışlardır: Tek Makine Öğrenimi (Single Machine Learning - SML) ve 10 kat çapraz doğrulama (10-fold cross validation) ile Toplu Makine Öğrenimi (Ensemble Machine Learning - EML) modeli. İlk sınıflandırma modeli olan SML, DT (Decision Tree), Yapay Sinir Ağları (Artificial Neural Network - ANN) ve SVM (Support Vector Machine) gibi farklı algoritmalarla gerçekleştirildi ve %98.85 doğruluk oranıyla SVM diğer sınıflandırılara göre daha iyi bir performansa sahip olduğunu kanıtladı. İkinci sınıflandırma modeli olan EML, RF (Random Forest), Oylama (Voting) ve Torbalama (Bagging) gibi çeşitli algoritmalarla uygulandı. Özellikle Torbalama sınıflandırıcısının kullanılmasıyla doğruluk oranı %99.60'a kadar arttırıldı. Diğer çalışmalarla kıyaslandığında, önerilen bu iki modelin sonuçları daha üstün bir performans sergilediği gözlemlendi. Önerilen iki model kendi arasında karşılaştırıldığında ise, EML'nin performans açısından SML'den daha iyi olduğu tespit edilmiştir [6].

Osman ve ark., Yerellik Ağırlıklı Öğrenme (Locality-Weighted Learning - LWL) ve Öz Düzenleyici Haritalar (Self Organizing Maps - SOM) stratejilerine dayanan yeni bir Covid-19 tanımlama tekniği önermişlerdir. Bu amaçla, öncelikle göğüs röntgeni veri kümelerinden alınan görüntülere, benzer özelliklerine göre farklı kümelerde gruplandırılmak üzere SOM stratejisi uygulanmıştır. Sonrasında, LWL algoritmasına dayalı akıllı öğrenme modeli Covid-19 vakalarını teşhis ve tespit etmek amacıyla geliştirilmiştir. Önerilen modelin %97.88 doğruluk oranıyla başarılı sonuçlar elde edildiği gözlemlenmiştir [7].

Saygılı, Covid-19 hastalarına ait BT görüntülerinin segmentasyonunu gerçekleştiren ve segmentasyondan elde edilen görüntüler aracılığıyla virüsün otomatik olarak tespit edilmesini sağlayan bir yöntem önermiştir. Bu çalışma, üç temel adım olan ön işleme (preprocessing), segmentasyon (segmentation) ve sınıflandırma (classification) adımlarını içeren bir yapıya sahiptir. Ön işleme aşamasında, görüntü yeniden boyutlandırma (image resizing), görüntü keskinleştirme (image sharpening), gürültü giderme (noise removal), kontrast esnetme (contrast stretching) gibi işlemler gerçekleştirilmiştir. Görüntülerin bölütlenme aşamasında ise görüntülere Beklenti-Maksimizasyon (Expectation-Maximization) tabanlı Gauss Karışım Modeli (Gaussian Mixture Model) uygulanmıştır. Covid-19 pozitif ve negatif olarak sınıflandırmak için Çekirdek Destek Vektör Makineleri (Kernel Support Vector Machines) yöntemi ile birlikte K-en Yakın Komşu (KNN), Karar Ağacı (DT) ve iki farklı topluluk (ensemble) yöntemi kullanılmıştır. Önerilen yöntem, kamuya açık olan iki farklı BT veri seti ve bu veri setlerinin birleştirilmesiyle oluşturulan karma bir veri seti üzerinde gerçekleştirilmiştir. Veri kümesi-1, veri kümesi-2 ve karışık veri kümesi için elde edilen doğruluk değerleri sırasıyla %98.5, %86.3 ve %94.5 olarak kaydedilmiştir [8].

Ismaela ve Şengür, göğüs X-ray görüntüleri ile Covid-19'u sınıflandırmak amacıyla üç derin öğrenme yaklaşımı dikkate alınmıştır. Önceden eğitilmiş derin ağlardan derin özellik çıkarımı, önceden eğitilmiş bir CNN modelinin ince ayarı ve bir CNN modelinin uçtan uca eğitim bahsedilen bu üç modeldir. ResNet18, ResNet50, ResNet101, VGG16 ve VGG19 modelleri de hem derin özellik çıkarımı hem de ince ayar prosedürleri için kullanılmıştır. Derin özelliklerin eğitilmesi amacıyla SVM sınıflandırıcısı Doğrusal, Karesel, Kübik ve Gaussian gibi çekirdek fonksiyonları ile birlikte gerçekleştirilmiştir. Katman sayısı 21 olan yeni bir CNN modeli önerilmiş ve uçtan uca eğitilmiştir. Bu yeni model bir giriş katmanı, beş evrişim katmanı, beş RELU katmanı ve beş toplu normalizasyon katmanından oluşturulmuştur. Birinci ve ikinci RELU katmanlarından sonra iki adet havuzlama katmanı, modelin sonunda da tam bağlantılı katman, softmax katmanı ve sınıflandırma katmanı kullanılmıştır. Elde edilen sonuçlara bakıldığında ResNet50 modelinden ve Doğrusal çekirdek fonksiyonuna sahip SVM sınıflandırıcısından çıkarılan derin özellikler kullanılarak en yüksek %94.7 doğruluk elde edilmiştir. Bu sonuçları ince ayarlı ResNet50 modeli ile %92.6 ve geliştirilen CNN modelinin uçtan uca eğitim ile %91.6 takip etmiştir. Performans karşılaştırılması amacıyla SVM sınıflandırmaları ve çeşitli yerel doku tanımlayıcıları kullanılmıştır. Tüm sonuçlar değerlendirildiğinde derin yaklaşımların daha etkili olduğu görülmüştür [9].

