

Göğüs X-Ray görüntülerinin AlexNet tabanlı sınıflandırılması

AlexNet-based classification of chest X-Ray images

Kubilay Muhammed SÜNNETÇİ^{1,2} , Ahmet ALKAN² , Edanur TAR³ 

¹Department of Electrical and Electronics Engineering, Osmaniye Korkut Ata University, Osmaniye, Turkey

²Department of Electrical and Electronics Engineering, Kahramanmaraş Sütçü İmam University, Kahramanmaraş, Turkey

³Department of Nursing, Osmaniye Korkut Ata University, Osmaniye, Turkey

(kubilaysunnetci@osmaniye.edu.tr, aalkan@ksu.edu.tr, edanurtar@osmaniye.edu.tr)

Received: Aug.,31, 2021

Accepted: Sep.26, 2021

Published: Oct.20, 2021

Özetçe—COVID-19 salgını Aralık 2019’da ilk kez ortaya çıkmış ve o zamandan beri dünyayı etkisi altına almaktadır. Gün geçtikçe dünyada COVID-19 hasta sayısı hızla artmaktadır ve bu hastalığın teşhisinin, hastalık tedavi süreci için önemli olduğu bilinmektedir. COVID-19 hastalığının teşhisinde klinik yardımcı olan göğüs X-Ray görüntüleri yaygın olarak kullanılmaktadır. Bu çalışmada, uzmanların iş yükünü azaltmak amacıyla, bu görüntüler kullanılarak makine öğrenmesi tabanlı modeller geliştirilmiştir. Çalışmada kullanılan veri setinde toplam 137 COVID-19, 90 normal ve 90 pnömoni kişilerden alınan görüntüler bulunmaktadır. Burada, AlexNet derin öğrenme mimarisi kullanılarak her görüntü için 1000 görüntü özelliği çıkartılmıştır. Sonrasında, bu görüntü özellikleri kullanılarak çalışmada kullanılan sınıflandırıcılar eğitilmiştir. Sonuçlardan, en başarılı sınıflandırıcı olan kübik destek vektör makinesi (Cubic Support Vector Machine, Cubic SVM) sınıflandırıcısının Doğruluk (%), Duyarlık (%), Özgüllük (%), Kesinlik (%), F₁ skoru (%) ve Matthews Korelasyon Katsayısı (Matthews Correlation Coefficient, MCC) değerlerinin sırasıyla 95.27, 94.95, 97.76, 94.65, 94.79 ve 0.9250’ye eşit olduğu görülmüştür.

Anahtar Kelimeler: COVID-19, özellik çıkartma, derin öğrenme, AlexNet, makine öğrenmesi, hastalık teşhisi

Abstract —COVID-19 pandemic first broke out in December 2019 and has been affecting the world ever since. The number of COVID-19 patients is increasing rapidly in the world day by day, and it is known that the diagnosis of this disease is important for disease treatment. Chest X-ray images that are clinical adjuncts are widely used in the diagnosis of COVID-19 disease. In the study, machine learning-based models are developed using these images to reduce the workload of expert. In the data set used in the study, there are images obtained from a total of 137 COVID-19, 90 normal, and 90 pneumonia subjects. Here, 1000 image features are extracted for each image using AlexNet deep learning architecture. Afterward, the classifiers used in the study are trained using these image features. From the results, Accuracy (%), Sensitivity (%), Specificity (%), Precision (%), F1 score (%), and Matthews Correlation Coefficient (Matthews Correlation Coefficient, MCC) values of Cubic SVM that is the most successful classifier are equal to 95.27, 94.95, 97.76, 94.65, 94.79, and 0.9250, respectively.

Keywords: COVID-19, feature extraction, deep learning, AlexNet, machine learning, disease diagnosis

1. Giriş

SARS-CoV-2 virüsünün neden olduğu “Yeni Koronavirüs Hastalığı” (COVID-19)’na ilk olarak 2019 yılında Çin’in Wuhan kentinde rastlanmıştır. Hızla tüm dünyaya yayılması ile DSÖ tarafından Mart 2020’de pandemi ilan edilmiştir (DSÖ, 2021). Damlacıklar ve yakın temas ile yayılım gösteren SARS-CoV-2 virüsü ile enfekte olan bireylerde belirtiler kişiden kişiye farklılık gösterebilmektedir. Sıklıkla görülen semptomlar 38 °C’nin üzerinde ateş, yorgunluk, kuru öksürük iken ağrı, titreme, burun tıkanıklığı, soğuk algınlığı, boğaz ağrısı, nefes darlığı, sindirim sistemi bozuklukları, koku ve tat kaybı gibi belirtiler de ortaya çıkabilmektedir. Enfekte olan bireylerin çoğu hafif ve orta şiddetli semptomlar verirken enfeksiyon şiddetli solunum yetmezliği ve ölümlerle de sonuçlanabilmektedir (Tar ve Küçüköğlü, 2021; Ludvigsson, 2020; Hadi vd., 2020). Bulaşıcılığı oldukça yüksek olan bu hastalık, Ağustos 2021 tarihi itibarıyla yaklaşık 202 milyon kişiyi enfekte etmiş ve 4 milyon kişinin ölümüne yol açmıştır (Worldometer, 2021). Virüsün daha fazla bireye yayılımını önlemek için enfekte olmuş bireylerin tespit edilmesi ve izolasyona alınması oldukça önemlidir. Nazofarengeal sürüntü ile yapılan “Ters transkripsiyon-kantitatif polimeraz zincir reaksiyonu” (RT-qPCR) dünya çapında COVID-19’un teşhisinde kullanılan altın standart yöntemdir. Ancak karmaşık laboratuvar ekipmanı ve kalifiye personel ihtiyacı nedeniyle RT-qPCR’nin gerçekleştirilmesi merkezi laboratuvarlarla sınırlıdır. Ayrıca bazen yanlış negatif veya belirsiz sonuçlar verebilmektedir. Bu nedenle yanılgıların önlenmesi amacıyla RT-qPCR test sonuçları, semptomlar ve radyolojik yöntemler ile değerlendirilmelidir (Palaz vd., 2021; Zimmermann ve Curtis, 2020).

