

## LÖKOSİT TESPİTİ İÇİN BEYAZ KAN HÜCRELERİNİN ESA KULLANILARAK SINIFLANDIRILMASI

**Mücella ÖZBAY KARAKUŞ<sup>1\*</sup>, Erdal ÖZBAY<sup>2</sup>**

<sup>1</sup>Yozgat Bozok Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Yozgat, 66100, Türkiye

<sup>2</sup>Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Elazığ, 23119, Türkiye

Geliş Tarihi/Received Date: 08.02.2022 Kabul Tarihi/Accepted Date: 18.07.2022 DOI: 10.54365/adyumbd.1069856

### ÖZET

Beyaz kan hücreleri, insanların bağışıklık sisteminin en önemli yapısı olup, kan ve lenf dokularında kemik iliği tarafından üretilmektedir. Bu hücreler insan vücudunu hastalık ve yabancı organizmalara karşı koruyan savunma mekanizmalarıdır ve kandaki oranı düştüğünde Lökopeni ile karşılaşılabilir. Bu hücrelerin insan vücudundaki oranının belirlenmesi ve hastalığın tespit ve tedavisi için yoğun emek harcaması gerekmektedir. Bu çalışmada, derin öğrenme modellerini kullanarak beyaz kan hücreleri sınıflandırma performansının iyileştirilmesi amaçlanmıştır. Sınıflandırma işlemi daha verimli gerçekleştirmek için evrişimli sinir ağı modelleri kullanılmıştır. Beyaz kan hücreleri çeşitleri olan eozinofil, lenfosit, monosit ve nötrofil arasında ayırım yapmak için Densenet201, ResNet50 ve Alexnet birleştirilmiştir. Elde edilen özellik haritalarının sınıflandırılması için K-En yakın komşuluk, Destek Vektör Makinesi ve Naïve Bayes olmak üzere üç farklı makine öğrenmesi sınıflandırıcısı kullanılmıştır. Derin Öğrenme (DÖ) ile eğitilen Kaggle veri kümesi görüntülerine CLAHE ve Gauss filtreleri uygulanarak bu görüntüler üç ESA ağı ile yeniden sınıflandırılmıştır. Bu filtreler uygulandıktan sonra elde edilen sonuçların, orijinal verilerle elde edilen sınıflandırma sonuçlardan daha yüksek olduğu ortaya konmuştur.

**Anahtar Kelimeler:** Beyaz kan hücreleri, Derin öğrenme, ESA, Görüntü işleme, Sınıflandırma

## CLASSIFICATION OF WHITE BLOOD CELLS USING CNN FOR THE DETECTION OF LEUCOCYTE

### ABSTRACT

White blood cells are the most important structure of the human immune system and are produced by the bone marrow in the blood and lymph tissues. These cells are the defense mechanisms that protect the human body against diseases and foreign organisms, and Leukopenia may be encountered when the rate in the blood decreases. Intensive effort is required to determine the ratio of these cells in the human body and to detect and treat the disease. In this study, it is aimed to improve the white blood cell classification performance by using deep learning models. Convolutional neural network models are used to perform the classification process more efficiently. Densenet201, ResNet50, and Alexnet were combined to distinguish between the white blood cell variants, eosinophils, lymphocytes, monocytes, and neutrophils. Three different machine learning classifiers, namely K-Nearest Neighborhood, Support Vector Machine and Naïve Bayes, were used to classify the obtained feature maps. By applying CLAHE and Gaussian filters to Kaggle dataset images trained with Deep Learning (DL), these images were reclassified with three CNN networks. It has been revealed that the results obtained after applying these filters are higher than the classification results obtained with the original data.


**Keywords:** White blood cells, Deep learning, CNN, Image processing, Classification

\* e-posta<sup>1</sup> : [mucella.karakus@yobu.edu.tr](mailto:mucella.karakus@yobu.edu.tr) ORCID ID: <https://orcid.org/0000-0003-0599-8802> (Sorumlu Yazar)

e-posta<sup>2</sup> : [erdalozbay@firat.edu.tr](mailto:erdalozbay@firat.edu.tr) ORCID ID: <https://orcid.org/0000-0002-9004-4802>

## 1. Giriş

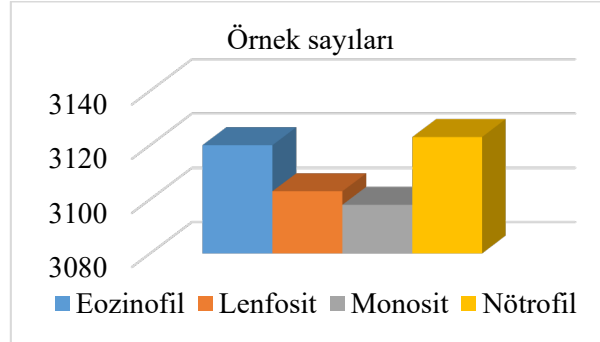
Beyaz Kan Hücreleri (BKH) insan vücudunu yabancı maddelere ve bulaşıcı hastalıklara karşı koruyan ve bunların neden olduğu enfeksiyonlara karşı savaşmasına yardımcı olan en önemli bağışıklık sistemi elemanlarıdır. Lökosit veya akyuvarlar olarak da bilinen beyaz kan hücreleri insan vücudunda bulunan bir kan bileşenidir [1]. Sağlıklı bir bireyin kanında ortalama 4000 ile 10000 arasında BKH bulunmaktadır. Kanın küçük bir bölümünü oluşturan ve bakteri, virüs ve mikroplara karşı savaşan lökositler, vücuda yabancı bir madde girdiğinde hızla çoğalır ve daha sonra damardan ayrılarak ilgili dokuya ulaşırlar [2]. Bu dokulardaki lökosit sayısı, sağlıklı bir kan örneğinden çok daha fazla olmaktadır. Tıpta kan hücreleri içerisinde beyaz kan hücrelerinin varlığı çeşitli hastalık türlerinin göstergesi olarak kabul edilmektedir [3]. Beyaz kan hücreleri, özellikle lösemi, kanser, hemoliz, hormon bozuklukları ve bazı enfeksiyon hastalıkları gibi hastalıkların tanısında bir parametre haline gelmiştir [4]. İnsan vücudundaki BKH'ne bağlı bozukluğunun bazı belirtileri şunlardır; hızlı kilo kaybı, halsizlik, yorgunluk ve buna bağlı olarak kronik enfeksiyonlar oluşabilmekte veya bu durum farklı hastalıkları tetikleyebilmektedir [5]. Bu gibi durumlarda her hastalıkta olduğu gibi BKH'ne bağlı bozuklukların da erken teşhisi hayati önem taşımaktadır. Bu olguların klinik muayenesinde kullanılan en yaygın tanı yöntemi hastaların mikroskopik görüntülerini alarak uzman doktorlar tarafından bu görüntülerin incelenmesidir [6]. Şekil 1'de gösterildiği üzere BKH Eozinofil, Lenfosit, Monosit ve Nötrofil olmak üzere dört farklı sınıfa ayrılmıştır. Farklı tipte BKH mikroskopik görüntüleme kullanılarak tespit edilebilmektedir. Ancak bu durum, BKH'nin tipi ve kandaki oranına bağlı olarak izlenecek prosedür, doktorun tecrübe ve bilgisine bağlıdır [7].



