

X-RAY GÖRÜNTÜLERİNİ KULLANARAK GLCM VE DERİN ÖZNETELİKLERİN BİRLEŞİMİNE DAYALI COVID-19 SINIFLANDIRILMASI

Classification of Covid-19 Based on a Combination of GLCM and Deep Features by Using X-Ray Images

Tolga HAYIT¹  Gökalp ÇINARER² 
^{1,2}Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Yozgat

Geliş Tarihi / Received: 27.10.2021

Kabul Tarihi / Accepted: 18.02.2022

ÖZ

Koronavirüs salgınının (Covid-19) tüm dünyayı etkisi altına alması ile Covid-19 gibi viral hastalıklar için acil ancak doğru ve hızlı teşhis yöntemlerine ihtiyaç duyulmuştur. Covid-19'un ortaya çıkması ile birlikte Covid-19'un tespit edilmesi için tıp doktorları tarafından akciğer tomografi ve X-Ray görüntüleri kullanılmaya başlanmıştır. Geleneksel ve modern makine öğrenimi yaklaşımlarının X-Ray ve tomografi görüntüleri kullanılarak hastalık teşhisi için kullanıldığı bilinmektedir. Bu yönü ile yapay zekaya dayalı uygulamalar alan uzmanlarına benzer ve hatta neredeyse daha iyi performanslar ortaya koyarak sektöre katkı sağlamaktadır. Bu çalışmada X-Ray akciğer görüntüleri kullanılarak hastalık teşhisi için derin ve geleneksel doku analizi özneteliklerinin kombinasyonuna dayalı hibrit bir destek vektör makineleri (SVM) sınıflandırma modeli önerilmektedir. Çalışmada kullanılan veri seti, sağlıklı, Covid-19, viral pnömoni ve akciğer opasitesi hastalarının X-Ray akciğer görüntülerinden oluşmaktadır. X-Ray görüntülerinden elde edilen hibrit öznetelikler Gri Seviye Eş-Oluşum Matrisi (GLCM) ve DenseNet-201 derin sinir ağı kullanılarak elde edilmiştir. Hibrit özneteliklerin performansı, geleneksel bir yaklaşım olarak GLCM öznetelikleri ile karşılaştırılmıştır. Her iki öznetelik SVM ile eğitilmiştir. Sınıflandırma başarısında ortalama %99.2 doğruluk değerine ulaşılmıştır. Elde edilen diğer performans ölçütleri de hibrit özneteliklerin geleneksel yöntemle göre daha başarılı olduğunu göstermektedir. Covid-19 teşhisi için önerilen yapay zekâ tabanlı yöntemin umut verici olduğu görülmüştür.

Anahtar kelimeler: Covid-19, Derin öğrenme, Hibrit model, Yapay zekâ.

ABSTRACT

With the coronavirus epidemic (Covid-19) affecting the whole world, urgent but accurate and fast diagnostic methods have been needed for viral diseases such as Covid-19. With the emergence of Covid-19, lung tomography and X-Ray images have been begun to be used by medical doctors to detect Covid-19. It is known that traditional and modern machine learning approaches using X-Ray and tomography images are used for disease diagnosis. In this respect, applications based on artificial intelligence contribute to the sector by showing similar or even better performances to field experts. In this study, for disease diagnosis by using X-Ray lung images, a hybrid support vector machines (SVM) classification model based on the combination of deep and traditional tissue analysis features is proposed. The dataset has been used consists of lung images of healthy, Covid-19, viral pneumonia and lung opacity patients. Hybrid features obtained from X-Ray images have been obtained by using Gray Level Co-occurrence Matrix (GLCM) and DenseNet-201 deep neural network. The performance of hybrid features has been compared to GLCM features as a traditional approach. Both attributes have been trained with SVM. An average of 99.2% accuracy has been achieved in classification success. Other performance measures which have been obtained show that hybrid features are more successful than the traditional method. The proposed artificial intelligence-based method for the diagnosis of Covid-19 has been shown to be promising.

Keywords: Artificial intelligence, Covid-19, Deep learning, Hybrid model.

