



Transfer Öğrenme ve Komşuluk Bileşen Analizine Dayalı Balgam Yayma Mikroskop Görüntüleri Üzerinden Otomatik Tüberküloz Teşhisi

Automated Tuberculosis Diagnosis on Sputum Smear Microscope Images Based on Transfer Learning and Neighborhood Component Analysis

¹Ömer Faruk NASİP , ²Kenan ZENGİN 

¹Tokat Gaziosmanpaşa Üniversitesi, Tıp Fakültesi, 60100, Tokat, Türkiye

²Tokat Gaziosmanpaşa Üniversitesi, Mühendislik ve Mimarlık Fakültesi, 60100, Tokat, Türkiye

¹omerfaruk.nasip@gop.edu.tr, ²kenan.zengin@gop.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received : 10 August 2022

Accepted : 14 September 2022

Keywords:

Tuberculosis, Transfer Learning, Neighborhood Component Analysis, Support Vector Machine

ABSTRACT

Tuberculosis is an infectious disease caused by the Mycobacterium tuberculosis bacterium, which is effective worldwide and can result in death. Examination of the sputum sample taken from the person under the microscope is one of the most common diagnostic methods of the disease. However, this manual process is error-prone and time-consuming. In this study, a model for automatic tuberculosis diagnosis using sputum smear microscope images is proposed. In the model, the features of the data set were obtained with the transfer learning approach using Vgg19, ResNet50 and DenseNet201. After the features are combined, they are weighted with Neighborhood Component Analysis (NCA) and the best ones are selected. The selected features were trained with the Support Vector Machine (SVM), and the performance of the model was calculated using five-fold cross validation. Experimental results yielded 99.03% accuracy, 99.24% precision, 98.81% sensitivity, 99.25% specificity, and 99.02% f1-score.

© 2022 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim : 10 Ağustos 2022

Kabul : 14 Eylül 2022

Anahtar Kelimeler:

Tüberküloz, Transfer Öğrenme, Komşuluk Bileşen Analizi, Destek Vektör Makinesi

ÖZET

Tüberküloz, Mycobacterium tuberculosis bakterisinin neden olduğu, dünya çapında etkili olan ve ölümlü sonuçlanabilen bulaşıcı bir hastalıktır. Kişiden alınan balgam örneğinin mikroskop altında incelenmesi hastalığın en yaygın tanı yöntemlerindedir. Ancak bu manuel işlem hataya açık ve zaman alıcıdır. Bu çalışmada, balgam yayma mikroskop görüntüleri kullanılarak otomatik tüberküloz teşhisi için bir model önerilmiştir. Modelde veri setine ait öznelikler transfer öğrenme yaklaşımı ile Vgg19, ResNet50 ve DenseNet201 kullanılarak elde edilmiştir. Öznelikler birleştirildikten sonra Komşuluk Bileşen Analizi (KBA) ile ağırlıklandırılıp en iyi olanları seçilmiştir. Seçilen öznelikler Destek Vektör Makinesi (DVM) ile eğitilmiş, modelin performansı beş kat çapraz doğrulama kullanılarak hesaplanmıştır. Deneysel sonuçlarda %99.03 doğruluk, %99.24 kesinlik, %98.81 duyarlılık, %99.25 özgüllük ve %99.02 f1-skoru elde edilmiştir.

© 2022 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Tüberküloz, çoğunlukla akciğerleri etkileyen ciddi bulaşıcı bir hastalıktır. Hastalığa Mycobacterium tuberculosis adı verilen bir bakteri türü neden olur. Hastalık havada yayılır ve bir kişinin enfekte olması için sadece birkaç mikrobu soluması yeterlidir. Dünyada her yıl yaklaşık 10 milyon kişiye tüberküloz teşhisi konulmaktadır. Önlenemez ve tedavi edilebilir bir hastalık olmasına rağmen tüberküloz nedeniyle her yıl 1,5 milyon kişi hayatını kaybetmektedir. Bu ölüm oranı, tüberkülozun dünyadaki en ölümcül bulaşıcı hastalık olduğunu göstermektedir. Hastalık teşhisi konulan kişilerin çoğu düşük ve orta gelirli ülkelerde yaşasa da, tüberküloz dünyanın diğer ülkelerinde de görülmektedir [1]. Hastalığın teşhisi için akciğer röntgen görüntüsü, balgam yayması, kan testi, interferon gamma salınım testi, deri testi gibi testler kullanılmaktadır. En yaygın kullanılan test mikroskopik balgam yayma testidir. Bu manuel teşhis yöntemi, uzman bilgisi, zaman ve maliyet gerektirir. Ayrıca 1-10 µm boyutundaki hastalık bakterisini görüntü üzerinde çıplak gözle tespit etmek oldukça zor ve hataya açıktır [2]. Erken teşhis süresinin hastalığın seyri için önemli olduğu ve uzman sayısının yeterli olamadığı durumlar göz önüne alındığında bilgisayar destekli otomatik sistemlerin iyi bir alternatif olduğu söylenebilir [3].

