

# İyileştirilmiş Görüntü Sınıflandırma Performansı için Hibrit ESA-Ağaç Temelli Bir Model A Hybrid CNN-Tree Based Model for Enhanced Image Classification Performance

Musa Aydın

Fatih Sultan Mehmet Vakıf Üniversitesi  
Bilgisayar Mühendisliği  
İstanbul, Türkiye  
Email: maydin@fsm.edu.tr

Zeki Kuş

Fatih Sultan Mehmet Vakıf Üniversitesi  
Bilgisayar Mühendisliği  
İstanbul, Türkiye  
Email: zkus@fsm.edu.tr

Zeliha Kaya Akçelik

Fatih Sultan Mehmet Vakıf Üniversitesi  
Bilgisayar Mühendisliği  
İstanbul, Türkiye  
Email: zkaya@fsm.edu.tr

**Özetçe** —Kan hücreleri, enfeksiyonlara karşı koruma ve vücudu savunma gibi çeşitli vücut fonksiyonlarında önemli bir rol oynar. Genel olarak kırmızı, beyaz ve trombosit olarak gruplanabilen kan hücrelerinin doğru bir şekilde sınıflandırılması klinik tanı ve hematolojik analiz için önem arz etmektedir. Ancak, bu hücrelerin ayırt edilmesi uzmanlık gerektiren ve zaman alıcı bir işlemdir. Bu nedenle, yüksek hassasiyette otomatik kan hücresi sınıflandırabilen yöntemlere olan ihtiyaç artmaktadır. Evrişimli sinir ağları (ESA) görsel veri analizi için kullanılan ve veriden özellik çıkarma konusunda çok güçlü olan bir derin öğrenme modelidir. Bu çalışmada, ESA'nın özellik çıkarma gücünü Rastgele Orman ve XGBoost algoritmalarının topluluk temelli tahmin yetenekleriyle birleştiren hibrit bir sınıflandırma modeli önerilmiştir. Önerilen hibrit model, BloodMNIST veri kümesi üzerinde farklı yöntemler ile sınıflandırma performansını ve çıkarım süresi açısından kıyaslanmıştır. Elde edilen sonuçlara bakıldığında ağaç-temelli yöntemlerin ESA'ya kıyasla 8.49 ve 11.62 puana kadar daha iyi sınıflandırma performansı gösterdiği ve diğer yöntemlere kıyasla 82.9 kata kadar daha iyi çıkarım süreleri elde edildiği görülmüştür.

**Anahtar Kelimeler**—ESA özellik çıkarmı, Rastgele orman, XGBoost, Kan hücresi sınıflandırma

**Abstract**—Blood cells play an essential role in various bodily functions, such as protection against infections and the body's defense. The accurate classification of blood cells, generally grouped as red, white, and platelets is important for clinical diagnosis and hematological analysis. However, identifying these cells is a specialized and time-consuming process. Therefore, there is a hot-topic for high-precision automatic blood cell classification methods. Convolutional neural networks (CNNs) are a deep learning model used for visual data analysis and are very powerful in extracting features from data. In this study, we propose a hybrid classification model that combines the feature extraction power of CNNs with the ensemble-based prediction capabilities of Random Forest and XGBoost algorithms. The proposed hybrid model is compared with different methods on the BloodMNIST dataset in terms of classification performance and inference time. The results show that the tree-based methods outperform CNN by up to 8.49 and 11.62 points and achieve up to 82.9 times better inference times than other methods.

**Keywords**—CNN feature extraction, Random forest, XGBoost,

*Blood cell classification,*

## I. Giriş

Ham veriden belirgin özellikleri çıkarma, sınıflandırma algoritmaları için veri hazırlama sürecinde çok önemli bir adım olmuştur. Çeşitli algoritmik yaklaşımlar veya el ile manuel hazırlanmış özelliklere dayanan geleneksel yöntemlerin aksine, evrişimli sinir ağları (ESA) verinin eğitimi süresince, ham veriden belirgin ve ayırt edici özellikleri bağımsız olarak öğrenmektedir [1]. Evrişimli sinir ağlarının en önemli ve güçlü yönlerinden biri, ham veriden hiyerarşik ve soyut özellikleri otomatik olarak öğrenebilme yeteneğidir. Bu özelliği ile evrişimli sinir ağları sınıflandırma problemlerinde özellik çıkarımı için güçlü modeller olarak karşımıza çıkmaktadır [2].

