

Akciğer X-Ray Görüntülerini Kullanarak Yerel İkili Örüntü Tabanlı COVID-19 Tespit Yöntemi

Local Binary Pattern Based COVID-19 Detection Method Using Chest X-Ray Images

Ferhat Bozkurt
Bilgisayar Mühendisliği Bölümü
Atatürk Üniversitesi
Erzurum, Türkiye
fbozkurt@atauni.edu.tr

Erkan Bayram
Bilgisayar Bilimleri Araştırma ve Uygulama Merkezi
Atatürk Üniversitesi
Erzurum, Türkiye
erkan@atauni.edu.tr

Özetçe—COVID-19, dünya çapında hızla yayılan küresel bir pandemik hastalıktır. Bilgisayar destekli araçlarla COVID-19'un otomatik erken tanınması, hastalık tedavisi ve kontrolü için çok önemlidir. Bu bağlamda, X-ray radyografik görüntüleme COVID-19 erken teşhisinde kolay erişilebilir alternatif bir araçtır. Ancak COVID-19, viral zatürre, bakteriyel zatürre gibi çeşitli akciğer hastalıkları birbirine benzeyebilir ve bu görüntüler birbirinden ayırt edilemeyebilir. Dolayısıyla COVID-19 semptomlarının viral pnömoniye (zatürre) benzer olması, yanlış tanımlara yol açabilmektedir. Bu çalışmada, yerel ikili örüntü (LBP) tabanlı COVID-19 tespit yöntemi üzerine çalışılmıştır. LBP ile dokusal öznitelikler çıkarılmış ve bu öznitelikler ile danışmanlı bir öğrenme işlemi gerçekleştirilmiştir. Öğrenme işleminde kNN, Naive Bayes, YSA ve DVM gibi farklı sınıflandırıcılar kullanılmış ve açık erişimli bir veri kümesi üzerinde deneysel çalışmalar gerçekleştirilmiştir. Çeşitli performans metrikleri ile sınıflandırıcıların performans değerlendirmeleri yapılmıştır. Farklı türde ve boyutta yapılan deneysel çalışmalar sonucunda LBP+DVM yöntemi ile %99 üzerinde bir başarı elde edilmiştir.

Anahtar Kelimeler—*makine öğrenmesi, LBP, COVID-19.*

Abstract—COVID-19 is a global pandemic disease that is rapidly spreading around the world. Automatic early diagnosis of COVID-19 with computer-aided tools is crucial for disease treatment and control. In this context, X-ray imaging is an easily accessible and alternative tool in the early diagnosis of COVID-19. However, various lung diseases such as COVID-19, viral pneumonia, bacterial pneumonia are similar to each other and these images may not be distinguished from each other. Thus, the similarity of COVID-19 symptoms to viral pneumonia can lead to misdiagnosis. In this study, the local binary pattern (LBP) based COVID-19 detection method is studied. The textural features are extracted with LBP and supervised learning methods are performed with these features. Different classifiers such as kNN, Naive Bayes, Neural Network, and SVM are used in the training stage and experimental studies are conducted on an open-access dataset. Performance evaluations of classifiers are made with various performance metrics. As a result of experimental studies conducted in different types and dimensions, over 99% accuracy is achieved with the LBP+SVM method.