GİRİŞ

Koronavirüs hastalığı 2019 (Covid-19), şiddetli solunum yolu enfeksiyonuna neden olan SARS-CoV-2 virüsünden kaynaklı bulaşıcı bir hastalıktır (T.C. Sağlık Bakanlığı, 2020). Kayıtlara göre 2019 yılı Aralık ayında Çin'in Vuhan şehrinde ortaya çıkmıştır ve o zamandan bu yana tüm dünyaya yayılmış ve ciddi bir salgına neden olmuştur. İlk aşamalarda Covid-19'un hafif semptomlara neden olduğu bildirilmiştir; ancak sonraki aşamalarda organ yetmezliği gibi ciddi semptomlara neden olabilmektedir (Wu ve McGoogan, 2020; Goyal vd., 2020). Ülkelere ve bölgelere göre Covid-19 güncel verileri incelendiğinde hastalığın dünya çapında 4.5 milyondan fazla ölüme neden olduğu görülmektedir (COVID-19 Dashboard by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University (JHU). Bununla birlikte yeni hastalık vakaları hızla artmaya devam etmektedir. Güncel Covid-19 tanı testi gerçek zamanlı reverse-transkripsiyon polimeraz zincir reaksiyonu (real-time reverse-transcription polymerase chain reaction: rRT-PCR) testidir (Durmaz, 2020). rRT-PCR testleri için özel malzeme, ekipman ve personel gereksiniminin yanı sıra testin pozitif sonuçlarının negatif sonuçlara göre daha güvenilir olduğu bildirilmiştir (Durmaz, 2020). Ayrıca tanıyı daha güvenilir hale getirmek için ikinci bir test gerekebilmektedir. Bu nedenle, yeterli personel ve ekipman bulunmayan durumlarda ya da şüpheli vakalarda tanının doğruluğunu desteklemek amacıyla X-Ray gibi radyolojik görüntüleme teknikleri kullanılabilir (Ai vd., 2020).

Son dönemde, sağlık sektöründe hastalık teşhisi için Makine Öğrenmesi (ML: Machine Learning) yaygın olarak kullanılmaktadır (Kareem, Al-Sulaifanie, Hasan, ve Ahmed, 2021). Denetimli ML'de, Destek Vektör Makineleri (SVM: Support Machine Learning), Lojistik Regresyon (LR), Yapay Sinir Ağları (ANN: Artificial Neural Networks) ve Rastgele Ormanlar (RF: Random Forests) gibi iyi bilinen algoritmalar hastaların akciğer X-Ray görüntülerinde Covid-19 tespiti için kullanılmıştır (Tang vd., 2020; Barstugan, Ozkaya, ve Ozturk, 2020; Sethy ve Behera, 2020). Evrişimsel Sinir Ağları (CNN: Convolutional Neural Networks), özellikle görüntülerden nesne tanımlama görevlerinde yaygın olarak kullanılan lider bir Derin Öğrenme (DL: Deep Learning) algoritmasıdır. CNN'nin, bir dizi evrişim, havuzlama ve bağlantılı katmanlardan oluşan bir mimarisi bulunmaktadır. Sağlık sektöründe yer alan son çalışmalar (Apostolopoulos ve Mpesiana, 2020; El Asnaoui, Chawki ve Idri, 2021; Ozturk vd., 2020; Mahmud, Rahman ve Fattah, 2020; Hall, Paul, Goldgof ve Goldgof, 2020), Covid-19'un görüntülerden teşhis edilmesi için CNN'nin kullanılabilirliğini kanıtlamaktadır.

DL'ye dayalı çalışmalarda CNN modelinin eğitim ve sınıflama için kullanılması iyi bir donanım gerektirmesinin yanı sıra ciddi zaman kaybına da neden olabilmektedir. Bu hususlar doğrultusunda özellik çıkarımında CNN kullanılarak, sınıflamada SVM gibi geleneksel sınıflandırıcıların tercih edilmesi belirli görevler doğrultusunda araştırmacılara avantajlar sunabilmektedir. Son yıllarda farklı sınıflandırma görevleri için doku ve derin özniteliklerin birleşimine dayalı hibrit özniteliklerin standart yöntemlere göre daha başarılı olduğunu ortaya koyan araştırmalar bulunmaktadır (Jia ve Meng, 2017; Zhang, Xia, Xie, Fulham ve Feng, 2017; Wei, Su, Wang, Li, Zou ve Gao, 2019; Ali, Hardie, De Silva ve Kebede, 2019; Hasan, Jalab, Meziane, Kahtan ve Al-Ahmad, 2019; Nanni, De Luca, Facin ve Maguolo, 2020; Luz, Oliveira, Araujo ve Magalhães, 2021; Naz vd., 2021). Bu çalışmalar geleneksel doku ve derin öznitelikleri bir araya getiren başarılı sınıflandırma çalışmalarından oluşmaktadır. Çalışmalarda gerçekleştirilen performans testleri, birleştirilmiş yöntemlerin doğrulama başarısını artırdığını kanıtlamaktadır.

ML ve DL alanlarında yapılan çalışmaların elde ettiği başarılı sonuçlar çalışma için motivasyon kaynağıdır. Bununla birlikte doğru ve kaliteli bir CNN modeli için öncelikle nitelikli bir veri setine ihtiyaç bulunmaktadır. Bu doğrultuda sınırlı veri miktarı ve yetersiz açık erişimli veri setleri CNN'nin eğitimi için sınırlayıcı etmenlerden bazılarıdır.