Şekil 1. BKH veri kümesi türleri

Derin öğrenme (DÖ), yapay zekânın en popüler alt dallarından biri haline gelmiştir. DÖ'de kullanılan çok sayıda mimari bulunmaktadır. Büyük veri setlerinin kullanımında özellikle sınıflandırma işleminde başarılı olan DÖ ağları incelenmiştir [8]. Bu çalışmada farklı lökosit türleri olan Eozinofil, Lenfosit, Monosit, Nötrofil sınıflandırılması için ESA modelleri kullanılmıştır. Bu bakımdan, farklı türdeki BKH tiplerinin mikroskopik görüntülerini kullanarak doğru bir şekilde hızlıca tespit edilmesi amaçlanmıştır [9]. Bu yaklaşımda, özellik seçimi önemlidir. DÖ modellerinden elde edilen öznelik setleri üzerinden öznelik seçim yöntemleri kullanılarak daha verimli özneliklerin seçilmesi sağlanmıştır [10]. Özellik çıkarım işlemi için Densenet201, ResNet50 ve Alexnet mimarileri kullanılmıştır. Bu üç mimarinin çıkarmış oldukları özellik haritaları birbirlerinden farklıdır. Bundan dolayı bu 3 mimarinin deneyiminden faydalanılarak elde edilen özellik haritaları birleştirilmiştir. Elde edilen bu özellik haritaları Komşuluk Bileşen Analizi (KBA) boyut indirgeme yöntemi kullanılarak optimize edildikten sonra K-En Yakın Komşuluk (KEK), Destek Vektör Makinesi (DVM) ve Naïve Bayes (NB) olmak üzere üç farklı klasik makine öğrenmesi sınıflandırıcısında sınıflandırılmıştır. Kullanılan veri setindeki her bir sınıfın içerdiği örnek sayıları Eozinofil için 3120, Lenfosit için 3103,

Monosit için 3098 ve Nötrofil için 3123'tür. Bu çalışmada kullanılan veri seti Kaggle platformundan elde edilmiştir ve içerdiği veri sayısı Şekil 2'de grafiksel olarak gösterilmiştir [11].



Şekil 2. BKH veri setinin her bir sınıftaki örnek sayısı

Bu makalenin geri kalanı aşağıdaki gibi organize edilmiştir. Bölüm 2'de BKH çalışmaları ile ilgili literatür taramasına yer verilmiştir. Bölüm 3'te veri seti ve önerilen yöntemler sunulmuştur. Bölüm 4'te deneysel sonuçlar açıklanmıştır. Bölüm 5'te sonuçlara yer verilmiştir.

## 2. İlgili Çalışmalar

Bu bölümde, veri seti, yöntemler ve performans ölçütleri dikkate alınarak BKH sınıflandırılmasına ilişkin literatürün bir özeti sunulmaktadır. Literatürde BKH tipini sınıflandırmak amacıyla yapılmış birçok yaklaşıma rastlanmaktadır. Bu yaklaşımlar arasında en popüler olanları Makine Öğrenmesi (MÖ), DÖ, Bulanık Mantık ya da hepsinin bir karışımı şeklindedir.

Singh vd., BKH sınıflandırması için bir ESA modeli önermiştir [12]. ESA modeli 200 iterasyon kullanılarak eğitilmiştir. Ma vd., doğruluk değerini artırmak amacıyla ResNet ve DC-GAN'ı birleştirerek bir sınıflandırıcı oluşturmuştur [13]. Şengür vd., beyaz kan hücrelerini sınıflandırmak için ESA yönteminin uygulandığı bir çalışmada HSV uzayındaki kan hücresi görüntülerinden “İlk İlgili Bölgesinin” (İİB) çıkarıldığı bir BKH sınıflandırma yaklaşımını önermiş ve ardından ResNet50 kullanarak özellik çıkarımı yapmıştır [14]. Çalışmada özellik çıkarımı, Temel Bileşen Analizi (TBA) yöntemiyle, sınıflandırma ise UKSB sınıflandırıcısı kullanılarak gerçekleştirilmiştir. Bu yaklaşımla, % 85,7'lik bir doğruluğa ulaşılmıştır. Aynı veri setini kullanan Patil vd., ise doğruluk değerini artırmak için Kanonik Korelasyon Analizi (KKA) yöntemini kullanmıştır [15, 16]. Çalışmada görüntü içeriğinin anlaşılmasını zenginleştirmek için ESA ve TSA modelleri birleştirilerek kullanılmıştır.