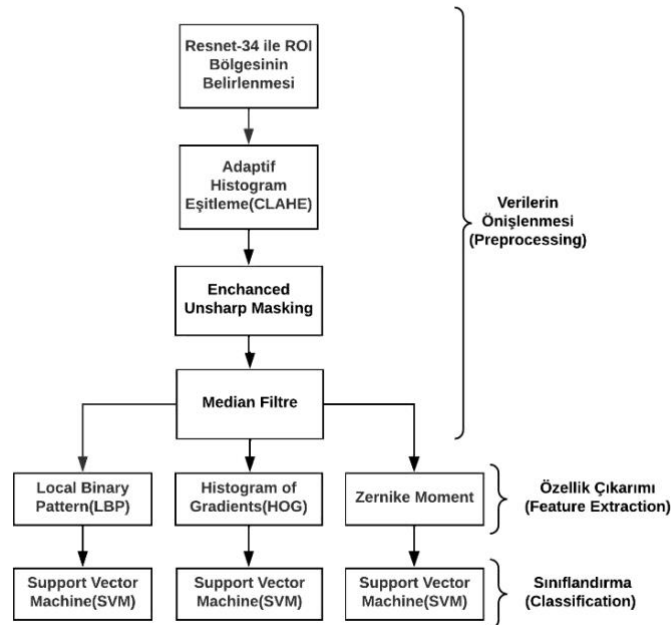
Hasoon ve ark., X-ray görüntüleri ile Covid-19 sınıflandırması için bir yöntem önermişlerdir. Çalışma; ön işleme, İlgi Alanı (ROI) tespiti ve segmentasyonu, özellik çıkarımı ve sınıflandırma aşamalarından oluşmuştur. Ön işleme aşamasında görüntü üzerindeki gürültülerin giderilmesi, görüntü eşikleme ve morfolojik işlemler gerçekleştirilmiştir. İlgi alanı tespiti ve segmentasyonu için Orta nokta elips çizim algoritması (Midpoint ellipse drawing algorithm) uygulanmıştır. Özellik çıkarımı amacıyla Yerel ikili model (LBP), Gradyan Histogramı (HOG) ve Haraclick doku özellikleri, son aşama olan sınıflandırma aşamasında ise K-En Yakın Komşu (KNN) ve Destek Vektör Makinesi (SVM) yöntemleri kullanılmıştır. LBP-KNN, HOG-KNN, Haralick-KNN, LBP-SVM, HOG-SVM ve Haralick-SVM olan altı model kombinasyonu görüntüler üzerinde denenmiştir. Modellerin sonuçlarına bakıldığında LBP-KNN modelinin ortalama %98.66 doğruluk (accuracy), %97.76 duyarlılık (sensitivity), %100 özgüllük (specificity) ve %100 kesinlik (precision) değerleriyle diğer modellere göre daha iyi performans gösterdiği tespit edilmiştir [10].

Oğuz ve Yağanoğlu, BT görüntüleri ile Covid-19 sınıflandırma sistemi tasarlamışlardır. Bu sebeple ilk olarak; ResNet-50, ResNet-101, AlexNet, Vgg-16, Vgg-19, GoogLeNet, SqueezeNet, Xception gibi yöntemler kullanılarak görüntülerin özellikleri çıkarılmıştır. Elde edilen bu özellikler Destek Vektör Makinesi (SVM), k En Yakın Komşu (kNN), Rastgele Orman (RF), Karar Ağaçları (DT), Naive Bayes (NB) gibi sınıflandırma yöntemlerine verilerek görüntüler üzerindeki performans sonuçları elde edilmiştir. Elde edilen sonuçlar doğruluk değeri, F1 skoru ve ROC eğrisi başarı kriterlerine göre değerlendirilmiştir. Bahsedilen başarı kriterlerine göre %96.296 doğruluk (accuracy), %95.868 F1 puanı (F1 score) ve AUC değeri 0.9821 değerleriyle en iyi sonuçlar ResNet-50 ve SVM yöntemiyle elde edilmiştir [11].

Verma ve ark., röntgen görüntülerini Covid-19 ve normal olarak sınıflandırabilecek bir model tasarlamışlardır. Modelde VGG16 evrişim ağı kullanılmış ve bu ağın son katmanına Destek Vektör Makinesi (SVM) içerecek şekilde oluşturulmuştur. VGG16 ve SVM arasında bir evrişim, havuz ve yoğun katmanı senkronizasyon amacıyla eklenmiştir. Radyal Temel fonksiyonu da en iyi sonucu bulmak amacıyla kullanılmıştır. Tasarlanan CovXmlc isimli model literatürde mevcut bulunan VGG16, VGG19, RestNet50, InceptionV3, DenseNet121 olmak üzere beş farklı modelle de karşılaştırılmıştır. CovXmlc modelinden bu karşılaştırmalar sonucunda %95 doğruluk (accuracy), %95 geri çağırma (recall), %96 özgüllük (specificity), %95 F1-puanı (F1-score), %96 kesinlik (precision) değerleri elde edilmiş ve diğer yöntemlere göre en iyi performansı gösterdiği gözlemlenmiştir [12].

Barstuğan ve ark., Covid-19 sınıflandırması için BT veri seti kullanarak iki aşamalı bir sınıflandırma modeli oluşturmuşlardır. Bu aşamalardan ilkinde görüntülerden dört farklı alt kümeye herhangi bir özellik çıkarma işlemine tabi tutulmadan Destek Vektör Makinesi (SVM) ile sınıflandırılmıştır. Diğer bir aşama olan ikincisinde ise, öznelikleri çıkarmak için görüntülere Gri Seviye Eş Oluş Matrisi (GLCM), Yerel Yönlü Desenler (LDP), Gri Seviye Çalışma Uzunluğu Matrisi (GLRLM), Gri Seviye Boyut Bölge Matrisi (GLSZM) ve Ayrık Dalgacık Dönüşümü (DWT) yöntemleri uygulandı ve elde edilen öznelikler SVM ile sınıflandırıldı. Sınıflandırma yapılırken 2 kat, 5 kat ve 10 kat şeklinde farklı çapraz doğrulamalar uygulandı. Elde edilen sonuçlara göre en iyi performansa 10 kat çapraz doğrulama ile %99.68 doğruluğa (accuracy) ulaştıran GLSZM öznelik çıkarma yöntemi ile ulaşıldı [13].