Gelişen yazılım ve donanım teknolojisi ile birlikte bilgisayarlar güncel sınıflandırma problemlerinde aktif rol oynamaktadır. Makine öğrenmesi teknikleri yardımıyla yapılan sınıflandırma işlemi, manuel yöntemlere göre daha hızlı ve başarılı sonuçlar vermesine rağmen bazı dezavantajları bulunmaktadır. Örnekler için özneliklerin çıkarılmasında insan müdahalesine duyulan ihtiyaç ve büyük veri setleri için sınırlı performans sergilemesi bunlardan bazılarıdır [4]. Derin öğrenme, veri işleme yöntemlerinde biyolojik sinir ağı yapısından esinlenerek yapay sinir ağları olarak bilinen algoritmaları kullanır. Derin öğrenmede makine öğrenmesinden farklı olarak çok katmanlı sinir ağı yapısı bulunur. Öznitelikler, derin sinir ağları tarafından otomatik olarak çıkarılır. Binlerce kategori ve milyonlarca görüntü içeren veri setleri ile eğitilip test edilmiş önceden eğitilmiş derin sinir ağları, hiyerarşik öznelik çıkarma yetenekleri sayesinde başarılı sonuçlar vermektedir. Özellikle, evrimsel derin sinir ağları, nesne algılama, örüntü tanıma, segmentasyon ve sınıflandırma problemleri gibi çeşitli görüntü işleme görevlerinde kullanılmaktadır [5, 6].

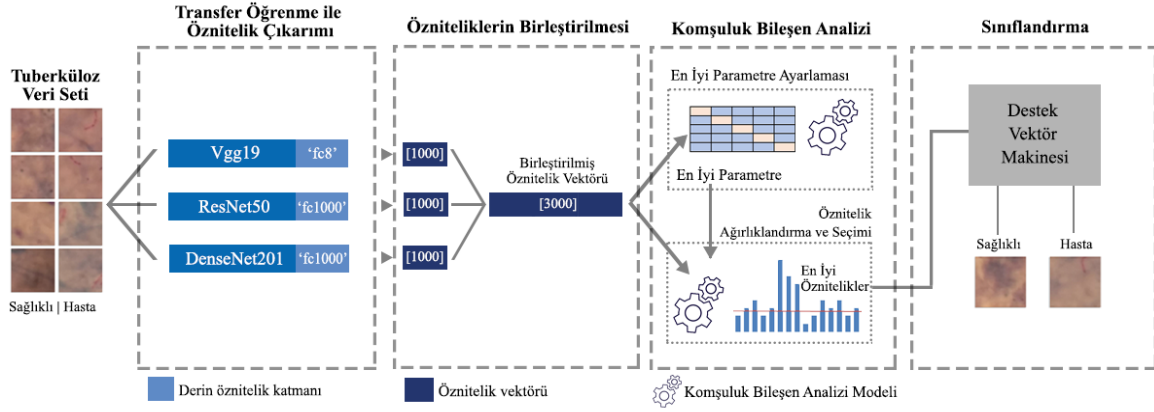
Literatürde tüberküloz teşhisi için balgam yayma mikroskop görüntüleriyle yapılan çalışmalar incelendiğinde Arisgraha ve arkadaşları (2015), mikroskop görüntülerini Mycobacterium bakterisi içeren ve içermeyen şeklinde iki ayrı sınıfa ayırmışlardır. Görüntüleri eğitip sınıflandırma amacıyla bir sinir ağı önermişlerdir. Eğitim ve test işlemi için bir uygulama geliştirmişlerdir [7]. Priya ve Srinivasan (2016), mikroskop görüntüsündeki nesnelere sınırlarını Fourier tanımlayıcısı ile tanımlamışlardır. Seçilen nesnelere destek vektörü ve geriye yayılım sinir ağı kullanarak eğitip test etmişlerdir. Çalışma sonucunda destek vektörü sinir ağı ile daha başarılı sonuçlar elde ettiklerini bildirmişlerdir [8]. Panicker ve arkadaşları (2018), mikroskop görüntülerini bakteri içeren (enfekte) ve bakteri içermeyen (sağlıklı) olarak iki sınıfa ayırmıştır. Elde ettikleri veri setini önerdikleri konvolüsyonel sinir ağı ile eğiterek sınıflandırmışlardır [2]. Hu ve arkadaşları (2019), mikroskop görüntülerini alt bölümlere ayırarak pozitif ve negatif olmak üzere iki sınıf içeren bir veri seti elde etmiştir. Veri setini InceptionV3, ResNet18 ve DenseNet derin sinir ağları ile eğitmişlerdir. Çalışmalarında InceptionV3 ile daha başarılı sonuçlar elde etmişlerdir [9]. Mithra ve Sam Emmanuel (2019), balgam yayma mikroskop görüntülerine kanal alan eşik segmentasyon tekniği uygulamış ve özneliklerini konum odaklı histogram yöntemi ile çıkarmışlardır. Çıkarılan öznelikler derin inanç ağı kullanılarak sınıflandırılmıştır [10]. Dinesh Jackson Samuel ve Rajesh Kanna (2019), enfekte ve sağlıklı örnekleri içeren veri seti kullanmışlardır. Transfer öğrenme yaklaşımı ile InceptionV3 derin sinir ağı kullanılarak öznelikleri çıkarılan veri seti, DVM ile eğitilip sınıflandırılmıştır [11]. Dinesh Jackson Samuel ve Rajesh Kanna (2020), hasta ve sağlıklı örnekleri içeren veri seti için transfer öğrenme yaklaşımı ile Vgg19 ağını kullanmış çıkarılan öznelikleri DVM ile sınıflandırmışlardır [12]. Rachmad ve arkadaşları (2020), balgam yayma mikroskop görüntülerini bölerek pozitif ve negatif olmak üzere iki sınıfa ayırmıştır. ResNet101 derin sinir ağını kullanarak elde ettikleri öznelikleri DVM, KNN, Naive Bayes ve Karar ağacı sınıflandırıcıları ile eğitip test etmişlerdir. Çalışmada en yüksek başarı DVM kullanılan model ile elde edilmiştir [13]. Ibrahim ve arkadaşları (2021), hasta ve sağlıklı bireylerin mikroskop görüntü veri setini transfer öğrenme yaklaşımı ile eğitip test etmişlerdir. Transfer öğrenme için AlexNet derin sinir ağı tercih edilmiştir [14].