Radyolojik yöntemlerden göğüs X-Ray görüntülerinin kullanımı COVID-19’un neden olduğu pnömoninin tespitinde yol gösterici olurken araştırmalar bunların radyologlar tarafından farklı bakış açıları ile yorumlandığını göstermektedir (Maguolo ve Nanni, 2021; Ai vd., 2020). Bu aşamada makine öğrenmesi ve derin öğrenme teknikleri kullanımının COVID-19’un tespitinde yüksek performans alınabileceğini bildiren çalışmalar mevcuttur (Booth vd., 2021; Jadon, 2021; Kassania vd., 2021; Khuzani vd., 2021; Kwekha-Rashid vd., 2021; Muhammet vd., 2021; Rasheed vd., 2021). Jadon (2021)’un çalışmasında veri büyütme, transfer öğrenme ve denetimsiz öğrenme gibi birkaç adımlı öğrenme yaklaşımı ile temel modelleri kullanarak göğüs X-Ray görüntülerinden COVID-19’un tespitinde %83’ten %96,4 doğrulukta verimli ve doğru bir derin öğrenme modeli elde edildiği sonucuna ulaşılmıştır. Makine öğrenimi kullanılarak COVID-19 enfeksiyonunda mortalite için prognostik bir model geliştirilen bir diğer çalışmada ise mortalite riski en yüksek olan hastalarda prognostik serum biyobelirteçlerini belirlemek amacıyla SARS-CoV-2 pozitif hastalardan alınan laboratuvar verileri ve mortalite analiz edilmiştir. Ölümün 48 saat öncesinde tahmin edilmesi amacıyla hastanın c-reaktif protein, kan üre azotu, serum kalsiyum, serum albümin ve laktik asit laboratuvar değerleri kullanılarak bir makine öğrenim modeli geliştirilmiştir. Elde edilen destek vektörü makine modelinde, uzatılmış test verilerinde hastanın ölümünü tahmin etmek için %91 duyarlılık ve %91 özgüllük (AUC 0.93) tespit edilmiştir (Booth vd., 2021). Kwekha-Rashid ve ark. (2021) COVID-19 ile ilgili araştırmalarda makine öğrenmesi uygulamaları ve algoritmalarının rolünü tespit etmek amacıyla yaptıkları çalışmada 14 makale incelemiştir. Makine öğreniminin COVID-19 vakalarının değerlendirilmesi ve sınıflandırılmasında önemli rol oynayabileceği ve denetimli öğrenmenin %92,9 test doğruluğu ile diğer denetimsiz öğrenme algoritmalarından daha iyi sonuçlar verdiği saptanmıştır (Kwekha-Rashid vd., 2021). COVID-19 ve pnömoni tanısı alan hastalar ile normal bireylerin göğüs X-Ray görüntüleri kullanılarak yapılan makine öğrenmesi temelli bir diğer çalışmada ise farklı türde akciğer hastalıklarının sınıflandırılmasında %94 oranında doğruluğa ulaşılmıştır (Khuzani vd., 2021). Muhammet ve ark. (2021) Meksika’da COVID-19 pozitif ve negatif vakalar için epidemiyoloji etiketli veri setlerini (RT-PCR sonuçları) kullanarak Decision Tree, Logistic Regression, Naive Bayes, Support Vector Machine ve Artificial Neural Network ile COVID-19 enfeksiyonu için denetimli makine öğrenimi modelleri geliştirmiştir. Bu modeller arasında en yüksek doğruluk %94.99 ile Decision Tree iken en başarılı ikinci sistemin doğruluk oranı %94.41 ile Logistic Regression sınıflandırıcısıdır (Muhammet vd., 2021). Göğüs X-Ray görüntülerinden makine öğrenimi tabanlı COVID-19 teşhisi için Logistic Regression (LR) ve Convolutional Neural Networks (CNN) yöntemlerinin kullanıldığı farklı bir çalışmada ise LR ve CNN modellerinin pozitif vaka tanımlaması temel bileşen analizi (PCA) olmadan %95,2-97.6 ve PCA ile %97,6-100 genel doğruluk gösterdiği saptanmıştır (Rasheed vd, 2021). Kassania ve ark. (2021)’nın makine öğrenimi tabanlı bir yaklaşım ile X-Ray ve Bilgisayarlı Tomografi (BT) görüntülerinde COVID-


19 tespiti amacıyla yaptıkları çalışmalarında Bagging Tree sınıflandırıcılı DenseNet121 öznitelik çıkarıcınının %99 sınıflandırma doğruluğu ile en iyi performansı elde ettiği ve ikinci en iyi öğrenicinin LightGBM tarafından %98 doğrulukla eğitilmiş bir ResNet50 özellik çıkarıcınının bir çeşidi olduğu tespit edilmiştir.