Keywords—*machine learning, LBP, COVID-19.*

I. GİRİŞ

Yeni tip Koronavirüs (2019) olarak da bilinen COVID-19 salgını, bir solunum yolu enfeksiyon hastalığıdır. Kasım 2019'da Çin'in Wuhan şehrinde ortaya çıktıktan sonra tüm dünyaya hızlıca yayılmıştır. Dünya Sağlık Örgütü raporlarına göre COVID-19, 27 Eylül 2020 tarihine kadar 32,7 milyon doğrulanmış vakaya ve 991 bin ölüme neden oldu [1]. Vakaların sayısı çok hızla artarken, dünyanın pek çok bölgesi kaynak ve test sıkıntısı ile karşı karşıyadır. COVID-19 salgınının yayılmasını engellemenin en önemli adımlarından biri, virüsün popülasyonda daha fazla yayılmasını önlemek için enfekte olduğundan şüphelenilen kişilerin etkili bir şekilde taranmasıdır [2]. Tüm dünyada bilim adamları, mühendisler ve sağlık uzmanları akciğer röntgeni görüntülerinden kısa sürede ve düşük maliyetle COVID-19'u tespit etme ve enfeksiyonun şiddetini belirlemelerine yardımcı olmak için yapay zekâ ve makine öğrenmesi destekli yöntemlerin geliştirilmesini teşvik ettiler. Özellikle X-ray, COVID-19'u özel test kitleri olmadan tespit etmek için yaygın olarak kullanılmaktadır. Bunun sebebi ise neredeyse tüm hastanelerde X-ray görüntüleme cihazları bulunmaktadır. X-ışını ile görüntülemenin bir avantajı, bazı durumlarda hastalığın ön aşamalarında tespit edilebilmesidir. Bu amaçla, hastalığın teşhisi noktasında uzmanlara zaman kazandırmak için taramalarda anormallik olup olmadığını tespit edecek otomatik bir analiz sistemi geliştirmek her zaman gereklidir. Tipik akciğer X-ray görüntüleri şüpheli vakaların erken taranmasına yardımcı olabileceği de, çeşitli viral pnömoni (zatürre) görüntüleri COVID-19 görüntülerine benzerdir ve benzer özellikler içermektedir. Dolayısıyla radyologların diğer bulaşıcı ve enflamatuar akciğer hastalıkları ile COVID-19'u ayırt etmesi zordur. COVID-19 semptomlarının viral pnömoniye benzer olması, yanlış tanıya yol açmaktadır [3].

Göğüs röntgenleri üzerine makine ve derin öğrenme teknikleri giderek popülerlik kazanmaktadır. Literatürde akciğer hastalıklarının akıllı sistemlerle sınıflandırılmasına yönelik birçok çalışma bulunmaktadır. Sogancioglu ve ark [4] yakın zamanda göğüs radyografilerinde derin öğrenme kullanan tüm çalışmalarını inceleyen bir derleme sundular. Sethy ve Behera [5], X-ray görüntülerinden COVID-19 tespitinde derin özellikler ile birlikte destek vektör makinesi (DVM) tabanlı


yöntem önerdiler. Bu yöntemde, evrişimli sinir ağları (ESA) modelinin tam bağlı katmanında derin özellikler çıkarılır ve sınıflandırma amacıyla DVM'ye verilir. Chen [6] çalışmasında, histogram denkleştirme, gri seviye eş-oluşum matrisleri ve destek vektör makinesi algoritmasına dayalı olarak göğüs radyografik görüntülerini tanımlayan etkili bir sınıflandırma sistemi önerdi. Sousa ve ark. [7], radyoloji görüntülerden bilgisayar destekli sistemler aracılığıyla bebeklerde otomatik pnömoni (zatürre) tespiti yapılmıştır. Bu sistemde, pnömoni verileri üç sınıflandırıcı kullanılarak sınıflandırılır. Kullanılan sınıflandırıcılar destek vektör makineleri, k-en yakın komşu (kNN) ve Naive Bayes (NB)'dir. Mevcut veriler için en uygun sınıflandırıcının destek vektör makineleri olduğu belirlenmiştir. Oğuz ve Yağanoğlu [8], akciğer BT görüntülerinden çeşitli sınıflandırma yöntemlerinin performanslarını olası COVID 19 vakası tespiti için derin öğrenme teknikleri kullanılarak değerlendirildi. En iyi sonuç, %95.18 başarı oranı ile ResNet-50 ve DVM sınıflandırma yöntemleri ile elde edildi. Son zamanlarda, derin öğrenme ile COVID-19 tespiti için radyoloji görüntüleri ile yapılmış çeşitli çalışmalar mevcuttur. Hemdan ve ark. [9], X-ray görüntülerinden COVID-19'u teşhis etmek için derin öğrenme modellerini kullandılar. Çalışmalarında yedi ESA modelinden oluşan bir COVIDX-Net modeli önerdiler. Wang ve Wong [10], çalışmalarında normal, COVID olmayan pnömoni ve COVID-19 sınıflarının olduğu veride COVID19 tespitini, %92.4 başarı veren bir derin model (COVID-Net) ile gerçekleştirdiler. Ioannis ve ark. [11], 224 onaylanmış COVID-19 görüntüsünü kullanarak derin öğrenme modeli geliştirdiler. Modelleri iki ve üç sınıf için sırasıyla %98.75 ve %93.48 başarı oranlarına ulaştı. Narin ve ark. [12], akciğer X-ray görüntülerini kullanarak ResNet50 modeliyle COVID-19 tespitinde % 98 oranında doğruluk elde ettiler. Togacar ve ark. [13], X-ray görüntülerinden Pnömoni tespiti için AlexNet, VGG-16 ve VGG-19 gibi derin öğrenme yöntemleri kullandılar en yüksek %99.41 doğruluk elde ettiler.