Çınar vd., bir çalışmada BKH'lerin sınıflandırılması için DÖ tabanlı Hibrit ESA modeli önerilmiştir. Sunulan model, önceden eğitilmiş Alexnet ve Googlenet mimarilerine dayanmaktadır. Her iki CNN mimarisinin son havuzlama katmanındaki özellik vektörü birleştirilmiş ve elde edilen özellik vektörü, Destek Vektör Makinesi tarafından sınıflandırılmıştır. [17]. Bir diğer çalışmada Sharma vd., BKH sınıflandırmak için DenseNet121 modelini kullanan bir derin öğrenme DÖ modeli uygulamıştır. Bu model %98.84 doğruluk, %99.33 kesinlik, %98.85 hassasiyet ve %99.61 özgüllük vermiştir [18].

Ayrıca Girdhar vd., tarafından yapılan bir çalışmada da BKH tipini diğer yaklaşımlardan çok daha az iterasyonla sınıflandırabildiği belirtilen bir ESA yaklaşımı önerilmiştir [19]. Yu vd., yılında yaptıkları çalışmada BKH sınıflandırması için ResNet50, Inception V3, VGG16, VGG19, Xception yazılımlarını kullanmış ve diğer sınıflandırma yöntemleri arasından % 88.5'lik doğruluk oranıyla en yüksek değerin ESA yöntemiyle elde edildiğini belirtmiştir [20]. Macawile vd. ise ESA tekniklerinden GoogleNet, Alexnet ve ResNet-101 yazılımlarını yine BKH sınıflandırması için kullanmış ve %96.63 değerinde bir ortalama doğruluk değeri elde etmiştir [21].

Zhao vd., BKH verileri için otomatik bir algılama ve sınıflandırma yöntemi sunmuştur [22]. Çalışmada mikroskop görüntüleri incelenmiş, kırmızı, yeşil, mavi (RGB) ve bu renklerin ara renkleri

arasında bağlantı kurularak BKH tipleri belirlenmiştir. Öznelik üretmek için ESA modelinin kullanıldığı çalışmada sınıflandırma doğruluğu % 92,6 ile sınırlı kalmıştır.

Razzak vd., BKH veri setini kullanarak segmentasyon ve sınıflandırma yapmış, sınıflandırma basamağında Extreme Machine Learning (EML) yöntemini [23] ESA ile birlikte kullanmıştır [24]. Parçalı hücre görüntüleri, özellik çıkarma aşamasından önce maskelenmiştir. Öznelikler daha sonra her parçalı hücreden çıkarılmış ve %95.1 başarı oranı ile sınıflandırma yapılmıştır.

Hegde vd., yaptıkları çalışmada hem geleneksel görüntü sınıflandırmasını hem de ESA kullanmış ve bu iki yaklaşımın sonuçlarını karşılaştırmıştır [25]. Elde edilen sonuçlar benzer olmakla birlikte; geleneksel yöntemin, büyük ölçüde segmentasyona ve özellik çıkarımına dayandığı, ESA'nın ise bu parametrelere bağlı olmadığı ifade edilmiştir. Bununla birlikte, ESA yaklaşımının büyük miktarda etiketlenmiş veri gerektirdiği ve geleneksel görüntü işlemenin bu tür zorunlulukları olmadığına da değinilmiştir. İlgili çalışmalar dikkate alındığında önceden eğitilmiş ESA modelleri, farklı BKH türlerini ayırmak için kullanışlı bir araç olarak gösterilmiştir.

### 3. Materyal ve Metot

Bu bölümde önerilen yöntemin deneysel sonuçları için kullanılan veri seti, verilerin özellikleri, DÖ, ESA ve ESA modelleri anlatılmaktadır. Uygulanan veri ön işleme adımları ve filtreler hakkında bilgi verilmektedir. Bu çalışmanın gerçekleştirilmesinde DÖ ağları ve DÖ modellerinden yararlanılmaktadır.

#### 3.1. BKH Veri Kümesi

Bu çalışmada kullanılan BKH veri kümesi açık erişimle genel olarak paylaşımına sunulmaktadır ve bu veri seti Eozinofil, Lenfosit, Monosit ve Nötrofil olmak üzere dört ayrı kategoriye ayrılmıştır. Şekil 2'de grafiksel olarak gösterildiği üzere bu veri kümesi 3.120 Eozinofil, 3.103 Lenfosit, 3.098 Monosit ve 3.123 Nötrofil mikroskobik görüntü örneklerinden oluşmaktadır.

BKH veri kümesi toplamda 12.444 adet .Jpeg formatında kaydedilmiş örnek kan hücresi görüntülerinden oluşmaktadır. Her bir görüntü örneği 24 bit derinliğe sahip olmakla birlikte piksel çözünürlüğü 320×240 boyutlarındadır. Bu veri kümesine ait her bir örnek deneyimli uzmanlar tarafından incelenerek etiketlenmiştir [11]. Veri kümesindeki örneklerinin etkili ve verimli kullanımı için her bir sınıftaki veri sayısı rastgele seçilerek ve eşit tutularak 3000 görüntüye ayarlanmıştır. Bu bakımdan deneysel sonuçlar için dört ayrı sınıfta toplamda kullanılan veri sayısı 12000 olmuştur. Bunun yanında veri kümesi eğitim ve test kümesi olarak sırasıyla %70 ve %30 oranlarında iki kısma ayrılmıştır.