Bu çalışmada 137 COVID-19, 90 normal ve 90 pnömoni bireylerden alınan toplam 317 göğüs X-Ray görüntüsü kullanılmıştır. Burada, her bir görüntü için AlexNet derin öğrenme mimarisi kullanılarak fc8 katmanından 1000 görüntü özelliği elde edilmiştir. Elde edilen bu görüntü özellikleri 8-kat çapraz doğrulama tekniği kullanılarak sınıflandırılmıştır. Bu çalışmada, Medium Tree, Bagged Trees Ensemble, Kernel Naive Bayes, Cosine KNN, Linear Discriminant, Quadratic SVM, Linear SVM ve Cubic SVM sınıflandırıcıları kullanılmıştır. Çalışmada kullanılan sınıflandırıcılar sınıflandırma performans metrikleri açısından birbirleriyle karşılaştırılmıştır.

Çalışma şu şekilde organize edilmiştir. Bölüm 2’de kullanılan veri seti açıklanmıştır ve Bölüm 3’te önerilen sistem açıklanmıştır. Burada, kullanılan özellik çıkartma yöntemi, eğitim parametreleri gibi bilgiler verilmektedir. Bölüm 4’te, çalışmada elde edilen deneysel sonuçlar paylaşılmıştır. Son olarak ise, yapılan çalışmanın sonuçları sunulmuştur.

2. Veri

Bu bölümde, Kaggle platformundan aldığımız göğüs X-Ray görüntüleri tanıtılmaktadır (Covid-19 Image Dataset, <https://www.kaggle.com/pranavraikokte/covid19-image-dataset>). Burada, 137 COVID-19 pozitif, 90 normal ve 90 pnömoni bireylerden alınan görüntü örnekleri bulunmaktadır. Bu görüntüler JPG, JPEG ve PNG formatındadır.



Şekil 1. Çalışmada kullanılan veri setinde bulunan örnek göğüs X-Ray görüntüleri

a) COVID-19, b) Normal, c) Pnömoni

Şekil 1’de çalışmada kullanılan veri setinde bulunan her bir sınıfa ait bir görüntü örneği bulunmaktadır. Şekil 1.a-c’de sırasıyla COVID-19 pozitif, normal ve pnömoni bireylerden alınmış göğüs X-Ray görüntüleri verilmektedir. Bu noktada, çalışmada kullanılan veri seti için 8-kat çapraz doğrulama kullanılarak sınıflandırıcılar eğitilmektedir.

3. Önerilen Sistem

Bu çalışmada, 137 COVID-19, 90 Normal ve 90 pnömoni kişiden alınmış olan toplam 317 görüntü kullanılmıştır. Burada, öncelikle veri setinde bulunan görüntülerden görüntü özellikleri AlexNet Derin Öğrenme mimarisine göre çıkarılmıştır. Tam bağlantılı katmanlardan her bir görüntü için 1000 adet

özellik elde edilmiştir. Sonrasında, elde edilen görüntü özellikleri kullanılarak, Medium Tree, Bagged Trees Ensemble, Kernel Naive Bayes, Cosine K-Nearest Neighbor (KNN), Linear Discriminant, Quadratic SVM, Linear SVM ve Cubic SVM sınıflandırıcıları eğitilmiştir (Alkan ve Günay, 2012; Akben, 2018; Polikar, 2012; Rish, 2001; Guo vd., 2003). Eğitim için 8-kat çapraz doğrulama tekniği kullanılmaktadır. Eğitim aşamasından önce, görüntü özelliklerinin AlexNet mimarisi kullanılarak çıkartılması nedeniyle, Şekil 2’de AlexNet mimarisinin ağ katman bilgileri verilmektedir (Siyuan vd., 2019).

| | Name | Type | Activations |
|----|---|-----------------------|-------------|
| 1 | data 227×227×3 images with 'zero-center' normalization | Image Input | 227×227×3 |
| 2 | conv1 96 11×11×3 convolutions with stride [4 4] and padding [0 0 0 0] | Convolution | 55×55×96 |
| 3 | relu1 ReLU | ReLU | 55×55×96 |
| 4 | norm1 cross channel normalization with 5 channels per element | Cross Channel Nor... | 55×55×96 |
| 5 | pool1 3×3 max pooling with stride [2 2] and padding [0 0 0 0] | Max Pooling | 27×27×96 |
| 6 | conv2 2 groups of 128 5×5×48 convolutions with stride [1 1] and padding [2 2 2 2] | Grouped Convolution | 27×27×256 |
| 7 | relu2 ReLU | ReLU | 27×27×256 |
| 8 | norm2 cross channel normalization with 5 channels per element | Cross Channel Nor... | 27×27×256 |
| 9 | pool2 3×3 max pooling with stride [2 2] and padding [0 0 0 0] | Max Pooling | 13×13×256 |
| 10 | conv3 384 3×3×256 convolutions with stride [1 1] and padding [1 1 1 1] | Convolution | 13×13×384 |
| 11 | relu3 ReLU | ReLU | 13×13×384 |
| 12 | conv4 2 groups of 192 3×3×192 convolutions with stride [1 1] and padding [1 1 1 1] | Grouped Convolution | 13×13×384 |
| 13 | relu4 ReLU | ReLU | 13×13×384 |
| 14 | conv5 2 groups of 128 3×3×192 convolutions with stride [1 1] and padding [1 1 1 1] | Grouped Convolution | 13×13×256 |
| 15 | relu5 ReLU | ReLU | 13×13×256 |
| 16 | pool5 3×3 max pooling with stride [2 2] and padding [0 0 0 0] | Max Pooling | 6×6×256 |
| 17 | fc6 4096 fully connected layer | Fully Connected | 1×1×4096 |
| 18 | relu6 ReLU | ReLU | 1×1×4096 |
| 19 | drop6 50% dropout | Dropout | 1×1×4096 |
| 20 | fc7 4096 fully connected layer | Fully Connected | 1×1×4096 |
| 21 | relu7 ReLU | ReLU | 1×1×4096 |
| 22 | drop7 50% dropout | Dropout | 1×1×4096 |
| 23 | fc8 1000 fully connected layer | Fully Connected | 1×1×1000 |
| 24 | prob softmax | Softmax | 1×1×1000 |
| 25 | output crossentropyex with 'tench' and 999 other classes | Classification Output | - |