Bu çalışmada akciğer BT görüntülerini Covid-19 ve normal olarak sınıflandırabilen bir model önerilmektedir. Bu model, ön-işleme, öznelik çıkarımı ve sınıflandırma olmak üzere üç aşamadan oluşmaktadır. İlk aşama olan ön-işleme aşamasında öncelikle akciğer görüntülerindeki lezyon bölgelerinin bulunduğu ilgili bölge dışındaki kısımların elenmesi için Resnet-34 kullanılmıştır. Daha sonra görüntüler üzerine Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) uygulanarak histogram iyileştirilmesi yapılmıştır. Keskinliği Azaltan Maskeleye (Unsharp Masking) yöntemi iyileştirilerek farklı bir versiyonu histogramı eşitlenen görüntülere uygulanmıştır. Son ön-işleme adımı olarak görüntüler ortanca filtre (median filter) uygulamasına tabi tutulmuştur. Öznelik çıkarımı aşamasında Zernike Moment, Yönlendirilmiş Gradyenlerin Histogramı (HOG) ve Yerel İkili Desen (LBP) yöntemleri sınıflandırma sonuçlarını karşılaştırılmak üzere ayrı ayrı veri setine uygulanmıştır. Son olarak da bu üç yöntemden elde edilen sonuçlar SVM kullanılarak sınıflandırma işlemine tabi tutulmuştur. Şekil 1'deki akış diyagramında, bahsedilen aşamalar gösterilmektedir.



Şekil 1. Önerilen Modelin Akış Diyagramı.


Uygulanan yöntemlerin detaylarına makalenin Metot kısmında değinilmiştir. Yöntemlerden elde edilen sonuçlar da Bulgular kısmında yer almaktadır.

II. MATERYAL VE METOT

A. MATERYAL

Bu çalışmada popüler veri tabanı Kaggle’ın Covid-19 bilgisayarlı tomografi veri tabanından elde edilen akciğer görüntüleri kullanılmıştır [14]. Veri seti, Covid-19 ve sağlıklı (normal) insanlara ait BT görüntüleri olmak üzere iki farklı sınıfa ait görüntülerden oluşmaktadır. Bu veri setinden 50 adet Covid-19 ve 50 adet normal görüntüden oluşan 100 akciğer (lung) BT görüntüsü üzerinde uygulama gerçekleştirilmiştir.

Şekil 2’de kullanılan veri setine ait görüntü örnekleri gösterilmektedir.



Şekil 2. Veri setinden örnek görüntüler (a) Covid-19 (b) Normal.

Covid-19’a sahip bir akciğer BT görüntüsünü hastalığa sahip olmayan bir görüntüden ayıran en belirgin özellikler;

- Buzlu cam görüntüsü,
- Birden fazla yerde tutulum olabilmesi,
- Periferik yani akciğer kenarlarına doğru görülmesi,
- Çoğunlukla alt lob denilen posterior bölgesinde bulunmasıdır.

B. METOT


B. 1. Derin Artık Sinir Ağı

ResNet, 2016 yılında He ve arkadaşları tarafından geliştirilen bir model olup, Derin Artık Ağ (Deep Residual Network) olarak da bilinir [15]. Bu model, derin öğrenme eğitimindeki zorlukları aşmak için tasarlanmıştır. Çünkü derin öğrenme eğitimi genellikle uzun süren bir süreçtir ve belirli bir katman

sayısıyla sınırlıdır. ResNet'in mimarisi derinleştikçe performansının düşmemesi diğer mimari modellerle kıyaslandığında bu modelin avantajıdır. Bunun yanı sıra, ResNet modeli hesaplama işlemlerini daha kolay hale getirir ve ağırları daha iyi eğitime yeteneğine sahiptir. ResNet modeli, içerisinde ReLU ve toplu normalizasyon (batch normalization) bulunan iki veya üç katmanlı atlayarak bağlantılarını gerçekleştirir. He ve arkadaşları, ResNet modelinde birden fazla katman için artık öğrenme (residual learning) yöntemini kullanmaktadır. ResNet'teki artık bloğun tanımı, Denklem 1'de gösterilmektedir [16]:

$$y = F(x, W + x) \quad (1)$$

Burada x giriş katmanıdır; y çıktı katmanıdır ve F fonksiyonu artık harita (residual map) ile temsil edilmektedir. Eğer girdi verisinin boyutları çıktı verisi boyutlarıyla aynı ise, ResNet üzerinde artık blok gerçekleştirilebilir [16]. Şekil 3'te bahsedilen artık blok yapısı gösterilmektedir [17].




Şekil 3. Artık Blok Yapısı [17].

ResNet blokları, iki (ResNet-18 ve ResNet-34 ağırları için) ya da üç katmandan (ResNet-50 ve ResNet-101 ağırları için) oluşmaktadır. ResNet mimarisinin ilk iki katmanı, 7×7 evrişim ve adım sayısı 227 olan 3×3 boyutunda maksimum havuzlama (max-pooling) yaparak GoogleNet'e benzemektedir [16].

ResNet-34'in yapısı, 33 evrişimli (convolutional) katman, 3×3 boyutunda bir max-pooling katmanı, bir ortalama havuz katmanı (average pool layer) ve bir tam bağlı katmandan (fully connected layer) oluşmaktadır. Klasik bir ResNet-34 modeli 63,5 milyon parametre içerir, burada "Temel-Blok (Basic-Block)" bloğundaki tüm evrişim katmanlarının arkasına doğrultma doğrusal olmayanlık (rectification nonlinearity-ReLU) aktivasyonu ve toplu normalleştirme (batch normalization) uygulanır ve son katmanda softmax fonksiyonu uygulanır [18].