Bu çalışmada X-Ray görüntülerinden Covid-19 teşhisi görevi için geleneksel doku öznitelikleriyle derin özniteliklerin birleşimine dayalı hibrit bir model önerilmiştir. Modelin eğitimi için sağlıklı, Covid-19, viral pnömoni ve akciğer opasitesi vakaları görüntülerinden oluşan X-Ray görüntüleri içeren açık erişimli veri setinden faydalanılmıştır. Önerilen hibrit metod için geleneksel öznitelik çıkarımında Gri Seviye Eş-oluşum Matrisi (GLCM: Gray Level Co-occurrence Matrix), derin öznitelik çıkarımında DenseNet-201 önceden eğitilmiş CNN mimarisi kullanılmıştır. Çıkarılan öznitelikler birleştirilerek SVM ile sınıflandırılmıştır. Çalışmanın ayrıca ilgili alanı, Covid-19 tespiti için derin özniteliklerin geleneksel doku özniteliklere göre geleneksel sınıflandırıcı performansında bir fark yaratıp yaratmayacağını belirlenmesidir. Makalenin organizasyonu şu şekildedir: ikinci bölümde kullanılan özellik çıkarım teknikleri ve metodoloji, üçüncü bölümde elde edilen bulgularla karşılaştırmalı performans sonuçları ve son bölümde de çalışmanın nihai sonuçları sunulmaktadır.

MATERYAL VE METOT

Veri Seti

Katar ve Dakka Üniversitesi'nden bir grup araştırmacı ekibi tarafından Pakistan ve Malezya'dan Tıp doktorları ile iş birliği içerisinde pozitif Covid-19 vakaları üzerinden bir veri

seti oluşturulmuştur. Oluşturulan veri seti daha sonra sağlıklı (normal), Covid-19, viral pnömoni ve akciğer opasitesi vakaları X-Ray görüntülerinden oluşan dört sınıflı bir veri seti olarak güncellenmiştir. Veri setinde bulunan viral pnömoni ve akciğer opasitesi grubu görüntüleri Covid-19 dışı vakalara ait görüntüleri içermektedir. Nihai veri seti açık erişimli olarak yayınlanmaktadır (Chowdhury, Rahman ve Khandakar, 2021). Bu çalışmada önerilen modelin eğitimi için bu veri seti kullanılmıştır. Veri seti sınıf sayıları Tablo 1 üzerinde; her bir sınıf için örnek X-Ray görüntüsü Şekil 1 üzerinde gösterilmiştir.



Şekil 1. Her Sınıf için Örnek X-Ray Görüntüleri, (a): Normal, (b): Covid-19, (c): Viral Pnömoni, (d): Akciğer Opasitesi

Tablo 1. Açık Erişimli Veri Seti İstatistikleri

Normal	Covid-19	Viral Pnömoni	Akciğer Opasitesi	TOPLAM
10.192	3.616	1.345	6.012	21.165

Açık erişimli veri seti istatistiklerine göre toplam veri sayısı özellikle CNN eğitimi için yeterlidir. Bununla birlikte sınıflar arası tutarsızlığa dikkat çekmek önemlidir. Sınıflar arası dengesizlik ve veri yetersizliği eğitimde aşırı uyum ya da yetersiz uyum gibi sorunlara neden olmaktadır. Bu problemin üstesinden gelebilmek için veri seti döndürme, yatay ve dikey çevirme, parlaklık ve kontrast ayarı gibi iyi bilinen veri artırım teknikleri kullanılarak artırılmıştır. Veri artırım tekniği, araştırmacılara orijinal veri setini etkilemeden veri çeşitliliğinin ve miktarının önemli ölçüde artırılmasını sağlayan bir avantaj sunmaktadır (Ho,

Liang, Chen, Stoica ve Abbeel, 2019). Veri artırımı, büyük sinir ağlarını eğitmek için kırpma, döndürme, yakınlaştırma/uzaklaştırma vb. teknikler kullanılarak gerçekleştirilmektedir. Yapılan araştırmalar, veri geliştirme yönteminin modelin eğitilmesinde olumlu sonuçlar ortaya koyduğunu göstermektedir (Moreno-Barea, Jerez ve Franco, 2020; Tian, Ding, Chen, Luo ve Wang, 2021; Oyelade ve Ezugwu, 2021). Çalışmada veri artırımı ile verilerde çeşitlilik sağlamakla birlikte sınıflarda bulunan görüntü sayıları eşitlenerek sınıflar arası tutarsız veri sorunu da engellenmiştir. Veri artırımı sonrası oluşan veri seti eğitim (%72), doğrulama (%18) ve test (%10) olmak üzere üç gruba ayrılmıştır. Test veri kümesi, eğitimin sağlıklı gerçekleştirildiğinin doğrulanması açısından test amaçlı kullanılmış ve doğrulama başarısıyla karşılaştırılmıştır. Veri artırımıyla birlikte oluşturulan veri kümelerine ilişkin istatistikler Tablo 2 üzerinde gösterilmiştir.