Şekil 2. AlexNet mimarisinin ağ katmanlarının görselleştirilmesi

Şekil 2’de, çalışmada görüntü özelliklerinin çıkartılması için kullanılan AlexNet mimarisi ağ katmanları gösterilmektedir. AlexNet, 8 katman derinliğine sahip bir mimaridir ve 1000 kategoriye kadar sınıflandırma işlemi yapabilir. Şekilde de görüldüğü gibi, 227*227*3 görüntüler için kullanılabilen bu mimari toplamda 25 katman içermektedir. Burada, konvolüsyon (Convolution), havuzlama (Pooling), ReLu ve tam bağlantılı katmanların (Fully Connected Layer) bulunduğu görülür (Alex vd, 2012). Ağ mimarisi incelendiğinde, biz 23 numaralı satırda bulunan fc8 katmanından görüntü

özelliklerini elde etmekteyiz. Şekilden de görüldüğü gibi, bu katman sayesinde her bir görüntü için 1000 adet görüntü özelliği çıkartılabilmektedir. Sonrasında, çıkartılan bu görüntü özellikleri kullanılarak çalışmada kullanılacak olan sınıflandırıcılar eğitilebilmektedir. Bu noktada, çalışmada kullanılan sınıflandırıcılar için elde edilen eğitim parametreleri ve değerlendirme metrikleri Tablo 1’de verilmiştir.

Tablo 1. Çalışmada kullanılan sınıflandırıcılar için eğitim parametreleri ve değerlendirme metrikleri