Bu çalışmada, yerel ikili örüntü (LBP) tabanlı COVID-19 tespit yönteminin performansını değerlendirmek için X-ray görüntülerini içeren açık erişimli bir veri seti kullanılır. Bu veri kümesinden LBP ile dokusal öznitelikler çıkarılır ve bu öznitelikler ile danışmanlı bir öğrenme gerçekleştirilir. LBP ile çıkarılan özniteliklerden öğrenme işleminin gürbüzlüğünü test etmek için k-en yakın komşu (kNN), Naive Bayes (NB), Yapay Sinir Ağı (YSA) ve Destek Vektör Makinesi (DVM) gibi farklı sınıflandırıcılar kullanılmıştır. Çeşitli performans metrikleri ile sınıflandırıcıların performans değerlendirmeleri yapılarak yöntemin COVID-19 tespitinde başarısı üzerinde durulmuştur. Çalışmanın geri kalanı aşağıdaki şekilde düzenlenmiştir. Bölüm 2'de materyal ve metottan bahsedilmiştir. Bu bölümde, deneysel çalışmada kullanılan veri tabanından ve uygulaması yapılan yöntemin aşamalarından bahsedilmiştir. Bölüm 3'de deneysel çalışmalar, Bölüm 4'de ise çalışmanın tartışma ve sonuçlar kısmına yer verilmiştir.


II. MATERYAL VE METOT

A. Materyal

Bu çalışmada, akciğer X-ray görüntülerini içeren Kaggle popüler veritabanı kullanılmıştır [2], [14]. Bu veri kümesinde 256x256, 1024x768 gibi farklı boyutlarda görüntüler mevcuttur. Şekil 1'de bu veri kümesindeki örnek bir COVID-19, Viral Pnömoni (Zatürre) ve Normal akciğer X-Ray görüntüleri



Şekil 1: Veri kümesindeki örnek COVID-19, Viral Pnömoni (zatürre) ve normal akciğer X-Ray görüntüleri [5], [16].



Şekil 2: Deneysel çalışmaları yapılan veri kümesinin kategorik dağılımı.

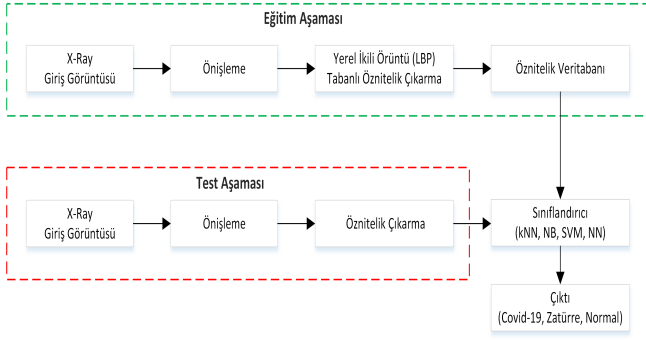
gösterilmiştir. Şekil 2'de veri kümesinin kategorik dağılımında gösterildiği, bu veri içerisinde üç sınıfa ait, 1200 adet COVID-19, 1345 adet Viral Pnömoni ve 1341 adet Normal ve olmak üzere toplam 3886 görüntü bulunmaktadır. Örneğin, verinin %80 eğitim ve %20 test için ayrıldığında kategorik dağılımı Şekil 2'de gösterilmiştir.

