

Model Hybrid CNN Mengintegrasikan *NasNetMobile* dan *MobileNet* untuk Meningkatkan Akurasi Klasifikasi *White Blood Cell*

Sandy Putra Siregar*, Anjar Wanto, Sundari Retno Andani

^{1,2,3}Prodi Informatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: ^{1,*}sandiputra@gmail.com, ²anjarwanto@amiktunasbangsa.ac.id, ³sundariretnoandani@gmail.com

Email Correspondencial : sandiputra@gmail.com

Abstrak—Sel darah putih merupakan komponen vital dalam sistem kekebalan tubuh pada manusia yang berperan penting dalam melindungi tubuh dari serangan mikroorganisme penyebab penyakit. Variabilitas hasil dalam klasifikasi sel darah putih yang disebabkan oleh keterbatasan metode identifikasi manual masih menjadi isu kritis bagi akurasi system diagnostic berbasis citra. Dalam studi ini difokuskan untuk mengatasi permasalahan tersebut dengan merancang model jaringan saraf konvolusional (CNN) *hybrid* baru yang dinamakan SAN-Net, yang mengintegrasikan keunggulan arsitektur *NASNetMobile* dan *MobileNet* guna meningkatkan akurasi dalam klasifikasi jenis sel darah putih (*basophil*, *erythroblast*, *monocyte*, *myeloblast*, dan *seg neutrophil*). Model yang diusulkan dilatih menggunakan dataset citra sel darah putih yang dikumpulkan dari Kaggle kemudian dibandingkan dengan arsitektur standar yakni *NASNetMobile*. Hasil Pengujian menunjukkan bahwa model SAN-Net memberikan performa terbaik, dengan capaian akurasi, presisi, recall, dan Skor F1 sebesar 99,80%, serta secara signifikan melampaui kinerja model pembandingan. Temuan ini mengindikasikan bahwa potensi arsitektur deep learning modern dalam menghadirkan sistem klasifikasi sel darah putih otomatis dengan konsisten dan akurat, sehingga dapat meningkatkan efisiensi proses diagnosis.

Kata Kunci: Klasifikasi Citra; Sel Darah Putih; *NASNetMobile*; *MobileNet*; SAN-Net

Abstract—White blood cells are a vital component of the human immune system, playing a crucial role in protecting the body from disease-causing microorganisms. Variability in white blood cell classification results due to the limitations of manual identification methods remains a critical issue for the accuracy of image-based diagnostic systems. This study focuses on addressing this issue by designing a new hybrid convolutional neural network (CNN) model called SAN-Net, which integrates the advantages of the *NASNetMobile* and *MobileNet* architectures to improve the accuracy of white blood cell type classification (*basophil*, *erythroblast*, *monocyte*, *myeloblast*, and *neutrophil*). The proposed model was trained using a white blood cell image dataset collected from Kaggle and then compared with the standard *NASNetMobile* architecture. Test results showed that the SAN-Net model provided the best performance, with an accuracy, precision, recall, and F1 score of 99.80%, significantly outperforming the benchmark model. These findings indicate the potential of modern deep learning architectures to deliver a consistent and accurate automated white blood cell classification system, thereby improving the efficiency of the diagnostic process.

Keywords: Image Classification; White Blood Cells; *NASNetMobile*; *MobileNet*; SAN-Net

1. PENDAHULUAN

Sel darah putih (white blood cells/WBC) berperan sebagai indikator penting yang mencerminkan aktivitas sistem imun manusia, yang pembentukannya dipengaruhi oleh faktor genetik maupun non-genetik [1], [2], [3]. Analisis terhadap 11.813 peserta dewasa dalam survei nasional kesehatan dan gizi Amerika Serikat (NHANES, 2009–2014) menunjukkan bahwa variabilitas kadar WBC dan komposisi diferensialnya mencerminkan respons imun terhadap faktor-faktor perilaku dan fisiologis [4]. Karakteristik jumlah, bentuk, serta proporsi antarjenis sel darah putih (white blood cell/WBC) memiliki peran krusial dalam menggambarkan kondisi fisiologis seseorang. Variasi morfologi dan distribusi WBC sering kali menjadi indikator diagnostik penting bagi sejumlah penyakit [5]. Darah putih khususnya neutrofil dan monosit, memiliki keterkaitan yang signifikan dengan pembentukan serta tingkat keparahan penumpukan plak pada arteri karotis (pembuluh darah di leher yang mengalir ke otak). Peningkatan konsentrasi WBC diketahui berhubungan dengan risiko yang lebih tinggi terhadap terjadinya aterosklerosis, terutama pada populasi laki-laki [6]. Oleh karena itu, WBC berpotensi digunakan sebagai biomarker penting dalam mendeteksi dan memantau perkembangan awal penyakit kardiovaskular secara lebih akurat dan preventif.