Şekil 4'te Resnet-34 yönteminin görüntülere uygulanmasının sonuçları gösterilmektedir.

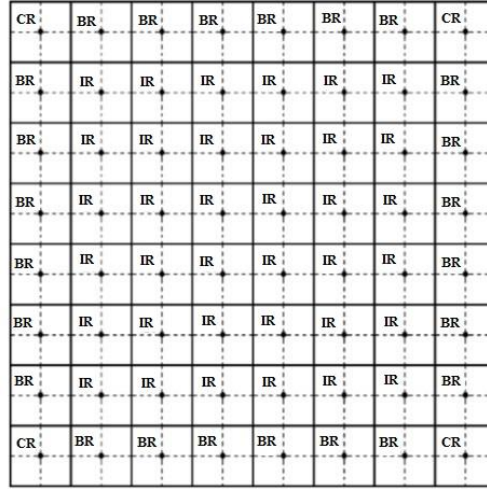


Şekil 4. Resnet-34 Yönteminden Elde Edilen Sonuçlar (a) Covid-19 (b) Normal.

B. 2. Kontrast Sınırlı Adaptif Histogram Eşitleme


Kontrast sınırlı adaptif histogram eşitleme (CLAHE), hemen hemen eşit büyüklükte, birbiriyle örtüşmeyen birkaç bölgeye görüntüyü bölmeye dayalı olarak formüle edilmiştir. 512×512 görüntüde, iyi bir istatistiksel tahmin elde etmek için, görüntü her yönde 8'e eşit olarak bölünerek bölge sayısı genellikle 64'e eşit olacak şekilde seçilir. Böyle bir bölünmenin bir örneği, Şekil 5'te gösterilmektedir. Bu bölünme, üç farklı bölge grubuyla sonuçlanır. Yalnızca dört bölgeden oluşan bir grup, köşe bölgeleri (CR) sınıfıdır. 24 bölgeden oluşan ikinci grup ise yatılı bölgeler (BR) sınıfıdır. Köşe bölgeleri hariç, resim tahtasındaki tüm bölgeler bu sınıfa aittir. Kalan 36 bölgenin tümünü içeren son grup, iç bölgeler sınıfı (IR) olarak adlandırılır. Bu yaklaşımda öncelikle her bölgenin histogramı hesaplanır [19].

Sonrasında, istenilen bir sınıra bağlı olarak kontrast genişletme amacıyla histogramların kırılması için bir kırma sınırı seçilir. Sonraki adımda, her histograma, yüksekliği kırma sınırını aşmayacak şekilde yeni değerler atanır ve gri tonlamalı haritalama için elde edilen kontrast sınırlı histogramların kümülatif dağılım fonksiyonları (CDF) hesaplanır. Bu yöntemde her bir pikselin kendi en yakın komşuluğunda bulunan dört bölgenin haritalanmasından elde edilen sonuçlar birleştirilerek haritalanır. IR, CR ve BR grubundaki bölgeler için bazı formülasyonlara göre bu değerlendirmeler gerçekleştirilir [19].



Şekil 5. 512×512 boyutlara sahip bir görüntünün 64 eşit bölgeye ayrılmış görünümü [19].

Şekil 6'da CLAHE algoritmasının uygulanması sonucu elde edilen sonuçlar gösterilmektedir.



Şekil 6. CLAHE Algoritmasından Elde Edilen Sonuçlar (a) Covid-19 (b) Normal.

B. 3. İyileştirilmiş Keskinliği Azaltan Maskeleye

Keskinliği azaltan maskeleye (Unsharp Masking - UM), görüntünün bulanık bir versiyonunun görüntünün kendisinden çıkarıldığı görüntüleri keskinleştirme tekniğidir.

Formülü şu şekildedir: $K(x, y) = I(x, y) + (I(x, y) - G(x, y)) \times \alpha$

Önce bir görüntüyü bulanıklaştırabilir ve ardından keskin olmayan maskeleye uygulamak için orijinal ve bulanık görüntü arasındaki fark olarak ayrıntı görüntüsü hesaplanmaktadır [20].¹

Keskinleştirilmiş görüntü, orijinal görüntü $I(x, y)$ ile detaylı görüntü $D(x, y)$ 'nin doğrusal bir kombinasyonu olarak hesaplanabilir. Denklem 2 ve 3'te UM yönteminin denkleştirilmiş hali aşamalar şeklinde gösterilmektedir.

$$I(x, y) - G(x, y) = D(x, y) \quad (2)$$

$$I(x, y) + \alpha \times D(x, y) = K(x, y) \quad (3)$$

$I(x, y)$: orijinal görüntü.

$G(x, y)$: gauss filtre ile yumuşatılmış görüntü.

$D(x, y)$: detaylı görüntü.

$K(x, y)$: keskinleştirilmiş görüntü.

Bu yönteme ek işlem uygulanarak UM yöntemi değiştirilmiştir. Yöntemler aşağıdaki sırayla veri setindeki görüntülere uygulanmıştır. Denklem 4, 5 ve 6'da UM yönteminden yola çıkılarak elde edilen iyileştirilmiş UM yönteminin hali aşamaları gösterilmektedir.

$$I(x, y) - G(x, y) = D(x, y) \quad (4)$$

$$I(x, y) - \alpha \times D(x, y) = F(x, y) \quad (5)$$


$$I(x, y) + \text{Gauss}(F(x, y)) = E(x, y) \quad (6)$$

$F(x, y)$: Fark görüntüsü.

$E(x, y)$: İyileştirilmiş görüntü.