B. Metot

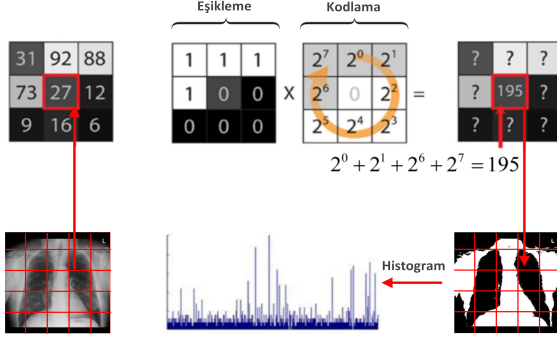
Şekil 3'de görüldüğü gibi bu çalışmada yöntem olarak, birinci aşamada X-Ray görüntüleri ön işleme aşamasından geçirilmiş olup, ikinci aşamada (eğitim aşamasında) LBP ile görüntülerin dokusal öznitelikleri çıkarılmış ve bir öznitelik kümesi oluşturulmuştur. Bu öznitelik kümesi kullanılarak danışmanlı öğrenme gerçekleştirilmiş ve bir sınıflandırıcı kurulmuştur. Bir sonraki aşamada test görüntülerinin bu sınıflandırıcıya sorularak COVID-19 tespiti (tanınması) yapılmıştır.

1) *Önişleme*: Bu aşamada, farklı büyüklük ve boyuttaki (256x256, 1024x1024) X-Ray görüntülerinin ölçeklendirilmesi yapılarak bütün görüntüler 256x256 boyutuna indirgenmiştir. Bu sayede bir sonraki aşamada öznitelik çıkarmada tüm görüntü özniteliklerinin aynı boyutta olması sağlanmıştır. Ayrıca bu aşamada 2D Gauss filtresi ile görüntülerde yumuşatma ve gürültü azaltma işlemi yapılmaktadır.

2) *Öznitelik Çıkarma*: Özellikle viral, bakteriyel zatürre görüntüleri COVID-19 ile benzerdir ve benzer özellikler içermektedir. Dolayısıyla bu görüntülerde saklı bilgilerin doku tanımlayıcıları ile çıkarılması gerekmektedir. Bu aşamada görüntülerin dokusal öznitelikleri yerel ikili örüntü (LBP) tabanlı yöntem ile çıkarılmıştır. Bu çıkarılan öznitelikler, öznitelik veri tabanında saklanmaktadır. Öznitelik çıkarmanın amacı, X-Ray görüntülerinin sağlam ve kararlı bir şekilde ayırt edici belirli özellikleri ve kilit noktalarını çıkarmaktır. LBP öznitelik çıkarımı doku sınıflandırması, yüz tanıma, yüz ifadesi tanıma,



Şekil 3: Yerel ikili örüntü tabanlı Covid-19 tespit yöntemi.



Şekil 4: Yerel ikili örüntü operatörlerinin hesaplanması.

cinsiyet belirleme, yaşın belirlenmesi gibi vb. uygulamalarda kullanılmaktadır [15]. LBP, gri görüntüdeki her pikselin 3x3 komşuluklarını karşılaştırarak ikili kodlar üretmektedir. Her pikselden elde edilen 3x3'lük görüntü dairesel olarak ele alınır ve merkezi piksel eşik değeri olarak kabul edilir. Komşu piksel değeri ile merkez piksel değeri karşılaştırıldığında, komşu pikselin değeri merkez pikselin değerinden büyük veya eşitse ikilik tabanda 1, küçük ise ikilik tabanda 0 olarak kodlanır. Bu şekilde, merkez pikselin LBP kodu, 8 bitlik ikili kod oluşturulup onluk sisteme çevrilerek elde edilmektedir. Yapılan bu işlem Şekil 4'de görüldüğü gibi görüntünün her pikseli için hesaplanır. Bir görüntüdeki köşeler, kenarlar, çizgi bölgeleri, aydınlık veya karanlık bölgeler gibi yerler görüntünün özelliklerine temsil eder. Görüntüye ait bu dokusal özellikler, LBP kodu ile çıkarılabilir. Bu sayede, oluşturulan LBP kodu ile görüntülerin farklı dokusal özelliklerini elde etmek mümkündür [15].

$$LBP(x_i, y_i) = \sum_{n=0}^{n-1} f(g_n - g_i) 2^n \quad (1)$$

$$f(k) = \begin{cases} 1 & \text{eğer } k \geq 0 \\ 0 & \text{eğer } k < 0 \end{cases} \quad (2)$$