Bu çalışmada balgam yayma mikroskop görüntüleri üzerinden Tüberküloz hastalığının otomatik teşhisi için hibrit bir model önerilmiştir. Önerilen modelde transfer öğrenme, öznelik seçimi ve makine öğrenmesi birlikte kullanılmıştır. Önceden eğitilmiş derin sinir ağları kullanılarak elde edilen öznelikler birleştirilip Komşuluk Bileşen Analizi ile en değerli olanları seçilmiştir. Seçilen öznelikler DVM kullanılarak eğitilmiştir. Beş kat çapraz doğrulama ile test edilen modelin performans değerleri hesaplanmıştır. Elde edilen sonuçlar öznelik seçimi yapılmadan eğitilen modellerle karşılaştırılmış, önerilen modelin hem sınıflandırma hızına hem de sınıflandırma doğruluğuna olumlu katkı sağladığı görülmüştür. Önerilen model klinikte ön tanı ve tanı süreçlerinin hızlandırılmasına yardımcı olacağı için hastalığın teşhisinde zaman ve iş gücünden tasarruf sağlar.

Çalışmanın sonraki bölümünde önerilen modelin aşamaları, kullanılan veri seti ve yöntemlerin ifade edildiği materyal ve metod bölümüne yer verilmiştir. Deneysel sonuçlar ve tartışma bölümünde çalışmada kullanılan performans metrikleri, çalışmada elde edilen ve literatürdeki çalışmalara ait deneysel sonuçlar ifade edilmiştir. Sonuç bölümünde ise çalışma hakkında genel bir değerlendirme yapılmıştır.

2. MATERYAL VE METOT


Çalışmada önerilen model dört aşamadan oluşmaktadır. İlk aşamada, önceden eğitilmiş Vgg19, ResNet50 ve DenseNet201 derin sinir ağları transfer öğrenme yöntemiyle kullanılmıştır. Bu ağların son tam bağlı katmanlarından veri setine ait her biri 1.000 adet öznetelik içeren öznetelik vektörleri elde edilmiştir. İkinci aşamada bu vektörler bir araya getirilerek içerisinde 3.000 adet öznetelik bulunan bir vektör oluşturulmuştur. Üçüncü aşamada en iyi özneteliklerin seçimi ve boyut azaltma amacıyla Komşuluk Bileşen Analizi (KBA) modeli kullanılmıştır. KBA için ilk olarak parametre ayarlaması yapılarak modele en uygun parametreler belirlenmiştir. Sonrasında bu parametrelerin kullanıldığı KBA modeli ile öznetelikler ağırlıklandırılıp en iyi olanları seçilmiştir. Son aşamada, seçilen öznetelikler DVM ile eğitilerek sınıflandırılmıştır. Şekil 1’de önerilen modelin aşamaları ifade edilmektedir.



Şekil 1. Önerilen modelin aşamaları.

2.1. Veri Seti ve Ön İşleme


Çalışmada Kaggle’da bulunan ve erişime açık tüberküloz görüntü veri seti kullanılmıştır [15]. Veri setindeki görüntüler balgam yayma örneklerinin Ziehl–Neelsen boyası ile boyanması ile elde edilmiştir. Veri setinde 1632x1224 piksel çözünürlüğe sahip 1.265 adet mikroskopik balgam yayma görüntüsü bulunmaktadır. Bu görüntüler, çalışmada kullanılan derin sinir ağlarının giriş boyutu olan 224x224 piksel görüntülere bölünmüştür. Bu şekilde 2.265 bakteri içeren (hasta) ve 2.265 bakteri içermeyen (sağlıklı) olmak üzere iki sınıfa ait toplam 4.530 mikroskop görüntüsü bulunan bir veri seti oluşturulmuştur. Şekil 2’de orijinal görüntü ve bu görüntüden elde edilerek çalışmada kullanılan görüntüler ifade edilmiştir.



Şekil 2. a. Orijinal görüntü b. Hasta örnek c. Sağlıklı örnek.

2.2. Transfer Öğrenme

Veri setini temsil eden öznetelikler, sınıflandırma işlemi için büyük önem arz etmektedir. Öznetelikler başarılı olarak ifade edilirse sınıflandırma işlemi de aynı derecede başarılı olur. Evrişimli Sinir Ağları (ESA), derin öğrenmenin en yaygın kullanılan mimarisidir. Genellikle görüntü ve video işleme amacıyla kullanılan ESA iki bölüme ayrılmaktadır. Birinci bölümde veri setine ait özneteliklerinin çıkarıldığı katmanlar bulunurken ikinci bölümde ise sınıflandırma işleminin gerçekleştiği katmanlar yer almaktadır. Şekil 3’te ESA mimarisinin genel görünümü görsel olarak ifade edilmiştir.



Şekil 3. ESA mimarisinin genel görünümü [16].