¹ https://scikit-image.org/docs/stable/auto_examples/filters/plot_unsharp_mask.html, [Ziyaret tarihi: 12.12.2022].

Şekil 7’de iyileştirilmiş unsharp masking algoritmasının uygulanması sonucu elde edilen sonuçlar gösterilmektedir.



Şekil 7. İyileştirilmiş Unsharp Masking Algoritmasından Elde Edilen Sonuçlar (a) Covid-19 (b) Normal.

B. 4. Ortanca (Medyan) Filtresi

Bilinen en iyi sıralama istatistikleri filtresi (order statistics filter), bir pikselin değerini o pikselin çevresindeki gri seviyelerin ortalamasıyla değiştirerek çalışan medyan filtredir. Medyanın hesaplanması sırasında pikselin orijinal değeri de dahil edilerek işlenir. Medyan filtreler oldukça popülerdir, çünkü belirli rasgele gürültü türleri için benzer boyuttaki doğrusal yumuşatma filtrelerinden çok daha az bulanıklıkla mükemmel gürültü azaltma yetenekleri sağlarlar [21].


$$y(i, j) = med\{x(a, b), (a, b) \in v\} \quad (7)$$

Denklem 7 ile medyan filtre matematiksel olarak ifade edilmektedir.

v : Maske boyutuna bağlı olan komşuluk pikselleri.

Denklemdaki komşuluk piksellerini belirleyen maske boyutu kullanıcı tarafından ayarlanmaktadır. Filtrenin çalışma prensibine bakıldığında, işlenecek pikselin komşuluğunda bulunan piksellerin yoğunluk değerleri küçükten büyüğe olacak şekilde sıralanır ve ortanca değer işlenen pikselin yeni yoğunluk değeri haline getirilir. Medyan filtre kullanılarak yapılan filtreleme işlemlerinde hem gürültü azaltılır hem de görüntü üzerindeki detaylar korunur [22].

Şekil 8’de medyan filtrenin uygulanması sonucu elde edilen sonuçlar gösterilmektedir.



Şekil 8. Medyan Filtresinden Elde Edilen Sonuçlar (a) Covid-19 (b) Normal.

B. 5. Zernike Moment

Görüntülere öznitelik çıkarımı için ilk olarak Zernike Moment yöntemi uygulanmıştır. Zernike momentleri, Zernike polinomlarının görüntü üzerine izdüşümü alınarak elde edilir. Zernike polinomları da birim disk üzerinde ortogonal olan bir polinomlar dizisi olarak hesaplanmaktadır. Zernike momentleri hesabı Denklem 8’de gösterilmektedir [23].

$$Z_{mn} = \frac{m+1}{\pi} \int_{\theta=0}^{2\pi} \int_{\rho=0}^1 P_{mn}^*(\rho, \theta) I(\rho, \theta) \rho d\rho d\theta, |\rho| \leq 1 \quad (8)$$

$I(\rho, \theta)$: Gri seviyeye sahip görüntü.

$P_{mn}(\rho, \theta)$: Zernike polinomları.

m : Moment derecesi.

n : Tekrarlanma sayısı.

$P_{mn}(\rho, \theta)$ olarak ifade edilen Zernike polinomları Denklem 9’daki gibi elde edilebilir [23]. $G_{mn}(\rho)$ gerçel değerli radyal polinomları göstermektedir.

$$P_{mn}(\rho, \theta) = G_{mn}(\rho) e^{-jn\theta} \quad (9)$$

B. 6. Yönlendirilmiş Gradyan Histogramı

Zernike moment yönteminden sonra görüntülere bu yöntem yerine Yönlendirilmiş Gradyan Histogramı (Histogram of Oriented Gradients-HOG) yöntemi ayrıca uygulanmıştır.

HOG özellikleri, gradyan açısına ve büyüklük dağılımlarına dayalıdır ve görsel verilerde, ortam aydınlatmasındaki ve renk varyasyonlarındaki hafif değişikliklere karşı gradyanın doğal değişmezliği nedeniyle sağlamdırlar. I görüntüsünü, $f_x = [-1,0,1]$ ve $f_y = [-1,0,1]^T$ gradyan tahmini filtrelerini ele alınırsa, h_x ve h_y Denklem 10 ve Denklem 11’de gösterildiği gibi gradyan görüntüleri temsil edilebilir [24].

$$h_x = I * f_x \quad (10)$$

$$h_y = I * f_y \quad (11)$$

Burada * evrişimi (convolution) temsil eder. Gradyanın büyüklüğü her pikselde Denklem 12’deki gibi hesaplanabilir [24]:

$$H(i, j) = h_x(i, j)^2 + h_y(i, j)^2 \quad (12)$$

ve her pikseldeki baskın gradyan açısı Denklem 13’deki gibi tahmin edilebilir [19]:

$$\theta(i, j) = \tan^{-1} \left(\frac{h_y(i, j)}{h_x(i, j)} \right) \quad (13)$$

HOG özellikleri daha sonra tamamen her pikseldeki gradyan büyüklüğü H ve gradyan açıları θ temelinde üretilebilir. HOG öznelik çıkarımı tarafından sağlanan birincil içgörü, bireysel $H(i, j)$ ve $\theta(i, j)$ 'nin oldukça değişken olmasına ve çok benzer görüntüler için bile yakın (i, j) konumlar arasında önemli farklılıklara tabi olmasına rağmen, benzer görüntülerdeki küçük bölgeler üzerindeki gradyan açılarının ve büyüklüklerinin uzamsal dağılımının toplu istatistikleri, bu bölgelerin oldukça sağlam tanımlayıcılarını sağlar [24].