#### 3.2. Evrişimli Sinir Ağı (ESA) ve Modelleri

DÖ, insan beyninin yapısı ve çalışma şekline esinlenerek Yapay Sinir Ağları (YSA) olarak adlandırılan algoritmaların modellendiği makine öğreniminin bir alt dalıdır [26]. DÖ, görüntü, video, sinyal ve doğal dil işleme, robotik, kimya, reklam, arama motorları, finans gibi birçok alanda yapılan sınıflandırma işlemlerinde yaygın olarak kullanılmaktadır. Derin öğrenmeyi geleneksel YSA'lardan ayıran en önemli özelliklerden bir tanesi birden çok katmanla çalışabilmesidir. YSA'lara ait her bir hücre, önceki ve sonraki katmanlardaki tüm hücrelere bağlı olarak çalışmaktadır ve her bir katmanda çok sayıda matematiksel işlem yerine getirilmektedir. Bu nedenle bu yaklaşımda veri miktarı ve katman sayısının artmasıyla yüksek miktarda CPU gücüne ihtiyaç duyulmaktadır. Özellikle son birkaç yıldır DÖ için GPU tabanlı ve yüksek bellekli işlemciler tercih edilmektedir. DÖ için kullanılan birden çok ağ türü bulunmaktadır. Bu ağlar, ESA, Uzun-Kısa Süreli Bellek ağları (UKSB), Sınırlı Boltzman Makineleri (SBM), Tekrarlayan Sinir Ağları (TSA) ve Derin Otomatik Kodlayıcılar (DOK) olarak sınıflandırılabilir [27].

Son yıllarda adından sıkça söz ettiren ESA, görüntü sınıflandırma gibi en yaygın kullanılan DÖ ağlarından biridir ve bu çalışmada ESA kullanılmıştır. ESA ağlarının kökeni yapay sinir ağlarına dayanmaktadır. Yapay sinir ağlarında gizli katman sayısı arttıkça ağın karmaşıklığı da artmakta ve ağdan daha iyi sonuçlar alınabilmektedir. ESA ağlarında kullanılan katman sayısı oldukça fazladır. Bunlardan Konvülsiyonel, Havuzlama, Tam Bağıntılı, Rectified Linear Unit (Relu), Seyreltme (Dropout), Normalleştirme ve Softmax katmanları genellikle kullanılmaktadır [28].

DÖ'de yaygın olarak kullanılan birçok model bulunmaktadır. Bu çalışmada ESA'da yaygın olarak kullanılan Densenet201, ResNet50 ve Alexnet modelleri kullanılmıştır. Elde edilen sonuçlar birbirleriyle karşılaştırılarak yorumlanmaktadır.

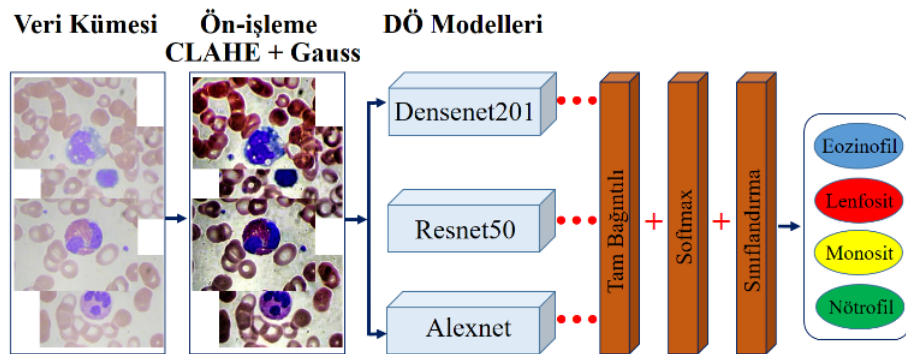
DenseNet-201, ImageNet veritabanından bir milyondan fazla görüntü üzerinde eğitilmiş bir ESA modelidir. Çeşitli görüntüler için zengin özellik temsillerini öğrenebilen katman derinliğine sahiptir. Modelin önemli bir avantajı, gelişmiş bilgi akışı ve daha iyi parametre verimliliği ile birlikte onları ağ üzerinden eğitmeyi kolaylaştıran bir gradyana sahip olmasıdır [29].

ResNet50 son yıllarda geliştirilen en başarılı ESA'lardan biridir. Bu model geliştirdiği yeni bir yaklaşım ile 1000 katman sınırını aşan ilk ESA modeli olarak 2015 yılında sınıflandırma, segmentasyon ve tespit gibi çeşitli alanlarında ILSVRC yarışmasını kazanmıştır. Sınıflandırma hata oranı ortalama bir insanda %5 olmasına karşın modelde ortalama %3,6 olarak test edilmiştir. Bu durum modelin başarısını net olarak ortaya koymaktadır. Bununla birlikte birçok ardışık modele öncülük etmiş ve çeşitli uygulamalarda, özellikle sınıflandırmada bu model kullanılmıştır [30].

AlexNet modeli ILSVRC yarışmasının 2012 yılı galibidir ve DÖ yaklaşımını yeniden popüler hale getiren bir modeldir. Bu model görüntü tanımadaki hata oranını %26 civarından yaklaşık %15 seviyelerine düşmüştür. Bu model LeNet mimarisine çok benzemektedir ve her iki mimaride de ardışık konvülsiyonel ve havuzlama katmanlarının varlığından dolayı, lineer olmayan fonksiyonlar için Relu aktivasyon fonksiyonu kullanılmaktadır [31].

CLAHE yöntemi, tıbbi görüntü iyileştirme sistemleri için geliştirilmiş, homojen alanlarda üretilen gürültüyü azaltmaya çalışan bir filtreleme ve histogram eşitleme yöntemidir [32]. Elde edilen doğruluk sonuçları ile kullanılan bu sayısal görüntü ön-ışleme tekniğinin, daha önce ESA tarafından tespit edilemeyen evrimsel filtreler aracılığıyla hassas nokta özneliklerinin daha iyi algılanmasını sağladığı görülmüştür. Daha sonra, fundoskopik görüntülerdeki gürültüleri yumuşatmak için Gauss çekirdeklerine dayalı morfolojik filtreleme kullanılmıştır. Morfolojik filtreleme, geometrilerini deforme etmeden vurgulamak için kan hücrelerinin rengini iyileştirmeyi amaçlamaktadır.

Gauss filtresi, belirli bir görüntüyü yumuşatmak için kullanılmaktadır. Yani resimdeki gürültüyü ortadan kaldırmakta ve resmi daha anlamlı hale getirmektedir. Gauss filtresine sahip bir resimde önce komşuluk matrisi oluşturulmaktadır. Bu matrisin boyutu, Gauss filtre işlemindeki komşuluk değerine bağlıdır. Özetle, Gauss filtresi resimdeki sert ton değişikliklerini azaltarak görüntüyü daha yumuşak hale getirmektedir [33].