Kemampuan model deep learning yakni *NASNetMobile*, menunjukkan keberhasilan signifikan yang unggul dalam proses klasifikasi citra medis [7], [8], [9] dan deteksi penyakit [10], [11]. Efektivitas arsitektur *NASNetMobile* dalam menghadapi keterbatasan dataset serta kemampuannya dalam mendukung sistem diagnosis otomatis berbasis perangkat mobile dengan tingkat keandalan yang tinggi [12]. *MobileNet* merupakan salah satu arsitektur CNN yang memiliki parameter lebih sedikit, tetapi memiliki akurasi akurat dalam mengenali pola visual penyakit tanaman dengan melalui diagnosa otomatis berbasis citra [13], [14], [15]. Arsitektur yang ringan, cepat serta akurat membuat *MobileNet* mengintegrasikannya dengan model lain menjadi lebih mudah dan menghasilkan diagnosis awal yang andal [16], [17], [18]. Pendekatan ICAFF-MobileNetV2 yang dilakukan oleh [19] berhasil meningkatkan kinerja klasifikasi sel darah putih melalui kombinasi mekanisme koordinat perhatian dan modul ekstraksi fitur multiskala, menghasilkan akurasi klasifikasi sebesar 98.54% pada dataset campuran yang digunakan. Peningkatan ini menunjukkan keunggulan signifikan *MobileNetV2* yang dioptimalkan dalam menyeimbangkan efisiensi model dan ketepatan klasifikasi, menjadikannya solusi efektif untuk analisis medis berbasis citra dengan kompleksitas rendah namun akurasi tinggi. Sel darah putih sangat penting dalam sistem kekebalan tubuh dan membantu mendiagnosis penyakit seperti infeksi atau kanker. Penelitian ini menggunakan CNN untuk mengklasifikasikan lima jenis sel darah putih Monosit, Eosinofil, Basofil, Limfosit, dan Neutrofil dengan hasil akurasi 98,55% [20].

Model hibrida berbasis Deep Learning yang menggabungkan AlexNet, GoogLeNet, dan SVM terbukti mampu meningkatkan akurasi klasifikasi sel darah putih hingga 99,73%, menunjukkan bahwa pendekatan kombinasi ini sangat efektif dalam mengenali 4 jenis sel darah putih yakni eosinophil, limfosit, monosit, dan neutrofil secara tepat dan konsisten [21]. Sistem hibrida yang memadukan Convolutional Neural Network (CNN) sebagai ekstraktor fitur dengan algoritma pembelajaran mesin seperti Random Forest, SVM, dan KNN menunjukkan kinerja unggul dalam klasifikasi citra sel darah putih mikroskopis, di mana model berbasis Random Forest mencapai akurasi tertinggi sebesar 98,7% . Pendekatan hibrida yang menggabungkan model Convolutional Neural Network (CNN) dengan algoritma Support Vector Machine (SVM) menunjukkan keberhasilan luar biasa dalam klasifikasi 3 jenis sel darah putih yakni lymphocytes, monocytes dan neutrophils, dengan penggunaan model ResNet50 dengan SVM mencapai akurasi 99% [22]. Pendekatan hybrid yang dilakukan oleh [23] menggunakan metode discrete moment quaternion dan Convolutional Neural Network (CNN) berhasil meningkatkan kinerja klasifikasi empat jenis sel darah putih yakni neutrophils, lymphocytes, monocytes, dan eosinophils, berdasarkan data citra mikroskopis. Melalui optimasi fitur menggunakan Grey Wolf Optimization (GWO), model ini mencapai akurasi tinggi, yaitu 98.53% untuk neutrophils, 98.16% untuk lymphocytes, serta 97.43% untuk monocytes dan eosinophils, yang menunjukkan efektivitas pendekatan hibrida dalam pengenalan sel darah putih secara otomatis. Pada dasarnya, meskipun penerapan model CNN untuk klasifikasi sel darah putih telah banyak dilakukan, penelitian yang berfokus pada pengembangan dan evaluasi arsitektur hibrida yang disesuaikan dengan karakteristik morfologi sel darah masih relatif terbatas. Keunikan studi ini terletak pada perancangan model hybrid yang mengintegrasikan kekuatan arsitektur *NASNetMobile* dan *MobileNet* guna meningkatkan efisiensi ekstraksi fitur serta akurasi klasifikasi. Pendekatan ini tidak sekadar memanfaatkan model *pre-trained*, tetapi membangun jaringan baru yang menggabungkan kemampuan pencarian arsitektur adaptif dari *NASNet* dengan efisiensi komputasi tinggi dari *MobileNet*. Model yang diusulkan selanjutnya diuji secara komparatif terhadap versi standarnya untuk memvalidasi keunggulannya dalam mengidentifikasi jenis-jenis white blood cell secara otomatis dan presisi.