Literatürde, hücre sınıflandırması üzerine gerçekleştirilmiş ve başarılı sonuçlar veren geleneksel makine öğrenmesi ve derin öğrenme yaklaşımları bulunmaktadır. Yapılan ilk çalışmalarda, geleneksel makine öğrenmesi yöntemleri ile kan hücrelerinin yapısal özellikleri kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Sabino vd. [3] tarafından yapılan çalışmada, kronik lenfositik lösemi de dahil olmak üzere farklı lökosit türleri arasında ayırım yapmak için doku parametrelerinin kullanımı tartışılmıştır. Bu yöntemler el ile çıkarılmış özellikler üzerinden analiz ve sınıflandırma işlemlerini gerçekleştirdiğinden dolayı istenilen sonuçlar elde edilememiş ve derin öğrenme yöntemlerinin yaygınlaşması ile bu alanda daha fazla çalışma önerilmiştir [4], [5]. Şengür vd. [6] tarafından yapılan çalışmada, beyaz kan hücrelerini sınıflandırmak için üç katmanlı bir yapı önerilmiştir. Bu hibrit yapı ilk katmanlarda görüntü işleme ve iyileştirme algoritmalarını kullanarak bölütleme ve özellik çıkarımı işlemi yaparken, son katmanda Uzun-Kısa Vadeli Bellek (ing: LSTM) ağını kullanarak sınıflandırma yapmaktadır. Önerilen model 349 adet görüntüye sahip kan yayma veri kümesi üzerinde şekil temelli özelliklerde %80.0 doğruluk sağlarken, ince detay (ing: fine-grained) özelliklerde ise %82.9 doğruluk elde etmiştir. Hegde vd. [7] ise beyaz kan hücrelerinin sınıflandırılması için geleneksel görüntü işleme yaklaşımı ile derin öğrenme yöntemlerinin karşılaştırıldığı

979-8-3503-8896-1/24/\$31.00 ©2024 IEEE

bir çalışma önermiştir. Özellik çıkarımının iyileştirilmesi için gürültüye ve aydınlatma değişimlerine karşı dirençli olan istiflenmiş otokodlayıcılar ve ESA gibi derin öğrenme yaklaşımları kullanılmıştır. Hücre sınıflandırma işlemi sinir ağları ve otokodlayıcılar ile gerçekleştirilmiş olup 1159 görüntüden oluşan veri kümesi üzerinde sırasıyla %97.2 ve %96.72 doğruluk değeri elde edilmiştir. Ma vd. [8], kan hücrelerinin sınıflandırılması problemi için doğruluğu arttırmak amacıyla kayıp fonksiyonu modifiye edilmiş yeni bir ESA ağı önermiştir. Bu kayıp fonksiyonu farklı sınıflar arasındaki uzaklığı artırırken aynı sınıfa ait örnekler arasındaki farkları azaltmaktadır. Çalışmada önerilen model ile birlikte kan hücreleri için %91.7 doğruluk ile sınıflandırma yapılmıştır.

Yapılan çalışmada, kan hücrelerinin sınıflandırılması problemi için ESA ve ağaç temelli yaklaşımların birlikte kullanıldığı hibrit bir model önerilmiştir. Önerilen model, verilen görüntüden özellik çıkarma işlemi için ESA ağını ve çıkarılan özelliklerden kan hücrelerinin sınıflandırılması için de Rastgele Orman (RF) ve XGBoost yöntemlerini kullanmaktadır. Aynı zamanda, ağaç temelli sınıflandırıcılar BloodMNIST [9] veri kümesi üzerinde çok katmanlı sınıflandırıcı ile, hem sınıflandırma performansı hem çıkarım süresi bakımından kıyaslanmıştır. Elde edilen sonuçlara bakıldığında RF ve XGBoost'un ESA'ya göre sırasıyla 8.49 ve 11.62 puana kadar daha fazla doğruluk elde ettiği görülmüş ve aynı zamanda XGBoost'un karşılaştırılan diğer yöntemleri 82.9 kata kadar hızlandırdığı gözlemlenmiştir.