Görüntüdeki bir pikselin (x_i, y_i) konumuna bakıldığında LBP, merkez piksel ile onu çevreleyen komşu pikseller arasındaki değerleri karşılaştırır. Şekil 4'de görüldüğü gibi 8 bitlik kod oluşturulup, onluk sisteme çevrildiğinde LBP kodu elde edilir. Görüntüdeki her piksel için komşu pikseller merkez piksele göre eşiklendirilerek ikili kod üretilir. LBP kodlarının üretimi aşağıdaki denklemdeki (1) gibidir. Denklem (1)'de;

(x_i, y_i) merkez pikselin koordinatları, g_i merkez pikselinin gri değerini, g_n ise merkez pikseli çevreleyen 3x3 komşuluktaki piksellerin değerlerini ifade etmektedir. $f(k)$ fonksiyonu gri piksellerin 8 komşuluk değerleridir [15], [16]. Görüntülerin ayırt edici özelliklerini bulmak için bölgesel histogramlar kullanılır. Bu aşamada X-Ray görüntüsü 8x8=64 dikdörtgenel bölgeye ayrılıp, her bölge için LBP kodları ayrı ayrı hesaplanıp histogramlar elde edilmiştir. Veri setindeki her bir görüntü için 3776 boyutunda bir öznitelik vektörü elde edilir. Elde edilen bu histogramlar birbirlerine uç uca eklenip öznitelik vektörü olarak sınıflandırıcıya verilir.

3) *Sınıflandırma*: Son ve gerçek tespit işlemi öznitelik eşleştirme işlemidir. Öznitelik çıkarma adımından elde edilen öznitelik vektörü, veritabanında önceden saklanan X-Ray görüntülerin sınıflarıyla karşılaştırılır. Bu işlem için farklı tipte danışmanlı öğrenme yöntemleri vardır. Bu çalışmada bu yöntemlerden, kNN, NB, DVM ve YSA (3 katmanlı basit bir YSA) yöntemleri ile sınıflandırmanın başarısı test edilmiştir.

TABLO I: LBP +DVM YÖNTEMİ İLE İKİ FARKLI DENEYDEN EDİLEN ÖRNEK PERFORMANS DEĞERLENDİRMELERİ

	SE(%)	SP(%)	PR(%)	RE(%)	F1-SC(%)	ACC(%)
Deney1	100	99.27	98.27	100	99.13	99.48
Deney2	98.86	99.39	98.58	98.86	98.72	99.23

TABLO II: LBP+DVM İLE DENEY-1 İÇİN ÖRNEK BİR HATA (CONFUSION) MATRİSİ

Gerçek	Tahmin		
	1-COVID	2-Viral	3-Normal
1-COVID	228	0	0
2-Viral	0	266	3
3-Normal	0	1	279

TABLO III: LBP+DVM İLE DENEY-2 İÇİN ÖRNEK BİR HATA (CONFUSION) MATRİSİ

Gerçek	Tahmin		
	1-COVID	2-Viral	3-Normal
1-COVID	347	2	2
2-Viral	0	390	1
3-Normal	0	4	420

III. DENEYSSEL ÇALIŞMALAR

Bu çalışmada, deneysel çalışmanın yapıldığı masaüstü bilgisayar, Intel (R) Core (TM) i7 3630QM CPU @ 2.40 GHz işlemcili, 4 GB NVIDIA GeForce 650 M ekran kartlı ve 16GB birincil belleğe sahiptir. Bu aşamada sonuçların daha istikrarlı olabilmesi için veriler farklı büyüklükte bölünerek iki tür deney yapıldı. Birinci deneysel çalışmada veriler (Deney1), %80 eğitim ve %20 test için ayrılmıştır. İkinci deneysel çalışmada veriler (Deney2), %70 eğitim ve %30 test için ayrılmıştır. Aşağıda her iki deneye yönelik performans değerlendirmelerine yer verilmiştir. Deneysel çalışmalarda sınıflandırıcıların başarı değerlendirmesi literatürde yaygın olarak kullanılan performans metrikleri [17] ile yapılmıştır.