Oleh karena itu, penelitian ini berfokus pada perancangan dan pengembangan model *deep learning hybrid* berbasis kombinasi arsitektur *NASNetMobile* dan *MobileNet*, yang dirancang agar lebih adaptif terhadap keragaman morfologi sel darah putih. Tujuan utama penelitian ini adalah pengembangan arsitektur Convolutional Neural Network (CNN) hibrida yang mengintegrasikan efisiensi ekstraksi fitur dari *MobileNet* dengan kemampuan hierarkis *NASNetMobile* untuk menghasilkan representasi visual yang lebih adaptif guna meningkatkan akurasi dalam klasifikasi jenis sel darah putih . Berdasarkan latar belakang tersebut, penelitian ini berupaya menjawab bagaimana rancangan arsitektur CNN hibrida dapat secara signifikan meningkatkan akurasi identifikasi jenis-jenis white blood cell serta bagaimana kinerja model yang diusulkan dibandingkan dengan model standar yang telah ada. Pendekatan yang digunakan meliputi pengembangan dan optimasi jaringan saraf dalam melalui integrasi fitur adaptif *NASNetMobile* dengan efisiensi komputasi *MobileNet*, menggunakan teknik transfer learning dengan bobot pra-latih sebagai dasar untuk penyempurnaan model.

2. METODOLOGI PENELITIAN

Metodologi penelitian ini meliputi identifikasi masalah, pengumpulan dataset citra, tahap prapemrosesan, pembangunan model, evaluasi performa, serta analisis komparatif terhadap arsitektur CNN konvensional yang telah ada.

2.1 Tahapan Penelitian

Dalam menjawab tujuan penelitian secara sistematis dan memperoleh pemahaman menyeluruh terhadap pendekatan yang diusulkan, bagian ini menyajikan kerangka konseptual penelitian secara komprehensif. Kerangka tersebut menggambarkan alur proses penelitian secara berurutan, dimulai dari tahap identifikasi permasalahan hingga penerapan model akhir, dengan menekankan langkah-langkah metodologis utama seperti pengumpulan data, tahap prapemrosesan, perancangan model, serta proses evaluasi kinerja.




Gambar 1. Tahapan Penelitian


Kerangka penelitian ini diawali dengan proses identifikasi permasalahan serta pengumpulan dan pelabelan sistematis terhadap dataset citra sel darah putih yang representatif. Tahap prapemrosesan meliputi normalisasi intensitas piksel dan augmentasi citra guna meningkatkan kemampuan generalisasi model. Model dilatih menggunakan optimizer Adam untuk menghindari overfitting selama proses pelatihan. Komponen utama dari kerangka ini mencakup evaluasi komparatif antara model hibrida yang diusulkan dengan arsitektur konvensional seperti MobileNet dan NASNetMobile murni. Penilaian kinerja dilakukan berdasarkan metrik akurasi, presisi, recall, dan F1-score, disertai analisis matriks kebingungan untuk mendeteksi kesalahan klasifikasi antar jenis sel. Selain itu, kurva loss pelatihan dan validasi dianalisis secara mendalam untuk memastikan stabilitas model dan kemampuan generalisasi yang optimal.