Şekil 3. Verilerin ön-ışlemlenmiş mimariler ile sınıflandırılması



BKH veri setine ait görüntüler MatlabR2019b ortamı kullanılarak sınıflandırılmıştır ve elde edilen deneysel sonuçlar karşılaştırılmaktadır. Bu aşamada hem Densenet201, ResNet50 ve Alexnet DÖ modellerinden yararlanılmış hem de işlenen verilerden elde edilen sonuçlar orijinal sonuçlarla karşılaştırılmıştır. Orijinal verilerle birlikte CLAHE ve Gauss filtreleri uygulanarak ön-işlenen bu görüntüler yine bu üç ESA ağı ile yeniden sınıflandırılmıştır. Geleneksel ESA modelleriyle sınıflandırma yaklaşımının akış şeması Şekil 3'te verilmiştir. Uygulamanın CLAHE ve Gauss filtreleri ile ön-işleme yapıldıktan sonraki akış şeması Şekil 4'te gösterildiği gibidir.

Komşuluk Bileşenleri Analizi (KBA), sınıflandırma performansını en üst düzeye çıkarmak için girdi verilerinin doğrusal dönüşümünü kullanan bir uzaklık metriğini öğrenme yöntemidir. Bu analiz amaçlı, gelecekteki test verileri üzerindeki performansı optimize etmektir, ancak gerçek veri dağılımı bilinmediğinden, bunun yerine eğitim verilerindeki performansı optimize edilmeye çalışılır. Bu yöntem rastgele bir uzaklık metriği belirlemek yerine lineer dönüşümü bulmakta ve KBA algoritması bu metriği kendisi öğrenmektedir. Temel Bileşen Analizinin (TBA) aksine, KBA denetimsiz bir öğrenme yöntemi değildir. Tahmin işlemini yaparken “T” yani hedef değerlere ihtiyaç duymaktadır [34].



Şekil 4. Önerilen yöntemde kullanılan modellerin mimarisi

Elde edilen özellik haritalarının sınıflandırılması için KEK, DVM ve NB olmak üzere üç farklı klasik makine öğrenmesi sınıflandırıcısı kullanılmıştır. DÖ ile eğitilen Kaggle veri kümesi görüntülerine CLAHE ve Gauss filtreleri uygulanarak bu görüntüler üç ESA ağı ile yeniden sınıflandırılmıştır.

#### 4. Deneysel Sonuçlar ve Tartışma

Bu çalışmada deneysel sonuçlardan elde edilen sonuçların karşılaştırılması için Kaggle veri kümesinden alınan BKH veri seti kullanılmıştır. Veri kümesi 4 farklı lökosit hücresi sınıfından oluşmaktadır. Her sınıfta 3000 adet veri örneği bulunmaktadır. Toplamda deneyler sırasında 12000 örnekten oluşan bir veri kümesi kullanılmıştır.

Bu bölümde sırasıyla Densenet201, ResNet50 ve Alexnet mimarilerinden doğruluk metriği bakımından elde edilen deneysel sonuçlara yer verilmiştir. Bu bakımdan Densenet201 mimarisiyle elde edilen hem doğrudan orijinal veriler üzerinden hem de ön-işleme (CLAHE, Gauss Filtresi) yapılan verilere ait sonuçlar Çizelge 1'de gösterilmiştir.

Çizelge 1. Densenet201 mimarisinin test sonuçları.

Densenet201 Karışıklık Matrisi				
Orijinal Veri Kümesi				
	1	2	3	4
1	0,4890	0,3006	0,0718	0,1884
2	0,0045	1	0,0045	0
3	0	0,1077	0,9243	0,0179
4	0,0313	0,1750	0,0268	0,8166

Doğruluk: %80,75				
CLAHE ve Gauss Filtreli Veri Kümesi				
	1	2	3	4
1	0,8212	0,0268	0,0089	0,1929
2	0,0673	0,9333	0,0134	0,0359
3	0,0897	0,0089	0,9199	0,0313
4	0,1794	0,0359	0,0045	0,8301
Doğruluk: %87,61				

ResNet50 mimarisıyla elde edilen hem doğrudan orijinal veriler üzerinden hem de ön-işleme (CLAHE, Gauss Filtresi) yapılan verilere ait sonuçlar Çizelge 2’de gösterilmiştir.

**Çizelge 2.** Resnet50 mimarisinin test sonuçları.

ResNet50 Karışıklık Matrisi				
Orijinal Veri Kümesi				
	1	2	3	4
1	0,7852	0,0089	0,0045	0,2512
2	0,0941	0,8121	0,0134	0,1300
3	0,1256	0,0134	0,8032	0,1166
4	0,1121	0,0224	0,0089	0,9063
Doğruluk: %82,67				
CLAHE ve Gauss Filtreli Veri Kümesi				
	1	2	3	4
1	0,7179	0,1480	0,1032	0,0807
2	0,0268	0,9872	0,0268	0,0089
3	0,0045	0,0359	1	0
4	0,1346	0,1211	0,1705	0,6237
Doğruluk: %83,22				

Alexnet mimarisıyla elde edilen hem doğrudan orijinal veriler üzerinden hem de ön-işleme (CLAHE, Gauss Filtresi) yapılan verilere ait sonuçlar Çizelge 3’te gösterilmiştir.