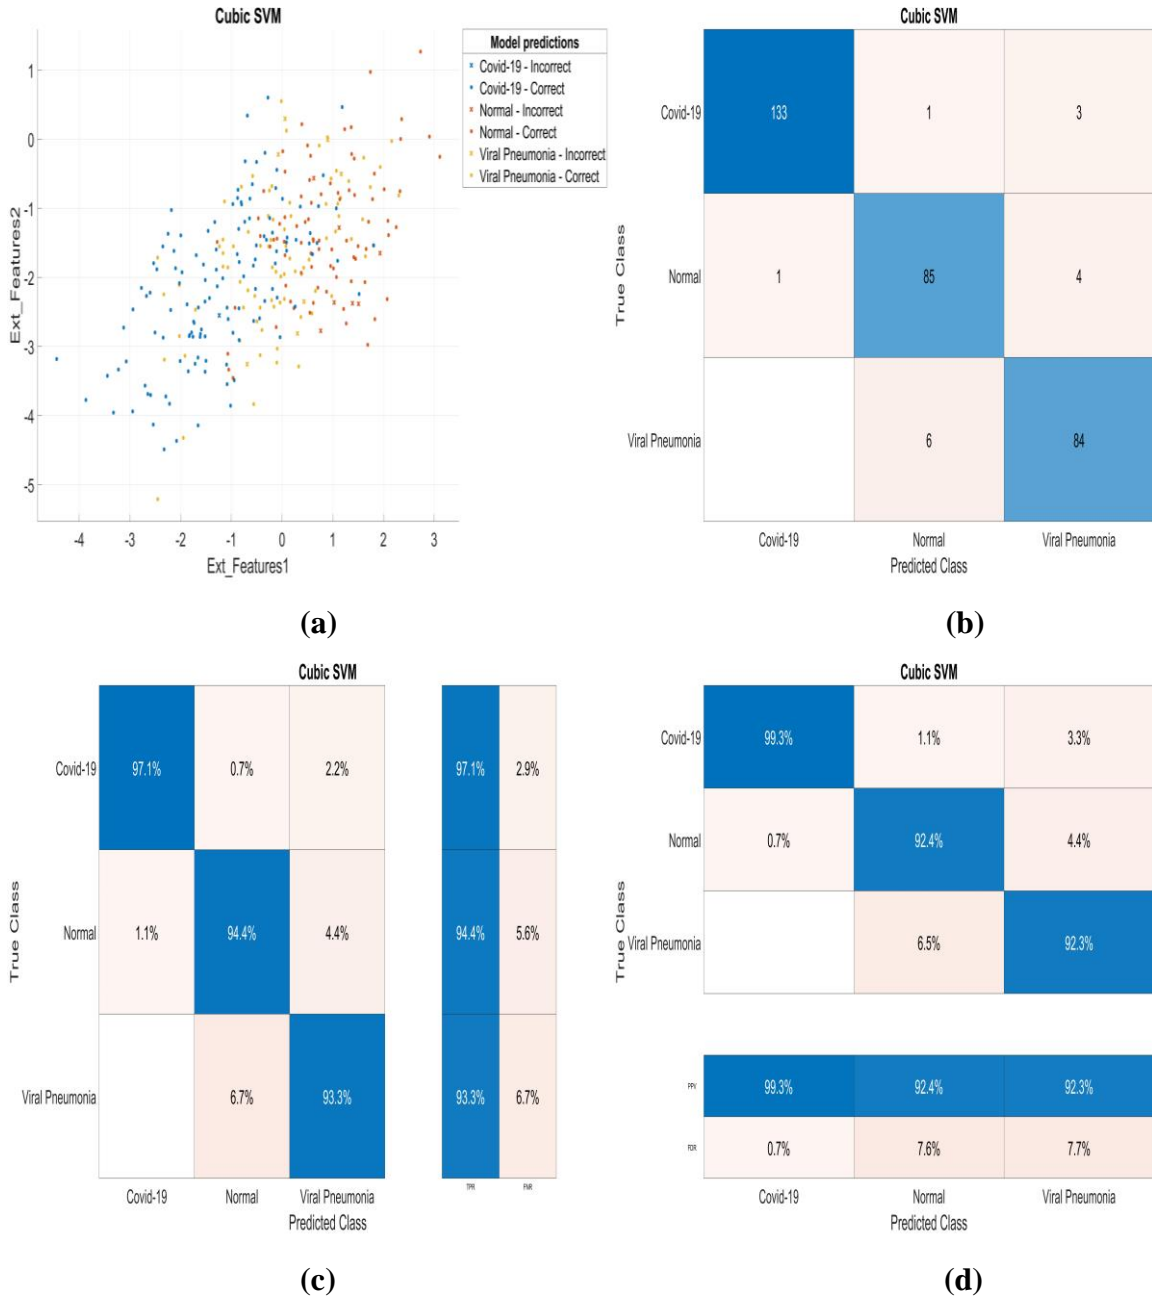
| | Doğruluk (%) | Toplam Yanlış Sınıflandırma | Tahmini Hız ~obs/s | Eğitim Zamanı s | Model Tipi |
|-----------------------|--------------|-----------------------------|--------------------|-----------------|---|
| Medium Tree | 80.76 | 61 | 620 | 10.583 | Maksimum bölme sayısı:20, Gini çeşitlilik endeksi |
| Bagged Trees Ensemble | 90.54 | 30 | 300 | 46.263 | Maksimum bölme sayısı:316, Öğrenici sayısı:30 |
| Kernel Naïve Bayes | 91.17 | 28 | 41 | 123.01 | Kernel tipi: Gaussian |
| Cosine KNN | 91.17 | 28 | 440 | 32.902 | Komşu sayısı:10, Mesafe metriği: Cosine |
| Linear Discriminant | 91.48 | 27 | 570 | 9.7243 | Kovaryans yapısı: Tam |
| Quadratic SVM | 94.01 | 19 | 430 | 18.488 | Kernel fonksiyonu: Quadratic |
| Linear SVM | 94.95 | 16 | 390 | 18.2 | Kernel fonksiyonu: Linear |
| Cubic SVM | 95.27 | 15 | 490 | 22.928 | Kernel fonksiyonu: Cubic |

Tablo 1’de, çalışmada kullanılan sınıflandırıcılar için eğitim parametreleri ve bazı değerlendirme metrikleri verilmiştir. Aynı zamanda bu sınıflandırıcılar için, sınıflandırma yöntemlerinde kullanılan model tipleri de Tablo 1’de yer almaktadır. Tablodan, çalışmada kullanılan Medium Tree, Bagged Trees Ensemble, Kernel Naive Bayes, Cosine KNN, Linear Discriminant, Quadratic SVM, Linear SVM ve Cubic SVM sınıflandırıcılarının doğruluklarının sırasıyla %80.76, %90.54, %91.17, %91.17, %91.48, %94.01, %94.95 ve %95.27’ye eşit olduğu görülmektedir. Bu nedenle toplam yanlış sınıflandırma ve doğruluk açısından en başarılı sistemin Cubic SVM olduğu anlaşılabilir. Bu sınıflandırıcılar, eğitim zamanı açısından incelendiğinde ise en başarılı sistemlerin sırasıyla Linear Discriminant ve SVM sınıflandırıcılarının olduğu görülmektedir.

4. Deneysel Sonuçlar

Bu bölümde, veri dağılım grafiği, karmaşıklık matrisleri ve pozitif sınıflar için Receiver Operating Characteristic (ROC) eğrileri verilmektedir. Bu noktada, çalışmada kullanılan sınıflandırıcıların performans metriklerini yorumlayabilmek açısından karmaşıklık matrisleri ve ROC eğrilerinin incelenmesi gerekmektedir. Bu nedenle, karmaşıklık matrisi üç farklı şekilde incelenmektedir (doğru ve hatalı gözlem sayısı, Doğru Pozitif Oranları (True Positive Rates, TPR)-Yanlış Negatif Oranları (False Negative Rates) ve Pozitif Tahmin Değerleri (Positive Predictive Values, PPV)-Yanlış Keşif Oranları