2.2 Data Penelitian


Dataset yang digunakan dalam penelitian ini terdiri dari citra sel darah putih yang mewakili berbagai tipe sel : basophil, erythroblast, monocyte, myeloblast, dan seg neutrophil. Data penelitian ini dikumpulkan dari Kaggle sebanyak 5000 data citra yang masing-masing kelas memiliki 1000 citra.




Gambar 2. Sel Darah Putih Jenis Basophil




Gambar 3. Sel Darah Putih Jenis Erythroblast



Gambar 3. Sel Darah Putih Jenis Monocyt



Gambar 4. Sel Darah Putih Jenis Myeloblast



Gambar 5. Sel Darah Putih Jenis Seg Neutrophil

2.3 Pengusulan Model


Penelitian ini memperkenalkan arsitektur Convolutional Neural Network (CNN) hibrida yang menggabungkan keunggulan NASNetMobile dan MobileNet untuk meningkatkan akurasi klasifikasi sel darah putih. MobileNet menghadirkan desain konvolusi ringan dengan depthwise separable convolution, memungkinkan jaringan untuk menangkap fitur multi-skala secara efisien dengan biaya komputasi yang lebih rendah. Integrasi kedua arsitektur ini memanfaatkan keunggulan komplementer antara adaptabilitas NASNetMobile dan efisiensi MobileNet, menghasilkan model hibrida yang mampu mengekstraksi representasi fitur yang kuat dari berbagai tipe white blood cell. Dibawah ini merupakan model yang diusulkan atau *proposed hybrid model* (SAN-Net) kebaruan yang dapat dilihat pada tabel 1.

Tabel 1. Proposed Architecture of The Hybrid Model (SAN-Net)

Layer	Output Size	Detail /Param
Input	224x224x3	Input Image
NASNet (Functional)	7x7x1059	4269716

Layer	Output Size	Detail /Param
MobileNet (Functional)	7x7x1024	3228864
GlobalAveragePooling2D	1056	
GlobalAveragePooling2D	1024	
Concatenate	2080	
Dropout	512	
BatchNormalization	512	2048
Dropout_1	256	
BatchNormalization_1	256	1024
Output Dense	Classes = 4	1285

Arsitektur Hybrid CNN dikembangkan sebagai model konvolusional hibrida yang mengintegrasikan dua backbone utama, yaitu NASNet dan MobileNet, guna meningkatkan kapasitas representasi fitur visual serta efisiensi komputasi dalam proses klasifikasi citra. Citra masukan berukuran $224 \times 224 \times 3$ diproses secara paralel oleh kedua jaringan tersebut, di mana NASNet menghasilkan fitur beresolusi tinggi dengan kedalaman 1056 kanal, sementara MobileNet mengekstraksi fitur ringan berdimensi 1024 melalui mekanisme *depthwise separable convolution* dan *inverted residual connection*. Hasil ekstraksi dari kedua jaringan kemudian disarikan menggunakan *Global Average Pooling* dan digabungkan (*concatenated*) menjadi satu vektor berdimensi 2080 untuk memperoleh representasi yang lebih komprehensif. Tahap selanjutnya melibatkan serangkaian lapisan *Dense* 512, 256 dengan aktivasi *ReLU*, disertai penerapan *Dropout* (0,5 dan 0,3) dan *BatchNormalization* untuk mengoptimalkan stabilitas pelatihan serta meminimalkan risiko *overfitting*. Proses klasifikasi akhir dilakukan melalui lapisan *Softmax* dengan lima neuron keluaran yang merepresentasikan probabilitas masing-masing kelas target. Kombinasi dua arsitektur modern ini memberikan keseimbangan antara kedalaman representasi dan efisiensi parameter, sehingga menghasilkan model yang adaptif, robust, dan memiliki kinerja yang lebih baik dalam melakukan klasifikasi.



(a) Model Hybrid Diusulkan (SAN-Net)

(b) Arsitektur Dasar NASNet


Gambar 6. Perbandingan Arsitektur

Warna Jingga menunjukkan komponen kebaruan yang tidak ada pada NASNet Standar

3. HASIL DAN PEMBAHASAN

3.1 Analisis Kemampuan Pelatihan Model

Penelitian yang dilakukan, melibatkan pelatihan 2 model utama: *NASNetMobile Baseline* dan Proposed Hybrid NASNet-MobileNet (SAN-Net). Visualisasi kurva akurasi serta nilai *loss*/kesalahan pada tahap pelatihan dan validasi memberikan gambaran menyeluruh mengenai performa dan perilaku masing-masing model. Sebagaimana ditunjukkan pada Gambar 7.