**Çizelge 3.** Alexnet mimarisinin test sonuçları.

Alexnet Karışıklık Matrisi				
Orijinal Veri Kümesi				
	1	2	3	4
1	0,7224	0,1391	0,1436	0,0448
2	0,1256	0,7987	0,0045	0
3	0,0179	0,0359	0,9961	0
4	0,1660	0,1480	0,1705	0,5654
Doğruluk: %77,06				
CLAHE ve Gauss Filtreli Veri Kümesi				
	1	2	3	4
1	0,7269	0,0359	0,1660	0,1211
2	0,0179	0,9737	0,0404	0,0179
3	0	0	1	0
4	0,1525	0,0313	0,1660	0,7000
Doğruluk: %85,01				

Densenet201 mimarisinde orijinal veriler kullanılarak BKH’i sınıflandırmada %80,75 doğruluk sonucuna ulaşılmıştır. Görüntülere CLAHE ve Gauss filtresi uygulandıktan sonra doğruluk oranı aynı mimaride %87,61’e yükselmiştir. ResNet50 mimarisinde orijinal veriler kullanılarak BKH’i sınıflandırmada %82,67 doğruluk sonucuna ulaşılmıştır. Görüntülere CLAHE ve Gauss filtresi uygulandıktan sonra doğruluk oranı aynı mimaride %83,22’e yükselmiştir. Alexnet mimarisinde orijinal

veriler kullanılarak BKH'i sınıflandırmada %77,06 doğruluk sonucuna ulaşılmıştır. Görüntülere CLAHE ve Gauss filtresi uygulandıktan sonra doğruluk oranı aynı mimaride %85,01'e yükselmiştir. Bu bakımdan kullanılan bu morfolojik filtrelemelerin sınıflandırmanın doğruluk sonuçlarına olumlu katkıda bulunduğu gösterilmiştir.

DeneySEL sonuçların bu üç DÖ modelleriyle elde edilen doğruluk değerleri Çizelge 4'te özetlenmiştir.

**Çizelge 4.** Mimarilerin doğruluk sonuçları.

	<b>Orijinal</b>	<b>CLAHE+Gauss</b>
<b>Densenet201</b>	%80,75	%87,61
<b>ResNet50</b>	%82,67	%83,22
<b>Alexnet</b>	%77,06	%85,01

ResNet50 mimarisi, orijinal verilerin kullanıldığı sınıflandırmada en yüksek doğruluğu %82,67 ile elde etmiştir. Bunu %80,75 ile Densenet201 mimarisi ve %77,06 ile Alexnet mimarisi izlemiştir.

Morfolojik filtreler uygulandıktan sonra DenseNet201 mimarisi %87,61 ile en yüksek doğruluğu elde etmiştir. DenseNet201'i sırasıyla %85,01 ile AlexNet ve %83,22 ile ResNet50 izlemiştir.

#### 4.1. Önerilen Özellik Çıkarıcı ESA Modeli

Önerilen modelin sınıflandırma performansı, doğruluk performans ölçütü aracılığıyla test edilmiştir. Bu performans ölçütünün matematiksel formülasyonu denklem (1)'de verilmiştir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \times 100 \quad (1)$$

Çıktı Sınıf	Negatif	Doğru Negatif (DN)	Yanlış Negatif (YN)
	Pozitif	Yanlış Pozitif (YP)	Doğru Pozitif (DP)
		Negatif	Pozitif

**Hedef Sınıf**

**Şekil 5.** Karışıklık matrisi

Denklem (1)'de verilen Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) gibi değerler karışıklık matrisi kullanılarak hesaplanmaktadır. Karışıklık matrisi Şekil 5'te verilmiştir. DeneySEL sonuçlar Intel Core i7 işlemci, 8 Gb Ram ve NVidia GeForce GTX 1060 ekran kartına sahip bir donanım üzerinden simüle edilmiştir.

Bu çalışmada öznitelik çıkarıcı olarak birer ESA mimarileri kullanılmıştır. Bu çalışmada kullanılan ESA modellerinde tercih edilen önemli parametre bilgileri şu şekildedir; AlexNet'in filtre boyutu 3×3 piksele ayarlanmıştır, adım sayısı 2 ve maksimum havuzlama tercih edilmiştir. ResNet50 modelinin filtre boyutu 7×7 piksel olarak ayarlanmıştır, adım sayısı 2 ve seçilen havuzlama türü maksimum olmuştur. Ayrıca ResNet50 için girdi katmanlarının boyutları 224×224 piksel olarak ayarlanmıştır. Ayrıca eğitim sırasında ESA'lar transfer öğrenme yaklaşımı olmadan eğitilmiştir.

Önceden eğitilmiş, literatürde kabul gören 3 mimari kullanılarak veri setindeki görüntülerin özellik haritaları çıkartılmıştır. Özellik çıkarım işlemi için Densenet201, ResNet50 ve Alexnet mimarileri kullanılmıştır. Bu üç mimarinin çıkarmış oldukları özellik haritaları birbirlerinden farklıdır. Bundan dolayı bu 3 mimarinin deneyiminden faydalanılarak elde edilen özellik haritaları birleştirilmiştir. Özellik çıkarımı yapılırken Densenet201 ile ResNet50'nin FC-1000 katmanı ve AlexNet modelinin FC-8 katmanı kullanılmıştır. Her bir mimaride elde edilen özellik haritasının boyutu 21000×1000'dir. Özellik birleştirme işleminden sonra elde edilen yeni özellik haritasının boyutu 21000×3000 olmuştur. Birleştirme işleminden sonra elde edilen özellik haritası KBA boyut indirgeme



yöntemi kullanılarak optimize edildikten sonra elde edilen yeni özellik haritasının boyutu 21000x250 olmuştur. Son olarak elde edilen yeni özellik haritası 3 farklı makine öğrenmesinde sınıflandırılmıştır. Önerilen hibrit model Şekil 4’te kabaca gösterilmiştir. Bilinen ESA modellerinin ve önerilen hibrit modelin elde ettiği doğruluk değerlerine ait sonuçlar Çizelge 5’te gösterilmiştir.

BKH dört türüne ait sınıflandırmanın karışıklık matrisi Şekil 6’da gösterilmektedir. Karışıklık matrisinin satırları tahmin edilen çıktı sınıfını ve sütunlar gerçek çıktı sınıfını göstermektedir. Kırmızı renkli sütunlar uyumsuzlukları, yeşil renkli kutular ise doğru eşleşen etiketleri göstermektedir. Kan yayma görüntülerinin temel gerçeği, hedef sınıf olarak etiketlenirken, tahmin edilen çıktı sınıfı, karışıklık matrisinde etiket çıktı sınıfı ile gösterilmiştir. Nötrofillerin 12 görüntüsü hatalı şekilde Eozinofil olarak etiketlendiğinden, Nötrofillerin etiketlenmesi durumunda maksimum uyumsuzluklar bulunmaktadır.