## II. MATERYAL YÖNTEM

### A. Veri Kümesi

BloodMNIST [9], herhangi bir enfeksiyon, kan hastalığı veya kanserli olmayan ve kan alma sırasında herhangi bir ilaç kullanmamış sağlıklı bireylerden alınan normal kan hücrelerinin yüksek kaliteli görüntülerinden oluşan bir veri kümesidir. Veri kümesi, araştırmacıların ve tıp uzmanlarının normal kan hücrelerinin yapısını ve işlevini daha iyi anlamalarına yardımcı olmak için tasarlanmıştır; bu da çeşitli kan hastalıklarının teşhisi ve tedavisi için gereklidir. BloodMNIST, 8 farklı kan hücresi sınıfına ait toplam 17.092 görüntüden oluşmaktadır. Bu sınıflar şu şekildedir: eritrositler (kırmızı kan hücreleri), trombositler (trombositler), lenfositler, monositler, eozinofiller, bazofiller, nötrofiller ve normoblastlar. Yapılan çalışmada, farklı modellerin adil bir şekilde karşılaştırılması amacıyla BloodMNIST veri kümesi için ayrılmış olan eğitim, doğrulama ve test kümeleri kullanılmıştır. Orijinal görüntü boyutu  $363 \times 360 \times 3$  piksel olan görüntüler ortalarından kırılarak  $200 \times 200 \times 3$  piksel haline getirilmiş ve ardından  $28 \times 28 \times 3$  piksel olacak şekilde Yang vd. [9] tarafından yeniden boyutlandırılmıştır. Şekil 1'de deneysel çalışmada kullanılan BloodMNIST veri kümesindeki örnek kan hücreleri gösterilmektedir. Bu çalışmada geliştirilen tüm algoritmalara bu <https://github.com/msaaydin/A-Hybrid-CNN-Tree-Based-Model-for-Enhanced-Image-Classification-Performance> bağlantı adresinden erişilebilir.

### B. Random Forest Algoritması

Yapılan çalışmada, medikal görüntülerin sınıflandırılması için gürbüz sonuçlar verdiği bilinen ve ağaç temelli bir yaklaşım olan Rastgele Orman (RF) algoritması kullanılmıştır. RF



Şekil 1: Deneysel çalışmada kullanılan BloodMNIST veri kümesindeki örnek kan hücresi görüntüleri: (a) bazofil, (b) eozinofil, (c) eritrosit, (d) normoblast, (e) lenfosit, (f) monosit, (g) nötrofil, (h) trombosit

algoritması aynı zamanda topluluk öğrenmesi (ing: ensemble learning) yaklaşımlarından biridir [10], [11]. RF algoritmasında çok sayıda karar ağacı oluşturulur ve bu karar ağaçlarının her biri eğitim için kullanılan örnekler ve özelliklerin bir alt kümesi üzerinde eğitilir. Bu ağaçların tahminleri çoğunluk oylaması (ing: majority voting) ile birleştirilir ve tek bir sonuç üretilir. Bu topluluk öğrenmesi yaklaşımı, yapay öğrenme problemleri için bir zorluk olan aşırı öğrenmeyi azaltır ve sunmuş olduğu karar ağaçlarının yapısı kolayca görselleştirilebildiği için yorumlanabilirlik açısından avantaj sağlar [12]. Bu çalışmada, RF algoritmasının gerçekleştirilmesi için scikit-learn kütüphanesi kullanılmıştır.

### C. XGBoost Algoritması

Yapılan çalışmada ikinci olarak, bir başka ağaç temelli yapay öğrenme aracı olan XGBoost algoritması kullanılmıştır. Extreme Gradient Boosting'in kısaltması olan XGBoost, sınıflandırma performansını artırmak için gradyan artırmanın (ing: gradient boosting) avantajlarını kullanan topluluk öğrenmesi yöntemidir. Hem RF hem de XGBoost sınıflandırma için karar ağaçlarını kullanır, ancak topluluk öğrenme yaklaşımı açısından bu iki algoritma birbirinden farklılaşır. RF algoritması paralel olarak çeşitli ağaçlar oluşturarak büyük veri kümeleri için yorumlanabilirlik ve verimlilik sunarken, XGBoost'un sıralı artırımı her ağaçta hataları azaltmaya odaklanarak daha az paralellik ve biraz daha az yorumlanabilirlik pahasına karmaşık veriler için potansiyel olarak daha yüksek doğruluk elde eder. RF algoritmasından farklı olarak XGBoost topluluk içerisinde kademeli olarak karar ağaçları ekleyerek çalışır ve sonraki her ağaç kendinden öncekinin hatalarını düzeltir [13], [14]. XGBoost, doğrusal olmama ve özellikler arasındaki karmaşık ilişkileri yakalama yeteneği nedeniyle medikal görüntüler gibi karmaşık, yüksek boyutlu veri kümeleri için özellikle uygundur [12].