(b) Hybrid Model (SAN-Net) - Proposed
Gambar 7. Hasil Perbandingan dari semua pelatihan model (Akurasi dan Kesalahan)


Penelitian ini menggunakan 2 model yakni NASNet Standar dengan Model yang diusulkan Hybrid NASNet-MobileNet (SAN-Net). Pada model NASNet Standar (Gambar 7.a) Grafik akurasi dan loss/kesalahan menunjukkan perkembangan kinerja model deep learning selama proses pelatihan 20 epoch. Nilai akurasi pelatihan meningkat hingga sekitar 98%, sedangkan akurasi validasi mencapai 95%, yang menandakan bahwa model mampu mempelajari pola data dengan baik dan memiliki kemampuan generalisasi yang cukup baik terhadap data baru. Penurunan loss yang konsisten pada data pelatihan dan validasi menunjukkan efektivitas proses pembelajaran, meskipun terdapat sedikit fluktuasi pada loss validasi di akhir pelatihan yang mengindikasikan tanda awal overfitting. Secara keseluruhan, model ini menunjukkan performa yang stabil dan efisien, namun tetap memerlukan pengawasan agar tidak kehilangan kemampuan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Model hybrid SAN-Net (7.b) Grafik akurasi model menunjukkan peningkatan signifikan pada data pelatihan dan validasi selama 20 epoch. Akurasi pelatihan yang awalnya sekitar 80% meningkat mencapai 99,80%, sementara akurasi validasi stabil di kisaran 97–99%, menandakan bahwa model mampu mengenali pola dengan baik pada data yang belum pernah dilihat tanpa mengalami overfitting berlebihan. Sementara itu, grafik loss model memperlihatkan penurunan tajam dari sekitar 0,2750 menjadi 0,0073 pada data pelatihan, dengan nilai loss validasi juga menurun dan stabil pada tingkat rendah. Meskipun terdapat sedikit fluktuasi pada loss validasi, hal ini tergolong wajar karena perbedaan karakteristik data. Secara keseluruhan, perbedaan kecil antara loss pelatihan dan validasi menunjukkan bahwa model telah belajar secara efektif dan memiliki kemampuan generalisasi yang baik terhadap data baru.

3.2 Matriks Perbandingan Evaluasi Model


Kinerja kedua model dianalisis menggunakan berbagai metrik evaluasi yang komprehensif guna memperoleh pemahaman menyeluruh mengenai kemampuan klasifikasi masing-masing. Evaluasi mencakup pengukuran akurasi, presisi, recall, dan F1-score, yang diperkuat dengan analisis visual melalui matriks kebingungan (Gambar 8), kurva presisi–recall (Gambar 9), serta perbandingan akurasi tiap kelas (Gambar 10) untuk menilai performa model secara lebih mendalam.

Matriks kebingungan pada Gambar 8 menggambarkan distribusi hasil prediksi yang benar dan salah pada setiap kelas. Model hybrid NASNet–MobileNet yang dikembangkan menunjukkan kinerja klasifikasi yang sangat akurat walaupun hanya memiliki kesalahan pada 1 citra kategori sel darah putih erythroblast dengan basophil, menandakan kemampuannya dalam membedakan fitur visual yang halus antar kelas. Sementara itu, model pembandingan seperti NASNetMobile standar memberikan hasil yang baik namun masih memperlihatkan sedikit

kesalahan klasifikasi, menunjukkan performa yang lebih rendah, dengan sejumlah besar kesalahan prediksi antar kelas, yang mengindikasikan keterbatasannya dalam mengenali kompleksitas struktur visual pada citra sel darah putih.




(a) Model NASNet Standar



(b) Model Hybrid (SAN-Net)

Gambar 8. Confusion Matriks

Perbandingan akurasi per kelas pada Gambar 9 semakin menegaskan hasil evaluasi, di mana model Hybrid NASNet–MobileNet mencapai tingkat akurasi hampir sempurna pada seluruh kategori sel darah putih. NASNetMobile memperlihatkan hasil yang menunjukkan performa yang kurang konsisten dengan akurasi cukup tinggi tetapi model terindikasi *overfitting* pada sebagian besar kelas dengan kemiripan morfologi tinggi, terutama pada kategori yang memiliki ciri visual kompleks.