**Karışıklık Matrisi**

<b>Çıktı Sınıf</b>	Eozinofil	288 %24.0	0 %0.0	0 %0.0	12 %1.0	%96.0 %4.0
	Lenfosit	10 %0.8	290 %24.2	0 %0.0	0 %0.0	%96.7 %3.3
	Monosit	0 %0.0	6 %0.5	294 %24.5	0 %0.0	%98.0 %2.0
	Nötrofil	2 %0.2	0 %0.0	5 %0.4	293 %24.4	%97.7 %2.3
		%96.0 %4.0	%98.0 %2.0	%98.3 %1.7	%96.0 %4.0	%97.1 %2.9
		Eozinofil	Lenfosit	Monosit	Nötrofil	
		<b>Hedef Sınıf</b>				

Şekil 6. BKH dört sınıfı için karışıklık matrisi

Çizelge 5. Modellerin sınıflandırma doğruluk sonuçları.

ESA Mimarisi	Sınıf sayısı	Özellik sayısı	Doğruluk %
Densenet201	4	1000	95,43
ResNet50	4	1000	94,83
Alexnet	4	1000	92,40
Densenet201, ResNet50, Alexnet	4	3000	95,45
Önerilen Model	4	250	97,10

Önerilen yaklaşımda, BKH sınıflandırması için öznitelik seçim yöntemleri bilinen ESA modelleriyle kombinasyonu değerlendirilmiştir. Önerilen yaklaşımla Densenet201, ResNet50 ve AlexNet mimarilerinin 1000 özellikli katmanlarından elde edilen öznitelikler birleştirilmiştir. Birleştirilmiş öznitelik kümesindeki öznitelikler KBA füzyon yöntemi ile indirgenmiştir. Birleştirilen öznitelik setlerinin sınıflandırma sonuçlarına katkı sağladığı görülmüştür. Burada birleştirilen özniteliklerinin tek öznitelik seçme yönteminden daha başarılı olduğu kanıtlanmıştır. Birleştirilen özniteliklerin elde ettiği doğruluk değeri %95,45 değeri ile en yüksek tek öznitelik yöntemi olan Densenet201’in elde ettiği %95,43 doğruluk değerinden daha yüksektir. Deneysel sonuçlar, öznitelik seçiminde kullanılan KEK, DVM ve NB, MÖ yöntemleri ile yapılan sınıflandırma sonucunda 250 öznitelik ile elde edilen genel doğruluk oranının %97,10 olduğunu göstermektedir.

Çizelge 5, önerilen ESA modelinin, mevcut ESA teknikleri ve birleşimlerinden elde edilen sınıflandırma doğruluk oranlarını göstermektedir. Tasarlanan ESA modelinin doğruluk açısından diğer yaklaşımlardan daha iyi performans gösterdiği görülmektedir.

## 5. Sonuçlar

Bu çalışmada, son yıllarda adından çok söz ettiren DÖ, DÖ katmanları ve DÖ modelleri sınıflandırma açısından incelenmektedir. Öncelikle lökosit kan hücresini oluşturan Eozinofil, Lenfosit, Monosit ve Nötrofil hücreleri Matlab uygulama ortamında Densenet201, Resnet50 ve Alexnet mimarileri kullanılarak sınıflandırılmıştır. Daha sonra veri tabanındaki örneklere CLAHE ve Gauss filtreleri uygulanmıştır. Yeni görüntüler aynı mimariler kullanılarak yeniden sınıflandırılmıştır. Görüntülere filtreler uygulandıktan sonra elde edilen sonuçların, orijinal verilerle elde edilen sonuçlardan daha iyi olduğu gözlemlenmiştir. Densenet201 bu çalışmada kullanılan ESA modelleri arasında %95,43 doğruluk değeri ile en yüksek tek öznitelik yaklaşımı olmuştur. Birleştirilen özniteliklerin elde ettiği doğruluk değerinin %95,45 ile daha iyi sonuç verdiği görülmüştür. Önerilen hibrit yöntemin ise elde ettiği genel doğruluk oranı %97,10 ile en yüksek sonuca ulaşmıştır. DÖ modelleri büyük veri tabanlarıyla çalıştığı için ağırları eğitmek ve test etmek uzun zaman almaktadır. Gelecekte bu hız sorununu aşmak için GPU tarzı kartlar tercih edilerek hız sorunu en aza indirilebilir.