Önceden eğitilmiş evrişimli derin sinir ağları, ImageNet gibi farklı kategorilerde binlerce sınıf ve milyonlarca görüntü içeren veri setleri ile eğitilmiş ve başarılı sonuçlar elde edilmiş ağlardır. Bu ağlar yeni problemlerin çözümünde kullanılabilir. Çünkü modeldeki katman yapısı ve parametreler öznetelik çıkarma yeteneği açısından oldukça başarılıdır [17, 18]. Önceden eğitilmiş derin sinir ağlarının yeni bir görev için kullanımına transfer öğrenme denir. Derin sinir ağının ilk katmanlarında veri setini temsil eden genel öznetelikler (sığ öznetelikler) elde edilirken, son katmanlarda ayırt edici öznetelikler (derin öznetelikler) elde edilir. Bu çalışmada, transfer öğrenme yaklaşımı ile veri setine ait öznetelikleri elde etmek için Vgg19, ResNet50 ve DenseNet201 derin sinir ağı tercih edilmiştir [19-21]. Tablo 1’de bu ağlara ait girdi görüntü boyutu, derinlik, katman sayısı, içerdiği toplam parametre sayısı ve özneteliklerin elde edildiği katmanlar ifade edilmiştir.

Tablo 1. Çalışmada kullanılan önceden eğitilmiş derin sinir ağlarının özellikleri.

Derin Sinir Ağı	Girdi Boyutu	Derinlik	Katman Sayısı	Parametre Sayısı (milyon)	Öznetelik Elde Edilen Katman
Vgg19	224x224	19	47	144	'fc8'
ResNet50	224x224	50	177	25.6	'fc1000'
DenseNet201	224x224	201	708	20	'fc1000'

2.3. Komşuluk Bileşen Analizi

Öznetelik seçimi, veri setinin tüm özneteliklerini içeren öznetelik vektöründen en iyi temsile sahip alt kümenin seçimi olarak tanımlanır. Nispeten düşük temsili olan özneteliklerin çıkarılması ile veri boyutu küçülür, hesaplama karmaşıklığı azalır ve verileri kullanan algoritmaların performansı artar [22]. Öznetelik seçim yöntemleri uzun zamandan beri birçok alanda kullanılmaktadır. Özellikle son yıllarda büyük veri setlerinden elde edilen öznetelik vektörlerinin boyutunun azaltılmasında öznetelik seçimi etkin bir rol oynamaktadır. Öznetelik seçim yöntemleri filtre tabanlı, sarmal tabanlı ve gömülü yöntemler olmak üzere üç ana gruba ayrılır. Filtre tabanlı yöntemlerde öznetelik korelasyonu herhangi bir tahmin modeli olmadan değerlendirilir. Bu yöntemler istatistiksel hesaplama dayanır. Sarmal yöntemlerde öznetelikler üzerinde arama işlemleri yapılarak seçim yapılır. Bu yöntemler tahmine dayalı model içerir. Gömülü yöntemlerde öznetelik seçimi öğrenme modeli kullanılarak yapılır. Bu yöntemler seçim için kendi sınıflandırıcısını barındırırlar [23].

Komşuluk Bileşen Analizi (KBA), parametrik olmayan, mesafeye dayalı öznetelik ağırlıklandırma ve seçim modelidir. Özneteliklerin ağırlıkları Stochastic Gradient Descent (SGD) ve Adaptive Moment Estimation (Adam) gibi optimizasyon algoritmaları kullanılarak hesaplanır. Bu ağırlıkların değeri her zaman pozitifdir. Kullanılan modelin başarısında etkisi olmayan öznetelikler küçük ağırlık değerleri ile ifade edilirken değerli özneteliklere büyük ağırlık değerleri atanır [24]. Özneteliklerin x_i , sınıf etiketinin y_i , örnek sayısını n ve boyutun d olarak belirtildiği bir öznetelik vektörünü $F = \{(x_1, y_1), \dots, (x_n, y_n)\}$ şeklinde ifade edelim. Ağırlık vektörü olan w , Eşitlik 1’de olduğu gibi x_i ve x_j örneği arasındaki $D_w(x_i, x_j)$ ağırlık mesafesi ile ifade edilir:

$$D_w(x_i, x_j) = \sum_{k=1}^d w_k^2 |x_{ik} - x_{jk}| \quad (1)$$

Sınıflandırma referans noktası olarak en yakın komşuyu seçmeye yönelik etkili yaklaşım, bu noktayı olasılık dağılımı ile belirlemektir. x_i örneğinin x_j örneğini referans noktası olarak seçme olasılığı Eşitlik 2’de tanımlanmıştır:

$$p_{ij} = \begin{cases} \frac{K(D_w(x_i, x_j))}{\sum_{k \neq i} K(D_w(x_i, x_k))}, & \text{eğer } i \neq j \\ 0, & \text{eğer } i = j \end{cases} \quad (2)$$

Denklem (1) ve Denklem (2)'den yararlanarak w ağırlık vektörünü hesaplama formülünü Eşitlik 3'teki gibi ifade edebiliriz. Eşitlikteki p_i , i örneğini doğru sınıflandırma olasılığı, w_r r 'nci özneliğin ağırlığı, λ düzenleme parametresidir.

$$w = \arg \max_w \sum_{i=1}^n p_i - \lambda \sum_{r=1}^l w_r^2 \quad (3)$$

Eşitlikteki lambda (λ) parametresi özneliklerin doğru bir şekilde ağırlıklandırılmasında belirleyicidir. Ancak başarılı bir öznelik seçimi için bu parametrenin doğru ayarlanması gerekir. Lambda büyükse, özneliklere atanan ağırlıklar sıfır ya da sıfıra çok yakın değer alacaktır. Bu durum en iyi özneliklerin seçimini zorlaştırmaktadır. Bu değerlerin sıfır olması özneliklere aynı ağırlık değerinin atanacağı anlamına gelir. Bu yüzden en iyi lambda değeri sıfırdan büyük olmak koşuluyla sıfıra çok yakın bir değer olarak ayarlanmalıdır. Çalışmada en iyi lambda değerini belirlemek için ilk olarak eğitim veri setine ait öznelikler beş kat çapraz doğrulama yaklaşımı için beşe bölünüp her katta verilerin 4/5'i eğitim seti ve 1/5'i test seti olarak kullanılacak şekilde ayrıldı. En iyi lambda adayları değerler kullanılan KBA modeli ile her katta eğitildi ve her lambda için ortalama kayıp değerleri hesaplandı. Hesaplamalar sonunda en düşük ortalama kayba karşılık gelen lambda değeri KBA modeli ile öznelik seçimi için en iyi lambda olarak belirlendi. En iyi lambdanın belirlenmesinde kullanılan hiperparametreler Tablo 2'de gösterilmiştir.