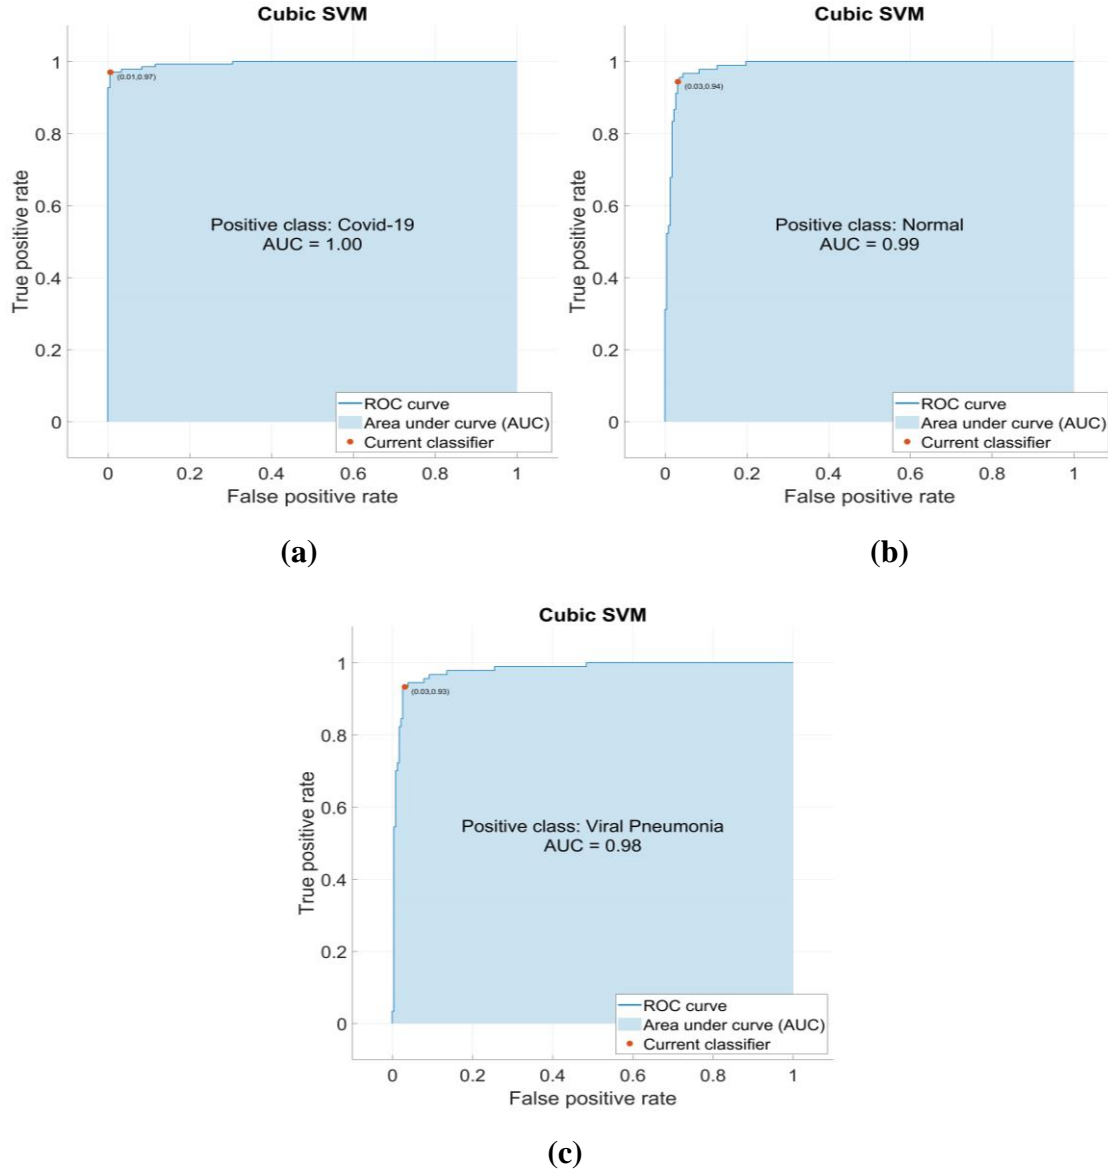
(False Discovery Rates, FDR)). Benzer şekilde, her sınıf için ROC eğrilerinin altında kalan alan değerleri ve grafikleri de burada verilmektedir.



Şekil 3. En başarılı sınıflandırıcı olan Cubic SVM'nin veri dağılım grafiği ve karmaşıklık matrisleri

Şekil 3.a ve 3.b-d'de, çalışmada kullanılan modeller arasından en başarılı olan Cubic SVM sınıflandırıcısının sırasıyla veri dağılım grafiği ve karmaşıklık matrisleri gösterilmektedir. Bu noktada, AlexNet mimarisine göre çıkartılan 1000 özelliğin iki tanesi, iki boyutlu olan Şekil 3. a'da gösterilmektedir. Burada, her bir sınıf için doğru veya hatalı olarak belirlenen özellik değerleri görülebilmektedir. Bir diğer taraftan, Şekil 3.b her sınıf için yapılan doğru ve hatalı tahmin sayılarını göstermektedir. Şekil 3.b'ye göre, 137 COVID-19 hastasının 133 tanesi COVID-19 olarak bilinirken, 1 tane tanesi normal ve 3 tanesi de pnömoni olarak tahmin edilmiştir. Benzer şekilde, 90 normal ve 90 pnömoni kişi sırasıyla 1 COVID-19/85 normal/4 pnömoni ve 0 COVID-19/6 normal/84 pnömoni olarak