Tablo 2. Nihai Veri Seti İstatistikleri

	Normal	Covid-19	Viral Pnömoni	Akciğer Opasitesi	TOPLAM
Eğitim	7.200	7.200	7.200	7.200	28.800
Doğrulama	1.800	1.800	1.800	1.800	7.200
Test	1.000	1.000	1.000	1.000	4000

Gri Seviye Eş-oluşum Matrisi (GLCM) Öznitelik Çıkarımı

Haralick 1979 yılında GLCM yöntemini önermiştir (Haralick, 1979). GLCM, istatistiksel doku analizi için güçlü bir yöntemdir (Manjunath ve Ma, 1996; Soh ve Tsatsoulis, 1999; Nikoo, Talebi ve Mirzaei, 2011) ve ikinci dereceden özelliklerin istatistiksel ölçümleri kullanılarak görüntü sınıflandırması için kullanılmıştır (Pantic, Dimitrijevic, Nesic ve Petrovic, 2016). GLCM öznitelikleri, bir görüntüde belirli bir mesafe ile ayrılmış iki piksel arasındaki özel ilişki kullanılarak hesaplanır (Yogeshwari ve Thailambal, 2021).

Gri Seviye Eş-Oluşum Matrisi yönteminin etkili bir doku tanımlayıcı olduğu belirtilmiş ve diğer doku analiz yöntemlerine göre daha iyi doğruluk değerine ve hesaplama süresine sahip olduğu belirtilmiştir (De Siqueira, Schwartz, ve Pedrini, 2013).

Çalışmanın geleneksel öznitelik çıkarımı tarafında GLCM yöntemi esas alınmıştır. Özellik çıkarımında GLCM için 22 özellik denklemleri kullanılmıştır (Soh ve Tsatsoulis, 1999; Nikoo vd., 2011; Pantic vd., 2016; Yogeshwari vd., 2021; De Siqueira vd., 2013; Haralick, 1973).

Her bir görüntü için uygulanan GLCM ile doku özellik çıkarımının aşamaları şu şekildedir:

• Çalışmanın derin öznitelik çıkarımı tarafında 224x224 boyutuna sahip giriş görüntüsü kullanıldığından dolayı standartlık oluşturma adına her bir görüntünün boyutu 224x224 olacak şekilde yeniden boyutlandırılmıştır.

• Her bir görüntü için GLCM'ler hesaplanmıştır. Bu aşamada daha önce bahsedilen 22 özelliği sağlayan MATLAB fonksiyonu kullanılmıştır (Uppuluri, 2021). Böylece her bir görüntü için toplamda 22 öznitelik elde edilmiştir.

• Son olarak sınıflandırma süresini azaltmak için her bir veri min-maks normalizasyon yöntemi kullanılarak normalleştirilmiştir.

Tüm bu işlemler sonucunda tüm X-Ray görüntüleri için 40.000 satır ve 22 sütundan oluşan bir matris elde edilmiştir.

Transfer Öğrenimi ve CNN Öznitelik Çıkarımı


Bir DL tekniği olarak transfer öğrenimi, belirli bir alandaki bir görev için büyük ölçekli bir veri kümesi üzerinde önceden eğitilmiş mevcut bir modelin, nispeten daha az etiketlenmiş veri setine sahip benzer bir alandaki başka bir görev için başlangıç aşaması olarak kullanılması durumudur. Sıfırdan eğitilen modellerle karşılaştırıldığında, transfer öğrenme tabanlı modeller daha az eğitim süresine ve daha az veriye ihtiyaç duyar ayrıca daha az maliyet gerektirir (Mohanty, Hughes, ve Salathé, 2016).

Çalışmanın bu aşamasında derin öznitelik çıkarımı için önceden eğitilmiş bir CNN metodu olan DenseNet (Dense Convolutional Network) kullanılmıştır (Huang, Liu, Van Der Maaten, ve Weinberger, 2017). DenseNet görsel nesne tanıma problemleri için yeni DL teknolojilerinden biridir. DenseNet'in DenseNet-121, DenseNet-160 ve DenseNet-201 olmak üzere üç farklı versiyonu bulunmaktadır. Versiyonlarda belirtilen sayılar modellerin ağında bulunan katman sayısını ifade etmektedir.

Wang ve Zhang (2020) tarafından, önceden eğitilmiş popüler CNN modellerin karşılaştırma sonuçlarına dayanarak DenseNet'in diğer modellere göre daha başarılı olduğu bildirilmiştir. Bununla birlikte aynı çalışmada, sınıflandırma görevi için DenseNet-201 modelinin diğer DenseNet modellerinden daha başarılı olduğunu kanıtlamışlardır. Bu nedenle bu çalışmada derin öznitelik çıkarımı için DenseNet-201 tercih edilmiştir.