Tablo 2. En iyi lambdanın belirlenmesi için kullanılan hiperparametreler.

Hiperparametre	Değer	Kullanılan
FitMethod	average, exact, none	exact
Solver	lbfgs, minibatch-lbfgs, sgd	sgd
IterationLimit	positive integer	10
GradientTolerance	1e-x	1e-6
Standardize	true, false	true
LossFunction	binodeviance, classifcost, classiferror, exponential, hinge, logit, mincost, quadratic	classiferror

En iyi lambda değeri belirlendikten sonra eğitim veri setine ait 3.000 adet özneliğin tamamı bu değer kullanılarak KBA modeli ile işleme alınıp her birine ağırlık değeri atanmıştır. Önerilen modelde sınıflandırma amacıyla ağırlık değeri en büyük 50 öznelik seçilmiştir. Çalışmada hesaplanan en iyi lambda değeri ve ağırlıklandırılan özneliklere ait grafikler deneysel sonuçlar ve tartışma bölümünde ifade edilmiştir.

2.4. Destek Vektör Makinesi

Destek Vektör Makinesi (DVM), çok boyutlu uzayda mümkün olan en iyi sınıflandırma için alanı bölen bir hiperdüzlem bulur. Bu sınıflandırma algoritması, istatistiksel öğrenme teorisine dayanmaktadır. DVM'nin matematiksel algoritmaları, başlangıçta iki sınıflı doğrusal verilerin sınıflandırma problemi için tasarlanmış ve daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir [25, 26]. DVM tarafından üretilen doğrusal ve doğrusal olmayan hiperdüzlemler Şekil 4'te gösterilmektedir.



Şekil 4. a. Doğrusal destek vektör makinesi modeli **b.** Doğrusal olmayan destek vektör makinesi modeli.

Büyük boyutlu veri setlerinde işlem yapabilmek için DVM farklı çekirdek fonksiyonları ile birlikte daha başarılı sonuçlar verebilir. Bu çekirdek fonksiyonlarının en sık kullanılanları lineer, polinomal, sigmoid ve radyal tabanlı çekirdek fonksiyonlarıdır [27]. Bu fonksiyonlar sırasıyla Eşitlik 4, Eşitlik 5, Eşitlik 6 ve Eşitlik 7'de ifade edilmektedir.

$$f_{\text{lineer}}(x_i, x_j) = x_i^T x_j \quad (4)$$

$$f_{\text{polinomal}}(x_i, x_j) = (\alpha x_i^T x_j + c)^d \quad (5)$$

$$f_{\text{radyal}}(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2) \quad (6)$$

$$f_{\text{sigmoid}}(x_i, x_j) = \tanh(\alpha x_i^T x_j + c) \quad (7)$$

Eşitliklerde α eğim, c sabit terim ve d polinom derecesidir. Bu çalışmada, lineer çekirdek fonksiyonlu DVM kullanılmıştır.

3. DENEYSEL SONUÇLAR VE TARTIŞMA

Çalışmada balgam yayma mikroskop görüntüleri kullanılarak tüberküloz hastalığının otomatik teşhisine yönelik bir model önerilmiştir. Hasta ve sağlıklı sınıfa ait toplam 4.530 görüntüden oluşan veri seti kullanılmıştır. Model performansını değerlendirmek için veri seti beş kat çapraz doğrulama ile eğitim ve test veri seti olarak ayrılmıştır. Her kat için veri setinin 4/5'i eğitim, 1/5'i test için dönüştürümlü olarak kullanılmıştır. Bu sayede veri setinde bulunan tüm görüntüler hem eğitim hem de test veri setinde değerlendirilmiştir. Model performansı hesaplanırken beş kat için ayrı ayrı elde edilen değerlerin ortalaması alınmıştır. Çalışmada Intel(R) Core(TM) i5-8400 CPU @ 2.80GHz (6 CPUs) işlemciye, NVIDIA GeForce GTX 1080 Ti NVIDIA CUDA® Cores ekran kartına ve Windows10 64 Bit İşletim Sistemine sahip bilgisayar kullanılmıştır. Uygulamalar MathWorks tarafından geliştirilen ve sayısal hesaplama yazılımı olan MATLAB kullanılarak gerçekleştirilmiştir [28]. Performans değerlendirmesinde sırasıyla Eşitlik 8, Eşitlik 9, Eşitlik 10, Eşitlik 11, Eşitlik 12'de verilen doğruluk, kesinlik, duyarlılık, özgüllük, F1-skor metrikleri ve ROC eğrisi kullanılmıştır. Eşitliklerde belirtilen TP (Doğru Pozitif) pozitif olan sınıfa pozitif, TN (Doğru Negatif) negatif olan sınıfa negatif, FP (Yanlış Pozitif) pozitif olan sınıfa negatif, FN (Yanlış Negatif) negatif olan sınıfa pozitif olarak tahminde bulunma sayısıdır. Modelin ayırt edicilik performansını ifade eden ROC Eğrisi (Receiver Operating Characteristic) sınıflandırma problemlerinde önemli bir göstergedir. Eğri X ekseninde yanlış pozitif oran (100-özgüllük), Y ekseninde ise doğru pozitif oran (duyarlılık) kullanılarak çizilir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (8)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \times 100 \quad (9)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \times 100 \quad (10)$$