### D. Evrişimli Sinir Ağı Modeli

Evrişimli sinir ağları (ESA), görüntülerdeki bölgesel ilişkileri yakalamakta algılamakta başarılı sonuçlar veren güçlü sinir ağı modelleridir. Ağın evrişim (ing: convolution) katmanlarında, giriş verisinin farklı bölgelerine belirli sıralamada sistematik olarak filtreler uygulanır ve verideki bölgesel kalıplar öğrenilir. Daha sonra, öğrenilen bölgesel kalıplar-yapılar, daha yüksek düzeyde temsiller oluşturmak için birleştirilir.

Bu hiyerarşik yaklaşım, ESA'nın basit kenar özelliklerinden daha karmaşık yapıları barındıran özellikleri ayırt etmesine olanak tanır. Bu çalışmada, özellik çıkarımı için oluşturulan ESA mimarisi Şekil 2'de gösterilmektedir. Bu ESA'nın özellik çıkarıcı bölümü 5 adet evrişim katmanından oluşmaktadır. İlk evrişim katmanındaki giriş özellik haritası sayısı 3, çıkış özellik haritası sayısı 4'tür, evrişim çekirdeği boyutu tüm evrişim katmanlarında  $3 \times 3$  olarak belirlenmiştir. 5 adet evrişim katmanının her biri için üretilen özellik haritalarının sayısı sırasıyla [4, 8, 16, 32] olarak belirlenmiştir. ESA'nın özellik çıkarıcı bölümünde 2 adet maksimum ortaklama (ing: maxpooling) katmanı bulunmaktadır ve bu katmanlar için çekirdek boyutları  $2 \times 2$ , adım kaydırma miktarı da 2 olarak seçilmiştir. Evrişim katmanlarında aktivasyon fonksiyonu olarak *ReLU* kullanılmıştır ve aktivasyon fonksiyonu öncesinde yığın normalizasyonu (ing: Batch Normalization) yapılmaktadır. ESA için hesaplanan gradyanlara göre ağırlıkların güncellenmesi için optimizasyon yöntemi olarak stokastik gradyan inişi (ing: Stochastic Gradient Descent-SGD) algoritması kullanılmıştır ve öğrenme oranı  $lr = 1e - 4$  olacak şekilde seçilmiştir. ESA'nın tahmin ettiği değerler ile gerçek değerler arasındaki kayıp, kategorik çapraz entropi kaybı (ing: categorical cross entropy loss) fonksiyonu ile hesaplanmaktadır. Toplamda çıktı katmanı dahil 3 adet tam bağlantılı katmandan oluşan ESA'nın tam bağlantılı katmanları için nöron sayıları sırasıyla 128, 256 ve 8 (çıkış katmanı) olarak seçilmiştir. Ağın çıktı katmanından elde edilen olasılık değerlerinin (ing: logits) sınıf bazlı olasılık dağılımını hesaplamak için, aktivasyon fonksiyonu olarak *Softmax* aktivasyon fonksiyonu kullanılmıştır.

TABLO I: Farklı eğitim dönemleri için CNN, RF ve XGBoost yöntemlerinin 4 farklı performans ölçütü ve çıkarım süresi açısından kıyaslanması. Hızlandırma kolonundaki değerler XGBoost ve RF algoritmalarının CNN yöntemini çıkarım süresi olarak kaç kat iyileştirdiğini göstermektedir.

#	Ölçüt	CNN	RF	XGBoost	Hızlandırma	
					RF	XGBoost
30	ACC	75.26	83.75	<b>86.88</b>	8.54	55.8
	PR	67.02	83.79	<b>85.89</b>		
	REC	65.25	78.75	<b>83.70</b>		
	F1	64.05	80.33	<b>84.63</b>		
	Test zamanı(sn)	0.726	0.085	<b>0.013</b>		
60	ACC	81.53	84.65	<b>87.05</b>	7.65	82.9
	PR	79.63	83.91	<b>85.94</b>		
	REC	75.93	79.50	<b>83.49</b>		
	F1	77.08	80.99	<b>84.53</b>		
	Test zamanı(sn)	0.995	0.130	<b>0.012</b>		
100	ACC	85.30	86.96	<b>88.66</b>	8.9	78.57
	PR	84.17	87.43	<b>87.78</b>		
	REC	81.19	82.61	<b>85.69</b>		
	F1	82.42	84.39	<b>86.61</b>		
	Test zamanı(sn)	1.100	0.123	<b>0.014</b>		