tespit edilmiştir. Bu noktada, Cubic SVM sınıflandırıcısının 8-kat çapraz doğrulama kullanarak elde ettiği performans metrikleri incelendiğinde, eğitim ve doğrulama aşamasının başarılı bir şekilde gerçekleştiği anlaşılabilmektedir. Şekil 3.c-d bu sınıflandırıcının sırasıyla TPR-FNR ve PPV-FDR değerlerini göstermektedir. Bu şekillerden COVID-19, normal ve pnömoni kişiler için elde edilen TPR ve PPV değerlerinin sırasıyla %97.1-%94.4-%93.3 ve %99.3-%92.4-%92.3'a eşit olduğu görülebilmektedir. İlaveten, bu sınıflandırıcının bir başka performans metriği incelemesi için aşağıdaki gibi farklı pozitif sınıfların ROC eğrileri verilmiştir.



Şekil 4. En başarılı sınıflandırıcı olan Cubic SVM'nin ROC eğrileri

Şekil 4.a-c'de, Cubic SVM sınıflandırıcısı için pozitif sınıflar sırasıyla COVID-19, normal ve pnömoni olarak çizdirilmiştir. Burada, eğri altında kalan alan (Area Under Curve, AUC) 1'e yaklaştıkça, eğitimin başarılı bir şekilde gerçekleştiği söylenebilmektedir. Bu noktada, Şekil 4.a-c'de verilen şekillerden, COVID-19, normal ve pnömoni pozitif sınıflarının AUC değerlerinin sırasıyla 1, 0.99 ve 0.98'e eşit olduğu görülmektedir. Böylece, çalışmada kullanılan en başarılı sınıflandırıcı olan Cubic SVM'nin en başarılı tespiti COVID-19 sınıfında yapabildiği görülmektedir.

5. Sonular

Bu alıřmada, AlexNet derin ğrenme mimarisi kullanılarak 317 grnt iin grnt zellikleri ıkartılmaktadır. Bu grntlerin 137 tanesi COVID-19, 90 tanesi normal ve 90 tanesi de pnmoni kiřilerden alınmıřtır. Bu grntlerin zellikleri, AlexNet derin ğrenme mimarisin fc8 katmanından elde edilmektedir. Ayrıca her bir grnt bir iin ıkartılan grnt zelliđi sayısı 1000'e eřittir. Sonrasında ıkartılan bu zellikler kullanılarak, Medium Tree, Bagged Trees Ensemble, Kernel Naive Bayes, Cosine KNN, Linear Discriminant, Quadratic SVM, Linear SVM ve Cubic SVM sınıflandırıcıları eđitilmektedir. Bu noktada, eđitim ve dođrulama seti 8-kat apraz dođrulama yntemiyle oluřturulmuřtur. Bylece, alıřmada kullanılan btn sınıflandırıcılar iin karmařıklık matrisleri elde edilebilmektedir. Bu sınıflandırıcıların karmařıklık matrislerinden faydalanılarak hesaplanabilen sınıflandırma performans metrikleri Tablo 2'de ki gibi verilmiřtir.

Tablo 2. alıřmada kullanılan sınıflandırıcıların sınıflandırma performans metrikleri

| | Medium Tree | Bagged Trees Ensemble | Kernel Naive Bayes | Cosine KNN | Linear Discriminant | Quadratic SVM | Linear SVM | Cubic SVM |
|--------------------------|-------------|-----------------------|--------------------|------------|---------------------|---------------|------------|---------------|
| Dođruluk (%) | 80.76 | 90.54 | 91.17 | 91.17 | 91.48 | 94.01 | 94.95 | 95.27 |
| Hata (%) | 19.24 | 9.46 | 8.83 | 8.83 | 8.52 | 5.99 | 5.05 | 4.73 |
| Duyarlılık (%) | 79.44 | 89.52 | 90.39 | 90.14 | 91.14 | 93.73 | 94.58 | 94.95 |
| zgllk (%) | 90.54 | 95.29 | 95.66 | 95.62 | 96.00 | 97.17 | 97.61 | 97.76 |
| Kesinlik (%) | 79.44 | 89.86 | 90.40 | 90.61 | 90.54 | 93.28 | 94.35 | 94.65 |
| F ₁ Skoru (%) | 79.39 | 89.65 | 90.39 | 90.23 | 90.77 | 93.47 | 94.44 | 94.79 |
| MCC | 0.6992 | 0.8504 | 0.8606 | 0.8605 | 0.8669 | 0.9058 | 0.9202 | 0.9250 |

Tablo 2 alıřmada kullanılan tm sınıflandırıcıların sınıflandırma performans metriklerini gstermektedir. Tablodan, alıřmada kullanılan Medium Tree, Bagged Trees Ensemble, Kernel Naive Bayes, Cosine KNN, Linear Discriminant, Quadratic SVM, Linear SVM ve Cubic SVM sınıflandırıcılarının dođruluklarının sırasıyla %80.76, %90.54, %91.17, %91.17, %91.48, %94.01, %94.95 ve %95.27 olduđu grlmektedir. Bylece, dođruluk aısından en bařarılı sınıflandırıcının Cubic SVM olduđu grlmektedir. En iyi sınıflandırıcının belirlenmesi hususunda sadece dođruluk metriđinin incelenmesi gereklidir ama yeterli deđildir. Tablo incelendiđinde, en bařarılı sınıflandırıcı olan Cubic SVM'nin hata (%), duyarlılık (%), zgllk (%), kesinlik (%), F₁ skoru (%) ve MCC deđerlerinin sırasıyla 4.73, 94.95, 97.76, 94.65, 94.79 ve 0.9250 olduđu grlr. Cubic SVM'nin sınıflandırma performans metrikleri diđer sınıflandırıcılarla karřılařtırıldıđında, bu sınıflandırıcının diđer sınıflandırıcılardan daha bařarılı olduđu grlmektedir.