TABLE IV: YÖNTEMİN DENEY-1 İÇİN FARKLI SINIFLANDIRICILAR İLE ELDE EDİLMİŞ ORTALAMA PERFORMANS DEĞERLENDİRMELERİ

	SE(%)	SP(%)	PR(%)	RE(%)	F1-SC(%)	ACC(%)
kNN	88.95	96.92	92.94	89.95	94.41	94.76
NB	100	93.90	88.13	100	93.68	95.80
YSA	99.20	97.54	94.70	99.20	96.88	98.04
DVM	99.42	99.33	98.52	99.42	98.97	99.36

TABLE V: YÖNTEMİN DENEY-2 İÇİN FARKLI SINIFLANDIRICILAR İLE ELDE EDİLMİŞ ORTALAMA PERFORMANS DEĞERLENDİRMELERİ

	SE(%)	SP(%)	PR(%)	RE(%)	F1-SC(%)	ACC(%)
kNN	91.56	96.83	92.92	91.56	92.23	95.19
NB	100	93.19	86.96	100	93.02	95.32
YSA	98.93	97.47	94.74	98.93	96.78	97.93
DVM	99.30	99.27	98.36	99.30	98.83	99.28

Performans metrikleri hata matrislerinden çıkarılan [18]; hassaslık (Sensitivity-SE), belirleyicilik (Specificity-SP), kesinlik (Precision-PR), duyarlılık (Recall-RE), F1-Skoru (F1-SC) ve doğruluk (Accuracy-ACC)'dir. Bu çalışmada, bu değerler 0-100 arasına ölçeklendirilmiştir. Tablo 1'de her iki deney için, LBP+DVM yöntemi ile yapılmış örnek bir performans değerlendirilmesi gösterilmiştir. Her iki deneyde de bu yöntem ile %99 üzerine bir başarı elde edilmiştir. Bu deneylere ait örnek hata (confusion) matrislerine Tablo 2 ve Tablo 3'de yer verilmiştir. Bu hata matrisleri ile farklı yöntemlerin performans değerlendirmeleri yapılmıştır. Bu çalışmada ayrıca, LBP ile elde edilen özneteliklerin farklı sınıflandırıcılar ile danışmanlı öğrenme işlemi gerçekleştirilmektedir. Bu sınıflandırıcıların performans değerlendirmesini daha kararlı yapabilmek için, farklı sınıflandırıcılar farklı rastgele eğitim ve test kümeleri ile 10 kez çalıştırılmıştır. Bir başka ifade ile örneğin Tablo 4'de verildiği gibi LBP+DVM yöntemi Deney1 kapsamında rastgele farklı test ve eğitim kümeleri üzerinde 10 defa çalıştırılmış ve ortalama sonuçları kaydedilmiştir. Benzer şekilde Tablo 5'de tüm sınıflandırıcılar Deney2 kapsamında rastgele farklı test ve eğitim kümeleri üzerinde 10 defa çalıştırılmış ve her bir metrik için ortalama sonuçları kayıt altına alınmıştır. Her iki tabloda da görüldüğü gibi, en düşük doğruluk oranı yaklaşık olarak %95 ile LBP+kNN'den ve en yüksek ise yaklaşık olarak %99 ile LBP+DVM'den elde edilmiştir.

IV. TARTIŞMA VE SONUÇ

X-ray görüntüleme COVID-19'un erken teşhisinde kolay erişilebilir alternatif bir araçtır. Akciğer X-ray görüntüleri şüpheli vakaların erken taranmasına yardımcı olur, ancak COVID-19, viral zatürre, bakteriyel zatürre gibi çeşitli akciğer hastalıkları birbirine benzeyebilir ve bu görüntüler birbirinden ayırt edilemeyebilir. Bu anlamda, COVID-19 semptomlarının viral pnömoniye benzer olması, yanlış tanıları yol açabilmektedir. Bu çalışmada, yerel ikili örüntü (LBP) tabanlı COVID-19 tespit yöntemi üzerine çalışılmıştır. LBP ile dokusal öznetelikler çıkarılmış ve bu öznetelikler ile danışmanlı öğrenme gerçekleştirilmiştir. X-ray görüntülerinden elde edilen dokusal özneteliklere göre kNN, Naive Bayes, YSA ve DVM gibi farklı danışmanlı öğrenme teknikleri ile eğitim işlemi yapılmıştır.