B. 7. Yerel İkili Desen

HOG yönteminden sonra görüntülere bu yöntem yerine Yerel İkili Desenler (Local Binary Pattern-LBP) yöntemi ayrıca uygulanmıştır. Gri tonlamalı değişmez bir doku ölçüsü olarak tanımlanan LBP (Local Binary Patterns), yerel bir komşuluktaki genel doku tanımından türetilir ve doku görüntülerinin modellemesi için kullanışlıdır. Bir görüntünün piksellerini etiketlemek için orijinal LBP operatörü, her pikselin merkezi pikselin değeriyle eşiklenmiş 3×3 komşuluğunu kullanır ve sonuçları iki terimli olarak birleştirerek bir sayı elde eder.

Temel LBP için eşikleme fonksiyonu $f(.,.)$ resmi olarak Denklem 14 ile temsil edilebilir [25]:

$$f(I(Z_0), I(Z_i)) = \begin{cases} 0, & \text{eğer } I(Z_i) - I(Z_0) \leq \text{eşik değeri} \\ 1, & \text{eğer } I(Z_i) - I(Z_0) > \text{eşik değeri} \end{cases}, i = 1, 2, \dots, 8 \quad (14)$$

Z_1	Z_2	Z_3
Z_8	Z_0	Z_4
Z_7	Z_6	Z_5

Şekil 9. Z_0 etrafındaki 8 komşuluk örneği [25].

Burada $Z_i, i = 1, \dots, 8$ Şekil 9'da gösterildiği gibi 8 komşuluk bir Z_0 noktasıdır.

Bir mikro model olarak adlandırılan bir LBP ikili gradyan yönlerinin birleştirilmesi olarak da kabul edilebilir. LBP yöntemi, hesaplaması kolay öznelik çıkarma işlemi ve basit eşleştirme stratejisi sayesinde çok verimli olup, istatistiksel öğrenme yöntemlerinden farklı olarak birçok parametreyi ayarlamayı gerektirmez [25].

B. 8. Destek Vektör Makineleri

Üç ayrı yöntemle öznelikleri çıkarılan görüntüler, her yöntemden sonra Destek Vektör Makineleri (SVM) ile sınıflandırılmıştır. SVM, ikili sınıflandırma için Vapnik tarafından geliştirilmiştir [26]. Amacı, $x \in R^m$ özelliklerine sahip belirli bir veri kümesindeki iki sınıfı ayırmak için en uygun $h(w, x) = w \cdot x + a$ hiperdüzlemini bulmaktır. SVM, bir optimizasyon problemini çözerek w parametrelerini öğrenir (Denklem 15) [27].

$$\min \frac{1}{p} w^T w + C \sum_{i=1}^p \max(0, 1 - y'_i(w^T x_i + a)) \quad (15)$$

Burada $w^T w$ Manhattan normudur (L1 normu olarak da bilinir), C ceza parametresidir (rasgele bir deęer veya hiper parametre ayarı kullanılarak seilen bir deęer olabilir), y' gerek etikettir ve $w^T x + a$, tahmin fonksiyonudur. Denklem 15, standart destek kaybı (hinge loss) ile L1-SVM olarak bilinir. Türevlenebilir muadili L2-SVM (Denklem 16), daha kararlı sonuçlar sağlar [27].

$$\min \frac{1}{p} \|w\|_2^2 + C \sum_{i=1}^p \max(0, 1 - y'_i(w^T x_i + a))^2 \quad (16)$$

burada $\|w\|_2$, dönüm noktası kaybının (hinge loss) karesi alınmış Öklid normudur (L2 normu olarak da bilinir) [27].

III. ARAŞTIRMA BULGULARI

Yapılan alıřmada akcięer BT görüntüleri kullanılarak bu görüntüleri Covid-19 ya da Normal olarak sınıflandırabilecek bir model tasarlanmıştır. Bu amaçla oluşturulan model 50 Covid-19 ve 50 Normal görüntüden oluşan bir veri seti kullanılarak test edilmiştir. Görüntülere ön-iřleme, öznelik çıkarımı ve sınıflandırma aşamaları altında yöntemler uygulanmıştır.

Ön iřleme aşamasında bulunan yöntemlerden ilki olan Resnet34, önceki alıřmalara bakıldığında daha çok sınıflandırma amacıyla kullanılmış bir yöntemdir. Bu alıřmada literatüre bir katkı olarak da sunduđumuz bu yöntemin akcięer ROI bölgesini ıkarma aşamasında kullanılmasıdır. CLAHE yöntemi ise histogram eşitleme için geçerlilięi kanıtlanmış bir yöntem olması sebebiyle veri setine uygulanması faydalı görülmüřtür. Literatürde keskinlięi azaltan maskeleye olarak geen yöntem ise görüntüler üzerinde iyileřtirme yapacak řekilde deęiřikliğe uğratarak farklı bir yöntem olarak görüntülere uygulanmıştır. Ön iřleme safhasının son iřlemi olan Ortanca filtre ise CLAHE gibi yetkinlięi kanıtlanmış ve gereksiz detayları ortadan kaldırma konusunda başarılı bir yöntem olması sebebiyle görüntülere uygulanması gerekli görülmüřtür. Öznelik ıkarma amacıyla kullanılan LBP ve HOG yöntemleri bu alanda yapılmış dięer alıřmalarda başarılı kabul edilebilecek yöntemlerdendir. Bu sebeple veri setine uygulanmıştır. Yine aynı aşamada kullanılan Zernike Moment yöntemi ise bu alanda kullanımına pek fazla yer verilmemiş bir yöntemdir. Zernike Moment gibi bu alanda uygulanmamış bir yöntem ile LBP ve HOG gibi daha sık kullanılan iki yöntemin SVM ile sınıflandırma sonuçlarına olan etkisi karşılařtırılmak istenmiştir. SVM ile sınıflandırma yapılırken veri setinin %20'si test verisi olarak belirlenmiştir.