Kaynaka

Alkan A, Gnay M. (2012) Identification of EMG signals using discriminant analysis and SVM classifier. *Expert systems with Applications* 39(1):44-47.

Akben SB. (2018) Predicting the success of wart treatment methods using decision tree based fuzzy informative images. *Biocybernetics and Biomedical Engineering* 38(4): 819-827.

- Ai T, Yang Z, Hou H, Zhan C, Chen C, Lv W, Xia L (2020) Correlation of chest CT and RT-PCR testing for coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases. *Radiology* 296(2): E32-E40.
- Booth AL, Abels E, McCaffrey P (2021) Development of a prognostic model for mortality in COVID-19 infection using machine learning. *Modern Pathology* 34(3):522-531.
- Dataset (2021) <https://www.kaggle.com/pranavraikokte/covid19-image-dataset>, COVID-19 Image Dataset, Pranav Raikote.
- Dünya Sağlık Örgütü (WHO) (2021) WHO Announces COVID-19 Outbreak a Pandemic. <https://www.euro.who.int/en/health-topics/healthemergencies/coronavirus-covid19/news/news/2020/3/who-announces-covid19-outbreak-a-pandemic>. Accessed 07.08.2021
- Hadi AG, Kadhom M, Hairunisa N, Yousif E, Mohammed SA (2020) A review on COVID-19: origin, spread, symptoms, treatment, and prevention. *Biointerface Research in Applied Chemistry* 10(6): 7234-7242.
- Guo G, Wang H, Bell D, Bi Y, Greer K. (2003) KNN model-based approach in classification. In OTM "Confederated International Conferences" On the Move to Meaningful Internet Systems" Springer, Berlin, Heidelberg. pp.986-996.
- Jadon S (2021) COVID-19 detection from scarce chest x-ray image data using few-shot deep learning approach. In *Medical Imaging 2021: Imaging Informatics for Healthcare, Research, and Applications* 11601:116010X.
- Kassania SH, Kassanib PH, Wesolowskic MJ, Schneidera KA, Detersa R (2021) Automatic detection of coronavirus disease (COVID-19) in X-ray and CT images: a machine learning based approach. *Biocybernetics and Biomedical Engineering* 41(3):867-879.
- Khuzani AZ, Heidari M, Shariati SA (2021) COVID-Classifier: An automated machine learning model to assist in the diagnosis of COVID-19 infection in chest x-ray images. *Scientific Reports* 11(1):1-6.
- Krizhevsky A, Sutskever I, Hinton GE. (2012) Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems* 25:1097-1105.
- Kwekha-Rashid AS, Abduljabbar HN, Alhayani B (2021) Coronavirus disease (COVID-19) cases analysis using machine-learning applications. *Applied Nanoscience* 1-13.
- Lu S, Lu Z, Zhang YD. (2019) Pathological brain detection based on AlexNet and transfer learning. *Journal of Computational Science* 30: 41-47.
- Ludvigsson JF (2020) Systematic review of COVID-19 in children shows milder cases and a better prognosis than adults. *Acta Paediatrica* 109(6):1088-1095.
- Maguolo G, Nanni L. (2021) A critic evaluation of methods for covid-19 automatic detection from x-ray images. *Information Fusion* 76:1-7.
- Muhammad LJ, Algehyne EA, Usman SS, Ahmad A, Chakraborty C, Mohammed IA. (2021) Supervised machine learning models for prediction of COVID-19 infection using epidemiology dataset. *SN computer Science* 2(1):1-13.
- Palaz F, Kalkan AK, Tozluyurt A, Ozsoz M. (2021) CRISPR-based tools: Alternative methods for the diagnosis of COVID-19. *Clinical Biochemistry* 89:1.
- Polikar R. (2012) Ensemble learning. Ensemble machine learning, Springer, Boston, MA.
- Rasheed J, Hameed AA, Djeddi C, Jamil A, Al-Turjman F. (2021) A machine learning-based framework for diagnosis of COVID-19 from chest X-ray images. *Interdisciplinary Sciences: Computational Life Sciences* 13(1):103-117.
- Rish I. (2001) An empirical study of the naive Bayes classifier. In *IJCAI 2001 workshop on empirical methods in artificial intelligence* 3(22): 41-46.

Tar E, Küçüköğlü S. (2021) COVID-19 ve Yenidoğan Sağlığı. N. Ulutaşdemir, İ. Kahrıman (Ed), COVID-19 Pandemisinde Çocuk Sağlığı içinde, <https://iksadyayinevi.com/wp-content/uploads/2021/05/COVID-19-PANDEMISINDE-COCUK-SAGLIGI.pdf>

Worldometer (2021) COVID-19 Coronavirus Pandemic. <https://www.worldometers.info/coronavirus/> Accessed 07.08.2021

Zimmermann P, Curtis N. (2020) Coronavirus infections in children including COVID-19: An overview of the epidemiology, clinical features, diagnosis, treatment and prevention options in children. *Pediatr Infect Dis J.* 39(5):355- 368.