$$\text{Özgüllük} = \frac{TN}{TN + FP} \times 100 \quad (11)$$


$$\text{F1-Skor} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (12)$$

Çalışmada, önceden eğitilmiş üç farklı derin sinir ağının son tam bağlı katmanlarından elde edilen öznetelik vektörlerinin birleştirilmesiyle oluşturulan vektördeki 3.000 öznetelik, KBA kullanılarak ağırlıklandırılmıştır. Ağırlıklandırma işlemi için ilk olarak en düşük ortalama kayıp değerini elde etmeyi sağlayan en iyi lambda değeri belirlenmiştir. Her kat için hesaplanan lambda/kayıp değerleri grafiği ve en iyi lambda değeri kullanılarak ağırlıklandırılmış öznetelikler Şekil 5'te verilmiştir. Hesaplanan en iyi lambda değeri grafiklerde mavi çerçeve içine alınmıştır.

Öznetelik ağırlığı/öznetelik indeksi grafiği ile belirtilen ve 3.000 öznetelik içeren vektördeki özneteliklerden 0-1.000 indeksi arası Vgg19, 1.001-2.000 indeksi arası ResNet50 ve 2.001-3.000 indeksi arası DenseNet201 kullanılarak elde edilmiştir. KBA ile ağırlıklandırılıp seçilen en iyi 50 özneteliğin arasında bu üç ağdan da öznetelik bulunması, kullanılan ağların tümünün modelin performansına katkı sağladığı anlamına gelir. Seçilen öznetelikler DVM ile eğitilip test edilmiştir. Şekil 6'da önerilen model ile beş kat çapraz doğrulama sonucu elde edilen karmaşıklık matrisleri, Tablo 3'de doğruluk, kesinlik, duyarlılık, özgüllük, f1-skor değerleri, Şekil 7'de ise ROC eğrisi ifade edilmiştir.

Tablo 3. Önerilen model ile elde edilen performans değerleri.


Kat	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skor (%)
Kat-1	99.12	99.55	98.68	99.56	99.11
Kat-2	99.78	99.56	100	99.56	99.78
Kat-3	99.89	99.78	100	99.78	99.89
Kat-4	98.23	98.88	97.57	98.9	98.22
Kat-5	98.12	98.43	97.78	98.46	98.1
Ortalama	99.03	99.24	98.81	99.25	99.02



Şekil 5. Lambda/kayıp grafiği ve ağırlıklandırılmış özmitelikler.

Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin		Gerçek	Tahmin	
	Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif		Pozitif	Negatif
Kat-1	447	6	Kat-2	453	0	Kat-3	453	0	Kat-4	442	11	Kat-5	440	10	Toplam	2235	27
	2	451		2	451		1	452		5	448		7	449		17	2251

Şekil 6. Önerilen model ile elde edilen karmaşıklık matrisleri.



Şekil 7. Önerilen model ile elde edilen ROC eğrisi.


Önerilen modeldeki öznetelik seçimi yaklaşımının sınıflandırma başarısına etkisini ifade edebilmek için önceden eğitilmiş derin sinir ağlarının her birinden elde edilen öznetelikler ayrı ayrı ve birleştirilerek kullanılmıştır. Özneteliklerin beş kat çapraz doğrulama kullanılarak DVM ile eğitilip test edilmesi sonrası elde edilen doğruluk, kesinlik, duyarlılık, özgüllük ve f1-skor değerleri Tablo 4'te verilmiştir.

Tablo 4. Öznetelik seçiminin model performansına etkisi.

Öznetelik Vektörü	Öznetelik Sayısı	Doğruluk(%)	Kesinlik(%)	Duyarlılık(%)	Özgüllük(%)	F1-Skor(%)
Vgg19	1000	97.97	98.27	97.66	98.28	97.96
ResNet50	1000	98.23	98.49	97.97	98.5	98.23
DenseNet201	1000	98.41	98.67	98.14	98.68	98.4
Birleştirilen	3000	98.68	98.93	98.41	98.94	98.67
KBA ile Seçilen	50	99.03	99.24	98.81	99.25	99.02

Birleştirilen öznetelikler ile elde edilen sınıflandırma başarısı bu ağların her birinden ayrı ayrı elde edilen özneteliklere göre daha yüksek olsa da, öznetelik sayısının 3 katına çıkması modelin eğitim süresi ve sınıflandırma hızını olumsuz yönde etkilemiştir. Bu nedenle KBA kullanılarak gerçekleştirilen öznetelik seçimi yaklaşımı ile hem bu olumsuz etki ortadan kaldırılmış hem de modelin sınıflandırma başarısı iyileştirilmiştir.

Şekil 8'de DVM ile eğitilen özneteliklere ait ortalama eğitim süreleri ve sınıflandırma hızları verilmiştir. Öznetelik seçimi ile eğitim süresinin Vgg19, ResNet50 ve DenseNet201'den ayrı ayrı elde edilen özneteliklere göre yaklaşık 4 kat, birleştirilmesiyle elde edilen özneteliklere göre yaklaşık 15 kat kısaldığı görülmektedir. Sınıflandırma hızının ise Vgg19, ResNet50 ve DenseNet201'den elde edilen özneteliklere göre yaklaşık 15 kat, birleştirilen özneteliklere göre yaklaşık 60 kat arttığı söylenebilir.