### III. DENEYSEL ÇALIŞMA VE SONUÇLAR

Yapılan çalışmada, ESA, RF ve XGBoost yöntemleri BloodMNIST [9] veri kümesi üzerinde karşılaştırılmıştır. Şekil 2'de deneysel çalışmalar için oluşturulan ESA mimarisi ile, RF ve XGBoost algoritmalarının ilişkisi gösterilmektedir. Bu ilişki incelendiğinde önerilen yapının iki parçadan oluştuğu görülmektedir: Özellik çıkarıcı ve sınıflandırıcı. Özellik çıkarıcı işlemi, karşılaştırılan üç yöntem için de aynı şekilde gerçekleştirilmektedir. ESA, BloodMNIST veri kümesi üzerinde eğitilir ve eğitilen ağırlıklar saklanır. Tüm yöntemler için verilen görüntüden gömme (ing: embedding) vektörünü

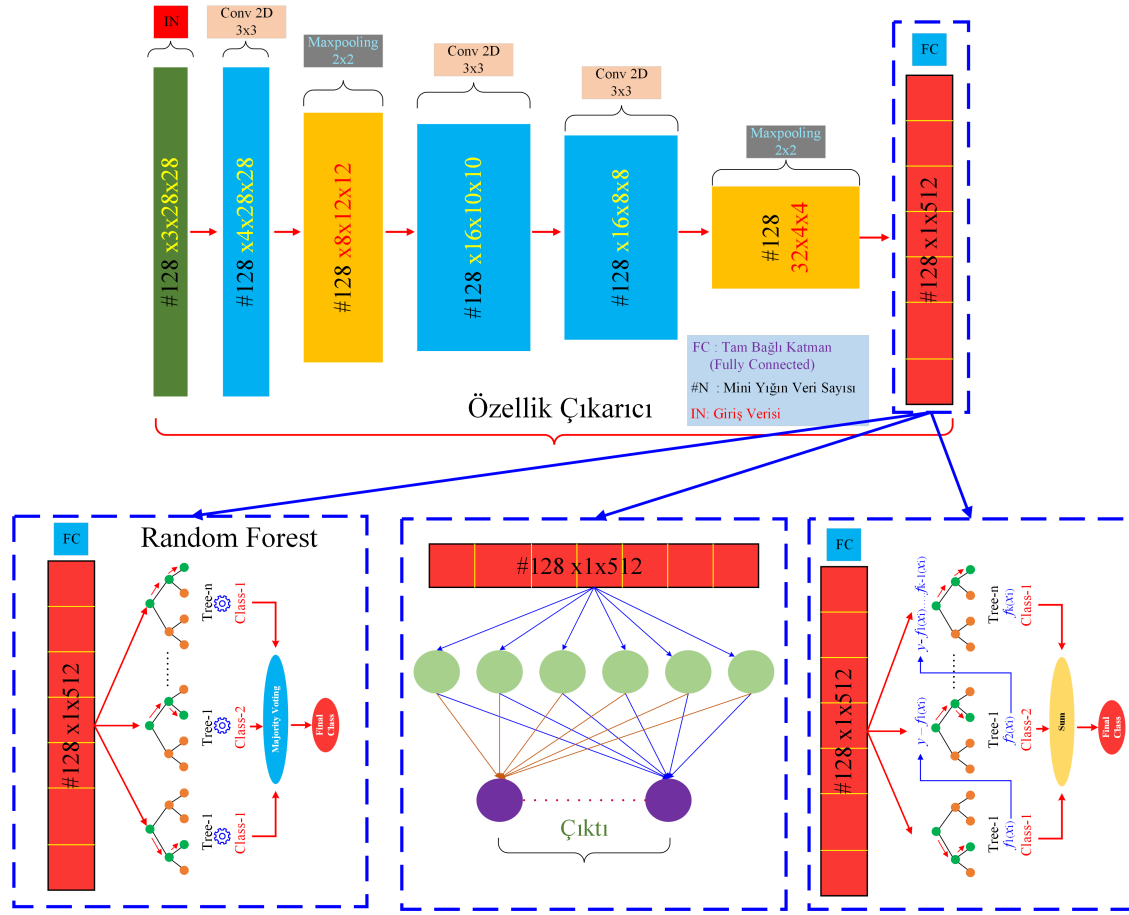
çıkarma işlemi eğitilmiş olan bu ağırlıklar ile gerçekleştirilir (bkz. Şekil 2 özellik çıkarıcı kısmı). Sınıflandırıcı kısmında ise 2 farklı yaklaşım kullanılmıştır:

- 1) ESA, özellik çıkarıcıdan gelen gömme vektörünü tam bağlantılı katmana besler ve bu katmanlar ile sınıflandırma işlemini gerçekleştirir.
- 2) RF ve XGBoost algoritmaları ise verilen görüntü için önceden eğitilmiş olan evrişimli sinir ağından gelen gömme vektörünü girdi olarak alır ve bu vektörü kullanarak tahmin işlemini gerçekleştirir.

Sonuç olarak ESA, eğitilmiş olan ağırlıkları kullanarak verilen görüntüden özellikler çıkarır ve oluşan gömme vektörünü sınıflandırma işlemi için bu algoritmalara besler. Böylece, evrişimli sinir ağından elde edilen öznelilikler, RF ve XGBoost algoritmalarının eğitiminde kullanılır.

BloodMNIST veri kümesinde 8 sınıfa ait  $28 \times 28 \times 3$  boyutunda toplam 17092 adet görüntü bulunmaktadır. Veri kümesindeki görüntüler eğitim, test, doğrulama kümeleri olacak şekilde sırasıyla 7 : 2 : 1 oranlarında bölünmüş ve ilgili kümeler için [11959, 3421, 1712] adet görüntü kullanılmıştır. Girdi görüntüsü boyutu, ESA kullanılarak gerçekleştirilen evrişim operasyonları sonucunda  $32 \times 4 \times 4$  boyutuna indirgenmiş ve düzleştirme (ing: flatten) işlemi sonucunda  $1 \times 512$  boyutunda gömme vektörü elde edilmiştir. Hesaplanan gömme vektörü hem RF hemde XGBoost modellerinde kullanılan giriş verisinin boyutunu temsil etmektedir. Ağaç temelli sınıflandırıcıların eğitim ve test işleminde kullanılan verilerin boyutları sırasıyla şu şekildedir, [11959  $\times$  512], [3421  $\times$  512]. Bu boyutlar, sırasıyla [eğitim örnek sayısı  $\times$  gömme vektörü boyutu] ve [test örnek sayısı  $\times$  gömme vektörü boyutu] şeklinde açıklanabilir.

Eğitilen ağaç temelli algoritmalar ve ESA, BloodMNIST test görüntüleri üzerinde ayrı ayrı doğruluk ve test zamanı bakımından karşılaştırılmış ve sonuçlar Tablo I'de raporlanmıştır. Tablo I'de  $PR = precision$ ,  $REC = recall$ ,  $F1 = F1score$ ,  $ACC = accuracy$ 'yi belirtmektedir. Karşılaştırılan sınıflandırıcıların başarılarının değerlendirilmesi için, ESA sırasıyla [30, 60, 100] eğitim dönemi boyunca eğitilmiştir. Farklı eğitim dönemleri boyunca eğitilen evrişimli sinir ağının ürettiği gömme vektörlerinin farklı sınıflandırıcılar üzerindeki etkisi incelenmiştir. Tablo I'de elde edilen sonuçlar incelendiğinde tüm eğitim dönemleri için RF ve XGBoost algoritmalarının hem sınıflandırma performansı hem çıkarım süresi açısından evrişimli sinir ağlarına göre daha iyi sonuçlar elde ettiği gözlemlenmiştir. ESA için eğitim adımlarının sayısı arttırıldıkça çıkarılan özelliklerin kalitesi arttığı için farklı sınıflandırma ölçütleri arasındaki fark azalmaktadır. Ancak, 30 eğitim adımı için elde edilen sonuçlara bakıldığında RF ve XGBoost'un evrişimli sinir ağına göre sırasıyla 8.49 ve 11.62 puan daha fazla doğruluk elde ettiği görülmektedir. Benzer durum, diğer sınıflandırma ölçütleri için de geçerlidir. Bu durum, RF ve XGBoost algoritmalarının daha az sayıda eğitim adımı ile üretilen gömme vektörleri için de daha iyi sonuçlar elde edebildiğini göstermektedir. Bu durum, eğitim işleminin maliyetli olduğu durumlar için önemlidir. Aynı zamanda, yöntemler çıkarım süresi açısından da kıyaslanmıştır. Bu süreler göz önüne alındığında, XGBoost'un karşılaştırılan diğer yöntemleri 82.9 kata kadar hızlandırdığı görülmektedir. Sonuç olarak, ağaç temelli yaklaşımların hem tüm sınıflandırma ölçütleri hem de çıkarım süreleri açısından evrişimli sinir ağından daha iyi sonuçlar elde