DenseNet-201, 224x224x3 görüntü giriş boyutuna sahiptir. İlk 224 değeri genişliği, sonraki 224 değeri yüksekliği ve 3 değeri derinliği (renk kanalları sayısını) ifade eder. Çalışmada veri setinden derin öznitelikleri elde etmek için ağın sonunda bulunan tam bağlantılı katmandan önce gelen küresel ortalama havuzlama katmanı "Global Average

Pooling” (GAP) üzerindeki aktivasyonlar kullanılmıştır. GAP, toplamda 1920 özellik sağlamıştır. DenseNet-201’in genel mimarisi Şekil 2 üzerinde gösterilmiştir.



Şekil 2. DenseNet-201 Mimarisi (Wang ve Zhang, 2020) (GAP Katmanı Özellikleri Sağlamaktadır.)

Çalışmada elde edilen CNN ve GLCM öznitelikleri ile birlikte 40.000 görüntü için toplamda 1942 (1920+22) öznitelik elde edilmiştir.

Sınıflandırıcı

Çalışmada, elde edilen birleştirilmiş özniteliklerin performans testi ve karşılaştırması için; Metre ve Ghorpade (2013)’ye göre popüler doku sınıflandırma yöntemleri arasında yer alan Destek Vektör Makineleri (SVM) ML yöntemi tercih edilmiştir. SVM kullanılarak çok sınıflı bir denetimli ML metodu önerilmektedir.

SVM, birçok doku sınıflandırma problemi için yaygın olarak kullanılan bir ML metodudur (Kim, Jung, Park ve Kim, 2002; Vapnik, 2013; Wang vd., 2019; Chakraborty, Paul ve Rahat-uz-Zaman, 2021). Çok sınıflı sınıflandırma problemleri için yararlıdır (Metre ve Ghorpade, 2013; Kim vd., 2002; Vapnik, 2013; Wang vd., 2019; Chakraborty vd., 2021). SVM, yüksek verilerle karşılaşıldığında genelleme yapabilmekte ve doku özellik uzayında optimal bir hiper düzlem oluşturabilmektedir. Çalışmada kullanılan SVM parametreleri Tablo 3 üzerinde gösterilmiştir.

Tablo 3. SVM Sınıflandırıcı Parametreleri

Parametre Adı	Değeri
Kernel	Cubic polynomial
Max. Iteration	30
Optimizer	Bayesian
Multiclass Method	One vs One

Değerlendirme ölçütleri

Çalışmada performans analizinin yapılabilmesi için literatürde de belirtilen belirli ölçütlere ihtiyaç duyulmaktadır. Temelde çok sınıflı bir sınıflandırma problemi ele alındığından dolayı başlıca değerlendirme ölçütlerinin kullanılması yeterlidir. Literatürde bahsedilen X-Ray sınıflandırma çalışmalarının büyük bir çoğunluğu sadece doğruluk

ölçütünü kullanmaktadır. Ancak son çalışmalarda özellikle sınıflandırma problemlerinin performansının belirlenmesinde doğruluk kriterinin tek başına yeterli olmadığı, farklı ölçütlerle başarının desteklenmesinin gereği belirtilmiştir. Bu nedenle çalışma kapsamında daha ayrıntılı ve sağlıklı bir değerlendirmenin yapılabilmesi için doğruluk ölçütünün yanı sıra kesinlik, hassasiyet ve F1 Skor gibi farklı ölçütlerden de yararlanılmıştır.

BULGULAR VE TARTIŞMA

Çalışmada birleşik GLCM ve derin öznitelikler SVM sınıflandırıcısı kullanılarak sınıflandırılmıştır. Çalışmanın amacı noktasında derin özniteliklerin performansa katkısının belirlenebilmesi için sadece GLCM öznitelikler ayrıca sınıflandırılmış ve hibrit modelin performansı ile karşılaştırılmıştır.


Her bir yöntemden elde edilen özniteliklerin sınıflandırılmasına ait ortalama doğruluk oranları Tablo 4 üzerinde gösterilmiştir. Burada, hibrit ve geleneksel modeller arasındaki farklar dikkate alındığında derin özniteliklerin deney sonuçlarına katkısını belirtmek önemlidir.

Tablo 4. Ortalama Doğruluk Oranları (%)

Metot	Doğruluk
Geleneksel Model	76.7
Hibrit Model	99.2

Kullanılan SVM sınıflandırıcısının parametreleri tüm öznitelikler için aynı şekilde uygulanmıştır.