Makalede incelenen alanda yapılan daha önceki alıřmaların sonuçları deęerlendirme metrikleri açısından deęerlendirildiğinde doęruluđun (accuracy) başarıyı temsil etmek konusunda yeterli gelmedięi görülmüřtür. alıřmaların birçoğunda karşımıza doęruluk (accuracy) metrięinin yanı sıra hassasiyet (precision), geri aęırma (recall) ve F1-skor (F1-score) çıkmaktadır. Bu sebeple yöntemleri deęerlendirme kriteri olarak bu dört metrik seilmiştir ve sonuçlar bu metriklere göre karşılařtırılmıştır. Bu deęerlendirme yöntemlerinin formülleri sırasıyla Denklem 17, 18, 19 ve 20'de gösterilmiştir.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

$$Precision = \frac{TP}{TP + FP} \quad (18)$$

$$Recall = \frac{TP}{TP + FN} \quad (19)$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (20)$$

Gerçek Pozitif (True Positive-TP), hem tahminin hem de gerçek olanın pozitif olduğu bir duruma benzetilir. Gerçek Negatif (True Negative - TN) durumu, hem tahminin hem de gerçekte olanın negatif olduğu bir durumu ifade eder. Yanlış Pozitif (False Positive-FP), bir şeyin pozitif olarak tahmin edildiği ancak yanlış olan bir durumdur. Yanlış Negatif (False Negative-FN) ise, negatif olarak tahmin edilip gerçekte pozitif olan durumdur. F1-skoru, hassasiyet (precision) ve geri çağırma (recall) değerlerinin harmonik ortalamasını temsil eder [28].

Üç farklı öznitelik çıkarımı yöntemlerinin sınıflandırma sonuçlarının bahsedilen değerlendirme kriterlerine göre elde edilen değerleri Tablo 1’de gösterilmektedir.

Tablo 1. Sınıflandırma sonuçları

Yöntemler	Doğruluk (Accuracy)	Hassasiyet (Precision)	Geri Çağırma (Recall)	F1-skor (F1-score)
Zernike+SVM	0.85	0.82	0.90	0.86
LBP+SVM	0.85	0.89	0.80	0.84
HOG+SVM	0.70	0.64	0.90	0.75

Elde edilen sonuçlara göre Zernike moment yöntemi ile % 85, LBP ile % 85 ve HOG ile % 70 doğruluk değerine ulaşılmıştır. Tablo 1’de gösterilen bu sonuçlara göre öznitelik çıkarımı yöntemlerinden Zernike moment ve LBP yöntemleri sonrasında SVM ile yapılan sınıflandırmalardan daha başarılı sonuçlar elde edildiği tespit edilmiştir.

IV. SONUÇ

Çalışmada akciğer BT görüntüleri üzerinden Covid-19 hastalığına sahip görüntüleri normal görüntülerden ayıran ve ikili bir sınıflandırma yapabilen bir model tasarlanması hedeflenmiştir. Bu hedefe yönelik olarak da bazı ön işleme yöntemleri ile görüntülerin sadece hastalıklı bölgelerini belirlemeye çalışılmıştır.

Ön-işleme aşamasında Resnet34, CLAHE, iyileştirilmiş keskinliği azaltan maskeleyme ve Ortanca filtre yöntemleri ile görüntüler üzerinde iyileştirme ve hastalığın tespiti için gerekli olmayan bölgeden

arındırma işlemleri gerçekleştirilmiştir. Öznitelik çıkarımı aşamasında Zernike moment, LBP ve HOG olmak üzere üç farklı yöntem ayrı ayrı uygulanmıştır. Uygulanan bu öznitelik çıkarımı yöntemlerinin her birinden sonra SVM yöntemi ile sınıflandırma yapıp sonuçlar karşılaştırılmıştır. Zernike Moment yönteminin diğer iki öznitelik çıkarım yöntemine göre sınıflandırma başarısına olan etkisi daha büyük olmuştur. Yapılan bu karşılaştırma öznitelik çıkarımının sınıflandırmaya olan etkisinin önemini göstermiştir.

Sonuçlar değerlendirildiğinde ve literatürdeki diğer çalışmalar incelendiğinde kullanılan yöntemler yanı sıra derin modellerin geliştirilmesi ve uygulanması düşünülmektedir. Derin modeller tasarlanarak bu çalışmadan elde edilen sonuçlarla karşılaştırılmasının yapılması hedeflenmektedir. Gelecekteki çalışmalarda veri setinin genişletilmesinin ardından öznitelik çıkarım yöntemleri üzerinde durularak Covid-19 ve Normal olmak üzere ikili sınıflandırma yapabilen tek bir model tasarlanması düşünülmektedir.

V. KAYNAKLAR

- [1] M. Çöl ve G. Güneş, “COVID-19 Salgınına Genel Bir Bakış”, *Covid-19*. Ankara, Türkiye: Ankara Üniversitesi Basımevi, 2020, böl. 1, ss. 1-9. [Çevrimiçi]. Erişim: <http://www.medicine.ankara.edu.tr/wp-content/uploads/sites/121/2020/05/COVID-19-Kitap.pdf>.
- [2] A. Gürün Kaya ve A. Kaya, “Klinik Yaklaşım: Solunum Sistemi”, *Covid-19*. Ankara, Türkiye: Ankara Üniversitesi Basımevi, 2020, böl. 7, ss. 49-55. [Çevrimiçi]. Erişim: <http://www.medicine.ankara.edu.tr/wp-content/uploads/sites/121/2020/05/COVID-19-Kitap.pdf>.
- [3] Ç. Uzun, “Görüntülemenin Yeri ve Radyolojik Bulgular”, *Covid-19*. Ankara, Türkiye: , Ankara Üniversitesi Basımevi, 2020, böl. 5, ss. 35-43. [Çevrimiçi]. Erişim: <http://www.medicine.ankara.edu.tr/wp-content/uploads/sites/121/2020/05/COVID-19-Kitap.pdf>.
- [4] H. M. Afify, K. K. Mohammed and A. E. Hassanien, “An Automated CAD System of CT Chest Images for COVID-19 Based on Genetic Algorithm and K-Nearest Neighbor Classifier”, *International Information and Engineering Technology Association*, vol. 25, no.5, pp. 589-594, 2020.
- [5] J. M. Challab and F. Mardukhi, “A Hybrid Method Based on LSTM and Optimized SVM for Diagnosis of Novel Coronavirus (COVID-19)”, *International Information and Engineering Technology Association*, vol. 38, no. 4, pp. 1061-1069, 2021.
- [6] A. M. Hasan, H. M. Abd El-Kader and A. Hossam, “An Intelligent Detection System for Covid-19 Diagnosis using CT-Images”, *Journal of Engineering Sciences Assiut University Faculty of Engineering*, vol. 49, no. 4, pp. 476–508, 2021.
- [7] A. H. Osman, H. M. Aljahdali, S. M. Altarrazi and A. Ahmed, “SOM-LWL method for identification of COVID-19 on chest X-rays”, *Plos One*, vol. 16, no. 2, 2021.