Şekil 2: Rastgele orman ve XGBoost ağaç temelli sınıflandırıcılar için özellik çıkarıcı olarak kullanılan hibrit evrişimli sinir ağı mimari yapısı

ettiği görülmüştür. Gelecek çalışmalarda, önerilen yöntemlerin farklı medikal görüntü sınıflandırma veri kümeleri üzerindeki performansı değerlendirilecektir.

#### KAYNAKLAR

- [1] A. A. Barbhuiya, R. K. Karsh, and R. Jain, "Cnn based feature extraction and classification for sign language," *Multimedia Tools and Applications*, vol. 80, no. 2, pp. 3051–3069, 2021.
- [2] T. He, Y. Liu, Y. Yu, Q. Zhao, and Z. Hu, "Application of deep convolutional neural network on feature extraction and detection of wood defects," *Measurement*, vol. 152, p. 107357, 2020.
- [3] D. M. U. Sabino *et al.*, "A texture approach to leukocyte recognition," *Real-Time Imaging*, vol. 10, no. 4, p. 205–216, Aug. 2004.
- [4] E. Gavas and K. Olpadkar, "Deep cnns for peripheral blood cell classification," *CoRR*, vol. abs/2110.09508, 2021.
- [5] R. Al-qudah and C. Y. Suen, "Improving blood cells classification in peripheral blood smears using enhanced incremental training," *Computers in Biology and Medicine*, vol. 131, p. 104265, Apr. 2021.
- [6] A. Şengür, Y. Akbulut, Ü. Budak, and Z. Cömert, "White blood cell classification based on shape and deep features," in *2019 International Artificial Intelligence and Data Processing Symposium (IDAP)*. Ieee, 2019, pp. 1–4.
- [7] R. B. Hegde, K. Prasad, H. Hebbar, and B. M. K. Singh, "Comparison of traditional image processing and deep learning approaches for classification of white blood cells in peripheral blood smear images," *Biocybernetics and Biomedical Engineering*, vol. 39, no. 2, pp. 382–392, 2019.
- [8] L. Ma, R. Shuai, X. Ran, W. Liu, and C. Ye, "Combining dc-gan with resnet for blood cell image classification," *Medical & biological engineering & computing*, vol. 58, pp. 1251–1264, 2020.
- [9] J. Yang, R. Shi, D. Wei, Z. Liu, L. Zhao, B. Ke, H. Pfister, and B. Ni, "Medmnist v2 - a large-scale lightweight benchmark for 2d and 3d biomedical image classification," *Scientific Data*, vol. 10, no. 1, Jan. 2023.
- [10] H. Aljumaily, D. F. Laefer, D. Cuadra, and M. Velasco, "Point cloud voxel classification of aerial urban lidar using voxel attributes and random forest approach," *International Journal of Applied Earth Observation and Geoinformation*, vol. 118, p. 103208, 2023.
- [11] U. Knauer, C. S. von Rekowski, M. Stecklina, T. Krokotsch, T. Pham Minh, V. Haufler, D. Kilias, I. Ehrhardt, H. Sagischewski, S. Chmara *et al.*, "Tree species classification based on hybrid ensembles of a convolutional neural network (cnn) and random forest classifiers," *Remote Sensing*, vol. 11, no. 23, p. 2788, 2019.
- [12] Z. Kaya, Z. Kuş, B. Kiraz, and G. Uludağ, "Machine learning approaches for cell viability," in *2023 31st Signal Processing and Communications Applications Conference (SIU)*, 2023, pp. 1–4.
- [13] S. Thongsuwan, S. Jaiyen, A. Padcharoen, and P. Agarwal, "Convxgb: A new deep learning model for classification problems based on cnn and xgboost," *Nuclear Engineering and Technology*, vol. 53, no. 2, pp. 522–531, 2021.
- [14] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.