Diğer yandan, sınıflandırıcının her sınıfta nasıl performans gösterdiğini anlamak için karışıklık matrisi kullanılmıştır (Şekil 3). Karışıklık matrisleri, sınıflandırıcının güçlü ve zayıf performans gösterdiği sınıfları belirlemiştir. Satırlar gerçek sınıfları, sütunlar ise tahmin edilen sınıfları göstermektedir. Çapraz hücreler ise her sınıfın ne kadar doğru sınıflandırıldığını göstermektedir. Mavi renkle gösterilen çapraz hücreler, sınıfların ne kadar doğrulukla sınıflandırıldığını belirtmektedir. Satır ve sütun adlarında yer alan rakamlardan 0 “Normal” sınıfı, 1 “Covid-19” sınıfını, 2 “Viral Pnömoni” sınıfını ve 3 “Akciğer Opasitesi” sınıfını temsil etmektedir.



Şekil 3. Karışıklık Matrisleri: Geleneksel Model (a), Hibrit Model (b)

Karışıklık matrislerinde geleneksel modelin performansı hibrit modele karşı gösterilmiştir. Buna göre, CNN özniteliklerinin sisteme dahil edilmesi her sınıf için fark edilir bir performans sağlamıştır.

Bunlara ek olarak geleneksel ve hibrit modelin karışıklık matrisleri aracılığıyla kesinlik, hassasiyet ve F1 skor ölçütleri ortalama olarak hesaplanmıştır. Her yöntemin performansı Tablo 5'te verilmiştir.

Tablo 5. Geleneksel Modele Karşılik Hibrit Modelin Performans Sonuçları

	Kesinlik	Hassasiyet	F1 Skor
Geleneksel Model	0.77	0.76	0.76
Hibrit Model	0.99	0.99	0.99

Önerilen hibrit modelin sınıf bazında başarısının tüm ölçütler için sonuçları Tablo 6 üzerinde gösterilmiştir. Buna göre önerilen model her sınıf için iyi bir performans sergilemiştir.

Tablo 6. Hibrit Modelin Sınıf Bazında Başarısının Tüm Ölçütler İçin Sonuçları

Ölçüt	Normal	Covid-19	Viral Pnömoni	Akciğer Opasitesi	Ortalama
Kesinlik	1.0	0.99	1.0	0.98	0.99
Hassasiyet	0.99	0.99	1.0	0.99	0.99
F1 Skor	0.99	0.99	1.0	0.99	0.99

Önerilen modelin Covid-19 sınıfı ortalama doğruluk başarısı %99.2 olarak hesaplanmıştır. Yani hibrit model oldukça iyi bir başarıyla Covid-19 vakalarını teşhis edebilmiştir.

Ek olarak, hibrit model eğitim sırasında karşılaşmadığı 4000 adet görüntü ile ayrıca test edilmiştir. Test işlemi sonucunda elde edilen doğruluk oranı 0.9917 olarak ölçülmüştür. Bu

oran doğrulama sonucu ile hemen hemen aynı değerde hesaplanmıştır. Dolayısıyla önerilen modelin aşırı uyum ve yetersiz uyum gibi sorunlardan da etkilenmediğini söylemek doğru olacaktır. Hem eğitim hem de test sonuçları, önerilen modelin iyi bir şekilde genelleştirildiğini göstermektedir.

Genel olarak, önerilen hibrit model geleneksel modele göre daha başarılı sonuçlar sergilemiştir. Derin özniteliklerin sınıflandırmada hassasiyet yaratabileceği kanıtlanmıştır. Önerilen model Covid-19 ve diğer sınıflar için iyi bir sınıflandırma başarısı göstermiştir.

SONUÇ VE ÖNERİLER

Bu çalışma, radyolojik görüntülerle Covid-19, viral pnömoni, akciğer opasitesi ve normal vakaların sınıflandırılmasında birleştirilmiş geleneksel ve derin öznitelik yaklaşımının kullanılabilirliğini göstermiştir. Önerilen hibrit modelin performansı geleneksel yaklaşım olarak GLCM tabanlı bağımsız modellerle karşılaştırılmıştır. Tüm performans ölçütleri doğrultusunda, hibrit model, bağımsız geleneksel modeli geride bırakmıştır. Önerilen hibrit model, DenseNet-201 derin öznitelikleri ve geleneksel öznitelikleri birleştirerek %99.2'lik bir doğrulama başarısı elde etmiştir. Bu çalışmanın başarısı doğrultusunda diğer CNN ağları işe koşularak performans değerlendirmelerinin ve karşılaştırmaların yapılması önerilmektedir. Ayrıca geleneksel öznitelik çıkarımı tarafında GLCM dışında farklı hesaplamalar da dikkate alınarak değerlendirme yapılabilir. Sonuç olarak bu çalışmada önerilen model Covid-19 gibi hastalıkların değerlendirilmesinde kullanılacak bir sistem için yazılımın başlangıç aşamasına hizmet etmektedir.