Farklı türde ve boyutta yapılan deneysel çalışmalar ile bu tekniklerin performans değerlendirilmesi yapılmıştır. Bu değerlendirmelere göre, en düşük doğruluk oranı yaklaşık olarak %95 ile LBP+kNN'den en yüksek ise yaklaşık olarak %99 ile LBP+DVM'den elde edilmiştir. İleri çalışmalarda diğer makine ve derin öğrenme tabanlı yaklaşımlar ve daha fazla veri üzerinde çalışmalar gerçekleştirilecek ve karşılaştırmalar yapılacaktır.

KAYNAKLAR

- [1] Organization W. H., "Global COVID-19 report," September 27, 2020.
- [2] Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahub, Z. B., ...& Islam, M. T., "Can AI help in screening viral and COVID-19 pneumonia?", IEEE Access, 8, 132665-132676, 2020.
- [3] Ouchicha, C., Ammor, O., & Meknassi, M., "CVDNet: A novel deep learning architecture for detection of coronavirus (Covid-19) from chest x-ray images". Chaos, Solitons & Fractals, 140, 110245, 2020.
- [4] Sogancioglu, E., Çallı, E., van Ginneken, B., van Leeuwen, K. G., & Murphy, K., "Deep Learning for Chest X-ray Analysis: A Survey", arXiv preprint arXiv:2103.08700, 2021.
- [5] Sethy, P. K., Behera, S. K., Ratha, P. K., & Biswas, P., "Detection of coronavirus disease (COVID-19) based on deep features and support vector machine", Preprints 2020, 2020.
- [6] Chen, Y., "Covid-19 Classification Based on Gray-Level Co-occurrence Matrix and Support Vector Machine", In COVID-19: Prediction, Decision-Making, and its Impacts, pp. 47-55, Springer, Singapore, 2020.
- [7] Sousa, R. T., Marques, O., Soares, F. A. A., Sene Jr, I. L., de Oliveira, L. L., & Spoto, E. S., Comparative performance analysis of machine learning classifiers in detection of childhood pneumonia using chest radiographs. Procedia Computer Science, 18, 2579-2582, 2013.
- [8] Oğuz, Ç. & Yağanoğlu, M., "Determination of Covid-19 Possible Cases by Using Deep Learning Techniques", Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 7-17, 2021.
- [9] Hemdan, E.E.D., Shouman, M.A., & Karar, M.E., "Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images", arXiv preprint arXiv:2003.11055, 2020.
- [10] Wang, L., Lin, Z.Q., & Wong, A., "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images", Scientific Reports, 10(1), 1-12, 2020.
- [11] Apostolopoulos, I.D., & Mpesiana, T.A., "Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks", Physical and Engineering Sciences in Medicine, 43(2), 635-640, 2020.
- [12] Narin, A., Kaya, C., & Pamuk, Z., "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks", arXiv preprint arXiv:2003.10849, 2020.
- [13] Toğaçar, M., Ergen, B., Cömert, Z., & Özyurt, F., "A deep feature learning model for pneumonia detection applying a combination of mRMR feature selection and machine learning models", Irbm, 41(4), 212-222, 2020.
- [14] T. R. Muhammad E. H. Chowdhury, Amith Khandakar, Rashid Mazhar, Muhammad Abdul Kadir, Zaid Bin Mahub, Khandakar R. Islam, Muhammad Salman Khan, Atif Iqbal, Nasser Al-Emadi, Mamun Bin Ibne Reaz. (2020), "Covid-19 Chest X-Ray Database", Available: <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- [15] Erol, Ş., "Yüz Bölgelerinin Ağırlıklandırılmasının Yerel İkili Örüntüler İle Yüz Tanıma Performansına Etkisi", Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü Enerji Sistemleri Mühendisliği Ana Bilim Dalı, Bilecik Şeyh Edebali Üniversitesi, 2019.
- [16] Kurt, B., Nabiye, V., & Bekiroğlu, Y., "Yüz İfadelerinin Tanınması", Elektrik-Elektronik-Bilgisayar Mühendisliği, 12, 2007.
- [17] Erdem, E., Bozkurt, F., "A comparison of various supervised machine learning techniques for prostate cancer prediction", Avrupa Bilim ve Teknoloji Dergisi, (21), 610-620, 2021.
- [18] Önal, M.K., Avci, E., Özyurt, F., & Orhan, A., "Classification of Minerals Using Machine Learning Methods", 2020 28th Signal Processing and Communications Applications Conference (SIU), Gaziantep, Turkey, pp. 1-4, 2020.