Şekil 8. Öznetelik seçiminin eğitim süresi ve sınıflandırma hızına etkisi.

KBA ile seçilen öznelikler farklı sınıflandırıcılar ile eğitilip test edilmiş ve elde edilen sonuçlar DVM ile karşılaştırılmıştır. Özneliklerin Naive Bayes (NB), K-En Yakın Komşu (KNN), Karar Ağacı (KA), Diskriminant Analizi (DA) ile sınıflandırılması sonrasında elde edilen sonuçlar Tablo 5’de verilmiştir.

Tablo 5. Farklı sınıflandırıcılar ile elde edilen performans değerleri.

Sınıflandırıcı	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1-Skor (%)
NB	95.94	96.24	95.73	96.15	95.98
KNN	98.26	98.71	97.79	98.72	98.25
KA	97.35	97.78	96.92	97.79	97.35
DA	98.17	98.44	97.88	98.46	98.16
DVM	99.03	99.24	98.81	99.25	99.02

Tablo 6’da balgam yayma mikroskop görüntüleri kullanılarak otomatik tüberküloz teşhisi yapılan çalışmalar ile elde edilen deneysel sonuçlar ifade edilmiştir. Çalışmalarda kullanılan veri setleri ve görüntü sayıları farklı olsa da görüntülerin tamamı balgam yayma örneklerinin Ziehl–Neelsen boyası ile boyanması yöntemiyle elde edilmiştir. Kullanılan görüntü sayısı ve sonuçlar dikkate alındığında sunulan çalışmanın kayda değer bir başarı sergilediği söylenebilir.

Tablo 6. Önerilen modelin mevcut çalışmalarla karşılaştırılması.

Çalışma	Yöntem	Görüntü Sayısı	Doğruluk	Kesinlik	Duyarlılık	Özgüllük	F1-Skor
Priya ve Srinivasan (2016)	ÇKA + DVM	1.537	92.5	-	95	90	92.68
Panicker ve ark. (2018)	ESA	1.800	-	-	97.13	78.4	86.76
Hu ve ark. (2019)	InceptionV3	2.630	98.40	-	98.40	98.40	98.40
Mithra ve Emmanuel (2019)	CAT+LoH+ESA	500	97.55	-	97.86	98.23	-
Samuel ve Kanna (2019)	Inception V3+ DVM	1.242	95.05	-	-	-	-
Samuel ve Kanna (2020)	Vgg19+DVM	1.242	86.60	-	-	-	-
Rachmad ve ark. (2020)	ResNet101+ DVM	1.266	96.56	96.96	96.28	-	96.60
Ibrahim ve ark. (2021)	AlexNet	2.464	98.73	-	98.59	98.84	-
Bu Çalışma (2022)	Vgg19+ResNet50+ DenseNet201+ KBA+DVM	4.530	99.03	99.24	98.81	99.25	99.02

4. SONUÇ

Tüberküloz, dünya çapında yaygın olan bakteri kaynaklı bulaşıcı bir hastalıktır. Başta akciğerler olmak üzere birçok organı etkileyebilir. Tedavisi mümkün olmakla birlikte, doğru teşhis konulamadığında ölümlerle sonuçlanabilir. Tanı için en uygun ve etkili yöntemler radyolojik ve mikroskopik görüntülemelerdir. Bu çalışmada, tüberküloz hastalığının otomatik teşhisi için balgam yayma mikroskop görüntülerinin kullanıldığı bir model önerilmiştir. Önerilen modelde, önceden eğitilmiş derin sinir ağlarının öznelik çıkarma yeteneğinden yararlanılmıştır. Elde edilen özneliklerin birleştirilmesi sayesinde veri setinin en iyi özneliklerini içeren öznelik vektörü oluşturulmuştur. Bununla birlikte birleştirilmiş öznelik vektörü, sınıflandırma üzerinde etkisi olmayan gereksiz öznelikleri de içermektedir. Ayrıca öznelik vektör boyutunun büyük olması modelin eğitim süresini ve sınıflandırma hızını da olumsuz etkilemektedir. Birleştirilmiş öznelik vektöründeki öznelik sayısı 3.000 iken, KBA yaklaşımı sonrası öznelik seçimi ile bu sayı 50’ye düşürülmüştür. En iyi özneliklerin seçilmesi modelin eğitim süresi, sınıflandırma hızı ve sınıflandırma başarısına katkı sağlamıştır. Çalışmada elde edilen %99.03 doğruluk, %99.24 kesinlik, %98.81 duyarlılık, %99.25 özgüllük ve %99.02 f1-skor değerleri hastalığın otomatik teşhisi için umut vericidir. Önerilen model, klinikte ön tanı veya kesin tanı sürecinde uzmanlara yardımcı olabilir. Sınıflandırma hızı önemli derecede artırdığı için, model gerçek zamanlı karar destek sistemleri için kullanılabilir. İleriki çalışmalarda önerilen model için gerçek zamanlı teşhise olanak sağlayan bir uygulama geliştirilmesi planlanmaktadır.

Yazar Katkıları

Yazarlar çalışmaya eşit oranlı katkı sunmuştur.