KAYNAKLAR

- 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.
- Ali, R., Hardie, R. C., De Silva, M. S., & Kebede, T. M. (2019). Skin lesion segmentation and classification for ISIC 2018 by combining deep CNN and handcrafted features. *arXiv preprint arXiv:1908.05730*.
- Apostolopoulos, I. D., & Mpesiana, T. A. (2020). 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.
- Barstugan, M., Ozkaya, U., & Ozturk, S. (2020). Coronavirus (covid-19) classification using ct images by machine learning methods. *arXiv preprint arXiv:2003.09424*.
- Chakraborty, S., Paul, S., & Rahat-uz-Zaman, M. (2021, January). Prediction of Apple Leaf Diseases Using Multiclass Support Vector Machine. In *2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)* (pp. 147-151). IEEE.
- Chowdhury, M. E. H., Rahman, T. & Khandakar, A. (2021). COVID-19 Radiography Database. 20 Ocak 2022 tarihinde <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database> adresinden erişildi.

- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., ... & Islam, M. T. (2020). Can AI help in screening viral and COVID-19 pneumonia?. *IEEE Access*, 8, 132665-132676.
- COVID-19 Dashboard by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University (JHU) Eylül 24, 2021, tarihinde <https://gisanddata.maps.arcgis.com/apps/dashboards/bda7594740fd40299423467b48e9ecf6> adresinden erişildi.
- De Siqueira, F. R., Schwartz, W. R., & Pedrini, H. (2013). Multi-scale gray level co-occurrence matrices for texture description. *Neurocomputing*, 120, 336-345.
- Durmaz, B. (2020). COVID-19 Enfeksiyonunda Mikrobiyolojik Tanı. *YIU Sağlık Bil Derg*, 1, 12-17.
- El Asnaoui, K., Chawki, Y., & Idri, A. (2021). Automated methods for detection and classification pneumonia based on x-ray images using deep learning. In *Artificial Intelligence and Blockchain for Future Cybersecurity Applications* (pp. 257-284). Springer, Cham.
- Goyal, P., Choi, J. J., Pinheiro, L. C., Schenck, E. J., Chen, R., Jabri, A., ... & Safford, M. M. (2020). Clinical characteristics of Covid-19 in New York city. *New England Journal of Medicine*, 382(24), 2372-2374.
- Hall, L. O., Paul, R., Goldgof, D. B., & Goldgof, G. M. (2020). Finding covid-19 from chest x-rays using deep learning on a small dataset. *arXiv preprint arXiv:2004.02060*.
- Haralick, R. M. (1979). Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5), 786-804.
- Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- Hasan, A. M., Jalab, H. A., Meziane, F., Kahtan, H., & Al-Ahmad, A. S. (2019). Combining deep and handcrafted image features for MRI brain scan classification. *IEEE Access*, 7, 79959-79967.
- Ho, D., Liang, E., Chen, X., Stoica, I., & Abbeel, P. (2019, May). Population based augmentation: Efficient learning of augmentation policy schedules. In *International Conference on Machine Learning* (pp. 2731-2741). PMLR.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Jia, X., & Meng, M. Q. H. (2017, July). Gastrointestinal bleeding detection in wireless capsule endoscopy images using handcrafted and CNN features. In *2017 39th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 3154-3157). IEEE.
- Kareem, O., Al-Sulaiman, A., Hasan, D. A., & Ahmed, D. M. (2021). Segmenting and Classifying the Brain Tumor from MRI Medical Images Based on Machine Learning Algorithms: A Review. *Asian J. Res. Comput. Sci*, 10, 51-60.
- Kim, K. I., Jung, K., Park, S. H., & Kim, H. J. (2002). Support vector machines for texture classification. *IEEE transactions on pattern analysis and machine intelligence*, 24(11), 1542-1550.
- Luz, J. S., Oliveira, M. C., Araujo, F. H., & Magalhães, D. M. (2021). Ensemble of handcrafted and deep features for urban sound classification. *Applied Acoustics*, 175, 107819.
- Mahmud, T., Rahman, M. A., & Fattah, S. A. (2020). CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization. *Computers in biology and medicine*, 122, 103869.
- Manjunath, B. S., & Ma, W. Y. (1996). Texture features for browsing and retrieval of image data. *IEEE Transactions on pattern analysis and machine intelligence*, 18(8), 837-842.