- [8] A. Saygılı, “Computer-Aided Detection of COVID-19 from CT Images Based on Gaussian Mixture Model and Kernel Support Vector Machines Classifier”, *Arabian Journal for Science and Engineering*, vol. 47, no. 2, pp. 2435–2453, 2021.
- [9] A. M. Ismaela and A. Şengür, “Deep learning approaches for COVID-19 detection based on chest X-ray images”, *Expert Systems With Applications*, vol. 164, 2021.
- [10] J. N. Hasoon, A. H. Fadel, R. S. Hameed, S. A. Mostafa, B. A. Khalaf, M. A. Mohammed and J. Nedoma, “COVID-19 anomaly detection and classification method based on supervised machine learning of chest X-ray images”, *Results in Physics*, vol. 31, 2021.
- [11] Ç. Oğuz, M. Yağanoğlu, “Detection of COVID-19 using deep learning techniques and classification methods”, *Information Processing & Management*, vol. 59, no. 5, 2022.
- [12] S. S. Vermaa, A. Prasadb and A. Kumar, “CovXmlc: High performance COVID-19 detection on X-ray images using Multi-Model classification”, *Biomedical Signal Processing and Control*, vol. 71, 2022.
- [13] M. Barstuğan, Umut Özkaya ve Şaban Öztürk, “Coronavirus (COVID-19) Classification using CT Images by Machine Learning Methods”, *4th International Conference on Recent Trends and Applications in Computer Science and Information Technology*, 2021, pp. 29-35.
- [14] H. Gunraj. [Online]. Available: https://www.kaggle.com/hgunraj/covidxct?select=2A_images.
- [15] K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Image Recognition”, *IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770-778.
- [16] D. Sarwinda, R. H. Paradisa, A. Bustamama and P. Anggia, “Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer”, *5th International Conference on Computer Science and Computational Intelligence*, 2021, pp. 423–431.
- [17] H. Zhang, J. Mo, H. Jiang, Z. Li, W. Hu, C. Zhang, Y. Wang, X. Wang, C. Liu, B. Zhao, J. Zhang and K. Zhang, “Deep Learning Model for the Automated Detection and Histopathological Prediction of Meningioma”, *Neuroinformatics*, vol. 19, no. 3, pp. 393–402, 2020.
- [18] M. Gao, J. Chen, H. Mu and D. Qi, “A Transfer Residual Neural Network Based on ResNet-34 for Detection of Wood Knot Defects”, *Forests*, vol. 12, no. 2, 2021.
- [19] A. M. Reza, “Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement”, *Journal of VLSI Signal Processing*, vol. 38, no. 1, pp. 35–44, 2004.
- [20] [Online]. Available: https://scikit-image.org/docs/stable/auto_examples/filters/plot_unsharp_mask.html.

- [21] G. Gupta, “Algorithm for Image Processing Using Improved Median Filter and Comparison of Mean, Median and Improved Median Filter”, *International Journal of Soft Computing and Engineering (IJSCE)*, vol. 1, no. 5, 2011.
- [22] A. Değirmenci, İ. Çankaya ve R. Demirci, “Gradyan Anahtarlama Gauss Görüntü Filtresi”, *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, c. 6, s. 1, ss. 196-215, 2017.
- [23] B. S. Akkoca, “Durgun Görüntülerden Yüz İfadelerinin Tanınması”, Yüksek Lisans Tezi, Bilgisayar Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul, Türkiye, 2014.
- [24] P. A. Torrione, K. D. Morton, R. Sakaguchi and L. M. Collins, “Histograms of Oriented Gradients for Landmine Detection in Ground-Penetrating Radar Data”, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no.3, pp.1538-1550, 2014.
- [25] B. Zhang, Y. Gao, S. Zhao and J. Liu, “Local Derivative Pattern Versus Local Binary Pattern: Face Recognition With High-Order Local Pattern Descriptor”, *IEEE Transactions on Image Processing*, vol. 19, no. 2, pp. 533 - 544, 2009.
- [26] C. Cortes and V. Vapnik. 1995. Support-vector Networks. *Machine Learning* 20.3 (1995), 273–297. <https://doi.org/10.1007/BF00994018>
- [27] A. F. Agarap, “An Architecture Combining Convolutional Neural Network (CNN) and Support Vector Machine (SVM) for Image Classification”, *Arxiv*, 2017.
- [28] N. C. Pratiwi, N. Ibrahim, Y. N. Fu’adah and K. Masykuroh, “Computer-Aided Detection (CAD) for COVID-19 based on Chest X-Ray Images using Convolutional Neural Network”, *International Conference in Engineering, Technology and Innovative Researches*, 2020.