## Kaynaklar

- [1] Fan H, Zhang F, Xi L, Li Z, Liu G, Xu Y. LeukocyteMask: An automated localization and segmentation method for leukocyte in blood smear images using deep neural networks. *Journal of biophotonics* 2019; 12(7): 201800488.
- [2] Janjua HU, Akhtar M, Hussain F. Effects of sugar, salt and distilled water on white blood cells and platelet cells: A review. *Journal of Tumor* 2016; 4(1): 354-358.
- [3] Wang Q, Bi S, Sun M, Wang Y, Wang D, Yang S. Deep learning approach to peripheral leukocyte recognition. *PloS one* 2019; 14(6): 0218808.
- [4] Kabat GC, Kim MY, Manson JE, Lessin L, Lin J. Wassertheil-Smoller S, Rohan TE. White blood cell count and total and cause-specific mortality in the Women's Health Initiative. *American journal of epidemiology* 2017; 186(1): 63-72.
- [5] Fest J, Ruitter R, Ikram MA, Voortman T, van Eijck CH, Stricker BH. Reference values for white blood-cell-based inflammatory markers in the Rotterdam Study: a population-based prospective cohort study. *Scientific reports* 2018; 8(1): 1-7.
- [6] Torre LA, Islami F, Siegel RL, Ward EM, Jemal A. Global cancer in women: burden and trends. *Cancer Epidemiology and Prevention Biomarkers* 2017; 26(4): 444-457.
- [7] Weitkamp E, Mermikides A. Medical performance and the 'inaccessible' experience of illness: an exploratory study. *Medical humanities* 2016; 42(3): 186-193.
- [8] Sajjad M, Khan S, Jan Z, Muhammad K, Moon H, Kwak JT, Rho S, Baik SW, Mehmood I. Leukocytes classification and segmentation in microscopic blood smear: a resource-aware healthcare service in smart cities. *IEEE Access* 2016; 5: 3475-3489.
- [9] Sharma M, Bhave A, Janghel RR. White blood cell classification using convolutional neural network. In *Soft Computing and Signal Processing* 2019; Springer: 135-143.
- [10] Wang JL, Li AY, Huang M, Ibrahim AK, Zhuang H, Ali AM. Classification of white blood cells with patternnet-fused ensemble of convolutional neural networks (pecnn). *IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)* 2018; 325-330.
- [11] Mooney P. Blood Cell Images. 2018 (Erişim: 07.02.2022), <https://www.kaggle.com/paultimothymooney/blood-cells>
- [12] Rojas I, Valenzuela O, Rojas F, Ortuño F. *Bioinformatics and Biomedical Engineering: 7th International Work-Conference. Proceedings* 2019; Part I. (11465).
- [13] Ma L, Shuai R, Ran X, Liu W, Ye C. Combining DC-GAN with ResNet for blood cell image classification. *Medical & biological engineering & computing* 2020; 58(6): 1251-1264.

- [14] Şengür A, Akbulut Y, Budak Ü, Cömert Z. White blood cell classification based on shape and deep features. *International Artificial Intelligence and Data Processing Symposium (IDAP) 2019*; 1-4.
- [15] Patil AM, Patil MD, Birajdar GK. White blood cells image classification using deep learning with canonical correlation analysis. *IRBM 2021*; 42(5): 378-389.
- [16] Hotelling H. Relations between two sets of variates. *Breakthroughs in statistics 1992*; 162-190.
- [17] Çınar A, Tuncer SA. Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-GoogleNet-SVM. *SN Applied Sciences, 2021*; 3(4), 1-11.
- [18] Sharma S, Gupta S, Gupta D, Juneja S, Gupta P, Dhiman G, Kautish S. Deep learning model for the automatic classification of white blood cells. *Computational Intelligence and Neuroscience*; 2022.
- [19] Girdhar A, Kapur H, Kumar V. Classification of White blood cell using Convolution Neural Network. *Biomedical Signal Processing and Control 2022*; 71: 103156.
- [20] Yu W, Chang J, Yang C, Zhang L, Shen H, Xia Y, Sha J. Automatic classification of leukocytes using deep neural network. *12th international conference on ASIC (ASICON) 2017*: 1041-1044.
- [21] Macawile MJ, Quiñones VV, Ballado A, Cruz JD, Caya MV. White blood cell classification and counting using convolutional neural network. *3rd International conference on control and robotics engineering (ICCRE) 2018*: 259-263.
- [22] Zhao J, Zhang M, Zhou Z, Chu J, Cao F. Automatic detection and classification of leukocytes using convolutional neural networks. *Medical & biological engineering & computing 2017*; 55(8): 1287-1301.
- [23] Ming Y, Zhu E, Wang M, Ye Y, Liu X, Yin J. DMP-ELMs: Data and model parallel extreme learning machines for large-scale learning tasks. *Neurocomputing 2018*; 320: 85-97.
- [24] Imran Razzak M, Naz S. Microscopic blood smear segmentation and classification using deep contour aware CNN and extreme machine learning. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops 2017*: 49-55.
- [25] Hegde RB, Prasad K, Hebbar H, Singh BMK. Comparison of traditional image processing and deep learning approaches for classification of white blood cells in peripheral blood smear images. *Biocybernetics and Biomedical Engineering 2019*; 39(2): 382-392.
- [26] Chen H, Engkvist O, Wang Y, Olivecrona M, Blaschke T. The rise of deep learning in drug discovery. *Drug discovery today 2018*; 23(6): 1241-1250.
- [27] Kermany DS, Goldbaum M, Cai W, Valentim CC, Liang H, Baxter SL, McKeown A, Yang G, Wu X, Yan F, Dong J, Prasadha MK, Pei J, Ting MYL, Zhu J, Li C, Hewett S, Dong J, Ziyar I, Shi A, Zhang R, Zheng L, Hou R, Shi W, Fu X, Duan Y, Huu VAN, Wen C, Zhang ED, Zhang CL, Li O, Wang X, Singer MA, Sun X, Xu J, Tafreshi A, Lewis MA, Xia H, Zhang K. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell 2018*; 172(5): 1122-1131.
- [28] Molchanov P, Tyree S, Karras T, Aila T, Kautz J. Pruning convolutional neural networks for resource efficient inference. *arXiv preprint arXiv 2016*; 1611.06440.
- [29] Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition 2017*: 4700-4708.
- [30] He T, Zhang Z, Zhang H, Zhang Z, Xie J, Li M. Bag of tricks for image classification with convolutional neural networks. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition 2019*: 558-567.
- [31] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems 2017*; 60(6): 84-90.
- [32] Shahzad A, Raza M, Shah JH, Sharif M, Nayak RS. Categorizing white blood cells by utilizing deep features of proposed 4B-AdditionNet-based CNN network with ant colony optimization. *Complex & Intelligent Systems 2021*: 1-17.

- [33] Izanloo R, Fakoorian SA, Yazdi HS, Simon D. Kalman filtering based on the maximum correntropy criterion in the presence of non-Gaussian noise. Annual Conference on Information Science and Systems (CISS) 2016: 500-505.
- [34] Goldberger J, Hinton GE, Roweis S, Salakhutdinov RR. Neighbourhood components analysis. Advances in neural information processing systems 2004; 17.