- Metre, V., & Ghorpade, J. (2013). *An overview of the research on texture based plant leaf classification*. arXiv preprint arXiv:1306.4345.
- Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). *Using deep learning for image-based plant disease detection*. *Frontiers in plant science*, 7, 1419.
- Moreno-Barea, F. J., Jerez, J. M., & Franco, L. (2020). *Improving classification accuracy using data augmentation on small data sets*. *Expert Systems with Applications*, 161, 113696
- Nanni, L., De Luca, E., Facin, M. L., & Maguolo, G. (2020). *Deep Learning and Handcrafted Features for Virus Image Classification*. *Journal of Imaging*, 6(12), 143.
- Naz, J., Sharif, M., Raza, M., Shah, J. H., Yasmin, M., Kadry, S., & Vimal, S. (2021). *Recognizing Gastrointestinal Malignancies on WCE and CCE Images by an Ensemble of Deep and Handcrafted Features with Entropy and PCA Based Features Optimization*. *Neural Processing Letters*, 1-26.
- Nikoo, H., Talebi, H., & Mirzaei, A. (2011, November). *A supervised method for determining displacement of gray level co-occurrence matrix*. In *2011 7th Iranian conference on machine vision and image processing (pp. 1-5)*. IEEE.
- Oyelade, O. N., & Ezugwu, A. E. (2021). *A deep learning model using data augmentation for detection of architectural distortion in whole and patches of images*. *Biomedical Signal Processing and Control*, 65, 102366.
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). *Automated detection of COVID-19 cases using deep neural networks with X-ray images*. *Computers in biology and medicine*, 121, 103792.
- Pantic, I., Dimitrijevic, D., Nesic, D., & Petrovic, D. (2016). *Gray level co-occurrence matrix algorithm as pattern recognition biosensor for oxidopamine-induced changes in lymphocyte chromatin architecture*. *Journal of theoretical biology*, 406, 124-128.
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S. B. A., ... & Chowdhury, M. E. H. (2021). *Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images*. *Computers in biology and medicine*, 132, 104319.
- Sethy, P. K., & Behera, S. K. (2020). *Detection of coronavirus disease (covid-19) based on deep features*.
- Soh, L. K., & Tsatsoulis, C. (1999). *Texture analysis of SAR sea ice imagery using gray level co-occurrence matrices*. *IEEE Transactions on geoscience and remote sensing*, 37(2), 780-795.
- Tang, Z., Zhao, W., Xie, X., Zhong, Z., Shi, F., Liu, J., & Shen, D. (2020). *Severity assessment of coronavirus disease 2019 (COVID-19) using quantitative features from chest CT images*. arXiv preprint arXiv:2003.11988.
- Tian, X., Ding, C. H., Chen, S., Luo, B., & Wang, X. (2021). *Regularization graph convolutional networks with data augmentation*. *Neurocomputing*, 436, 92-102.
- Uppuluri, A. (2021). *GLCM texture features* (<https://www.mathworks.com/matlabcentral/fileexchange/22187-glcm-texture-features>), MATLAB Central File Exchange. Retrieved September 16, 2021.
- Vapnik, V. (2013). *The nature of statistical learning theory*. Springer science & business media.
- Wang, S. H., & Zhang, Y. D. (2020). *DenseNet-201-based deep neural network with composite learning factor and precomputation for multiple sclerosis classification*. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(2s), 1-19.

-
- Wang, Z., Li, M., Wang, H., Jiang, H., Yao, Y., Zhang, H., & Xin, J. (2019). *Breast cancer detection using extreme learning machine based on feature fusion with CNN deep features*. *IEEE Access*, 7, 105146-105158.
- Wei, L., Su, R., Wang, B., Li, X., Zou, Q., & Gao, X. (2019). *Integration of deep feature representations and handcrafted features to improve the prediction of N6-methyladenosine sites*. *Neurocomputing*, 324, 3-9.
- Wu, J., & Hicks, C. (2021). *Breast Cancer Type Classification Using Machine Learning*. *Journal of personalized medicine*, 11(2), 61.
- Wu, Z., & McGoogan, J. M. (2020). *Characteristics of and important lessons from the coronavirus disease 2019 (COVID-19) outbreak in China: summary of a report of 72 314 cases from the Chinese Center for Disease Control and Prevention*. *Jama*, 323(13), 1239-1242.
- Yeni Koronavirüs (SARS-CoV-2) nedir? (n.d.). T.C. Sağlık Bakanlığı. Eylül 24, 2021, tarihinde <https://covid19.saglik.gov.tr/TR-66135/1-yeni-koronavirus-sars-cov-2-nedir.html> adresinden erişildi.
- Yogeshwari, M., & Thailambal, G. (2021). *Automatic feature extraction and detection of plant leaf disease using GLCM features and convolutional neural networks*. *Materials Today: Proceedings*.
- Zhang, J., Xia, Y., Xie, Y., Fulham, M., & Feng, D. D. (2017). *Classification of medical images in the biomedical literature by jointly using deep and handcrafted visual features*. *IEEE journal of biomedical and health informatics*, 22(5), 1521-1530.