Çıkar Çatışması

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKÇA

- [1] WHO, "Tuberculosis, Overview". (2021). <https://www.who.int/health-topics/tuberculosis> (Erişim Tarihi: Mart 15, 2022).
- [2] R. O. Panicker, K. S. Kalmady, J. Rajan, and M. K. Sabu, "Automatic detection of tuberculosis bacilli from microscopic sputum smear images using deep learning methods", *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 691-699, 2018.
- [3] M. El-Melegy, D. Mohamed, and T. Elmelegy, "Automatic detection of tuberculosis bacilli from microscopic sputum smear images using Faster R-CNN, Transfer Learning and Augmentation", In A. Morales, J. Fierrez, J. Sánchez, and B. Ribeiro (Eds.), *Pattern Recognition and Image Analysis, IbPRIA 2019, Lecture Notes in Computer Science*, pp. 270-278, Springer, Cham, 2019.
- [4] E. Korot, Z. Guan, D. Ferraz, S. K. Wagner, G. Zhang, X. Liu, L. Faes, N. Pontikos, S. G. Finlayson, H. Khalid, G. Moraes, K. Balaskas, A. K. Denniston, and P. A. Keane, "Code-free deep learning for multi-modality medical image classification", *Nature Machine Intelligence*, vol. 3, pp. 288-298, 2021.
- [5] Ö. F. Nasip, and K. Zengin, "Deep learning based bacteria classification", 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT), pp. 1-5, 2018.
- [6] T. Haryanto, I. Wasito, and H. Suhartanto, "Convolutional Neural Network (CNN) for gland images classification", 11th International Conference on Information and Communication Technology and System (ICTS), pp. 55-60, 2017.
- [7] F. C. Arisgraha, P. Widiyanti and R. Apsari, "Digital detection system design of mycobacterium tuberculosis through extraction of sputum image using neural network method", *Indonesian Journal of Tropical and Infectious Disease*, vol. 3, pp. 35-38, 2015.
- [8] E. Priya, and S. Srinivasan, "Automated object and image level classification of TB images using support vector neural network classifier", *Biocybernetics and Biomedical Engineering*, vol. 36, no. 4, pp. 670-678, 2016.
- [9] M. Hu, Y. Liu, Y. Zhang, T. Guan, and Y. He, "Automatic detection of tuberculosis bacilli in sputum smear scans based on subgraph classification", *International Conference on Medical Imaging Physics and Engineering (ICMIPE)*, pp. 1-7, 2019.
- [10] K. S. Mithra, and W. R. Sam Emmanuel, "Automated identification of mycobacterium bacillus from sputum images for tuberculosis diagnosis", *Signal, Image and Video Processing*, vol. 13, pp. 1585-1592, 2019.
- [11] R. Dinesh Jackson Samuel, and B. Rajesh Kanna, "Tuberculosis (TB) detection system using deep neural networks", *Neural Computing and Applications*, vol. 31, pp. 1533-1545, 2019.
- [12] R. Dinesh Jackson Samuel, and B. Rajesh Kanna, "Cybernetic microbial detection system using transfer learning", *Multimedia Tools and Applications*, vol. 79, pp. 5225-5242, 2020.
- [13] A. Rachmad, N. Chamidah, and R. Rulaningtyas, "Mycobacterium tuberculosis images classification based on combining of convolutional neural network and support vector machine", *Communications in Mathematical Biology and Neuroscience*, 85, 2020.
- [14] A. U. Ibrahim, E. Guler, M. Guvenir, K. Suer, S. Serte, and M. Ozsoz, "Automated detection of Mycobacterium tuberculosis using transfer learning", *Journal of Infection in Developing Countries*, vol. 15, no. 5, 678-686, 2021.
- [15] Kaggle. (2022, Apr 15). Tuberculosis Image Dataset [Online]. Available: <https://www.kaggle.com/datasets/saife245/tuberculosis-image-datasets>.
- [16] MathWorks. (2022, Sep 13). Convolutional Neural Network [Online]. Available: <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.
- [17] A. Alem, and S. Kumar, "Transfer learning models for land Cover and land use classification in remote sensing image", *Applied Artificial Intelligence*, vol. 36, no. 1, 2022.
- [18] C. Ammatmanee, and L. Gan, "Transfer learning for hostel image classification", *Data Technologies and Applications*, vol. 56, pp. 44-59, 2022.
- [19] K. Simonyan, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition", *CoRR*, abs/1409.1556, 2015.
- [20] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", *arXiv:1512.03385v1*, 2015.
- [21] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks", *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2261-2269, 2017.
- [22] C. Chen, Y. Tsai, F. Chang, and W. Lin, "Ensemble feature selection in medical datasets: Combining filter, wrapper, and embedded feature selection results", *Expert Systems*, vol. 37, 2020.
- [23] E. Alhenawi, R. Al-Sayyed, A. Hudaib and S. Mirjalili, "Feature selection methods on gene expression microarray data for cancer classification: A systematic review", *Computers in Biology and Medicine*, vol. 140, 2021.
- [24] W. Yang, K. Wang, and W. Zuo, "Neighborhood component feature selection for high-dimensional data", *Journal of Computers*, vol. 7, no. 1, pp. 161-168, 2012.
- [25] L. Wang, D. Johnson, and Y. Lin, "Using EEG to detect driving fatigue based on common spatial pattern and support vector machine", *Turkish Journal*

- of Electrical Engineering and Computer Sciences, vol. 29, no. 3, pp. 1429-1444, 2021.
- [26] M. Azimi-Pour, H. Eskandari-Naddaf and A. Pakzad, "Linear and non-linear SVM prediction for fresh properties and compressive strength of high volume fly ash self-compacting concrete", *Construction and Building Materials*, vol. 230, 2020.
- [27] S. Kilicarslan, K. Adem, and M. Celik, "Diagnosis and classification of cancer using hybrid model based on ReliefF and convolutional neural network", *Medical Hypotheses*, vol. 137, 2020.
- [28] MathWorks Inc. (2021, Oct 15). MATLAB V2021b [Online]. Available: <https://www.mathworks.com/products/matlab.html>.