Gambar 9. Perbandingan Akurasi Berdasarkan Kelas WBC

Hasil evaluasi menyeluruh mengindikasikan bahwa model hibrida NASNetMobile–MobileNet menunjukkan performa yang lebih baik dibandingkan NASNetMobile standar dalam tugas klasifikasi sel darah putih. Konsistensi peningkatan akurasi dan stabilitas lintas kelas memperlihatkan bahwa penggabungan fitur efisien dari MobileNet

dengan struktur NASNet meningkatkan kemampuan model dalam menangkap perbedaan morfologis halus pada citra sel.


3.3 Pembahasan Hasil Pengujian

Hasil evaluasi eksperimental memberikan pemahaman mendalam tentang tingkat efektivitas masing-masing model dalam melakukan klasifikasi terhadap jenis sel darah putih (tabel 2).

Tabel 2. Perbandingan Kinerja Model Berdasarkan Akurasi, Presisi, Recall dan F1-Score

Model	Akurasi	Presisi	Recall	F1-Score
NASNetMobile	0,9547	0,9540	0,9540	0,9560
SAN-Net	0,9980	0,9980	0,9980	0,9980

Model hybrid NASNetMobile–MobileNet menunjukkan kinerja luar biasa dalam mengklasifikasikan citra sel darah putih ke dalam lima kategori utama, yaitu basophil, erythroblast, monocyte, myeloblast, dan seg neutrophil. Akurasi hampir sempurna yang dicapai menegaskan kemampuan model dalam mengenali pola morfologis kompleks, termasuk variasi bentuk inti, ukuran sitoplasma, serta distribusi granula. Hasil evaluasi memperlihatkan bahwa model mampu mengekstraksi dan menggeneralisasi fitur visual penting dari data uji yang belum pernah dilihat sebelumnya. Kesesuaian antara label prediksi (“*Pred*” atau “*Prediction*”) dan label aktual atau kebenaran (“*True*”) menunjukkan stabilitas dan keandalan arsitektur hybrid. Secara keseluruhan, hasil ini mengonfirmasi bahwa NASNetMobile–MobileNet tidak hanya unggul pada metrik evaluasi standar tetapi juga memiliki potensi kuat untuk diaplikasikan pada kondisi nyata dengan tingkat akurasi yang sangat baik dan akurat. Dibawah ini hasil prediksi model hybrid (SAN-Net) menampilkan 10 gambar sampel seperti yang dapat dilihat pada gambar 10.



Gambar 10. Hasil Prediksi Menggunakan Model Hybrid (SAN-Net)

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model *deep learning* hibrida NASNetMobile–MobileNet untuk klasifikasi sel darah putih secara otomatis. Arsitektur ini menggabungkan kemampuan NASNetMobile dalam pencarian arsitektur optimal dengan efisiensi komputasi dari MobileNet, sehingga meningkatkan kemampuan model dalam mengekstraksi fitur morfologis penting dari citra mikroskopik. Hasil eksperimen menunjukkan bahwa model hibrida ini mencapai akurasi, presisi, recall, dan F1-score sebesar 99,80%, serta mampu mengenali variasi halus pada bentuk inti dan struktur sitoplasma sel. Evaluasi komprehensif menggunakan matriks kebingungan memperkuat bukti bahwa model ini memiliki stabilitas dan generalisasi yang baik terhadap data uji. Temuan ini menegaskan potensi integrasi dua arsitektur CNN dalam mendukung sistem diagnosis hematologi berbasis kecerdasan buatan yang lebih akurat. Sebagai arah penelitian selanjutnya, model ini dapat dikembangkan lebih lanjut dengan penambahan mekanisme interpretabilitas (explainable AI), augmentasi data berbasis GAN, serta pengujian pada dataset multi-sumber untuk memperluas kemampuan generalisasi dan kesiapan penerapan klinis di dunia nyata.

REFERENCES

- [1] I. Barroso, “White blood cells in a healthy adolescent population according to social and health characteristics,” *Arch. Pediatr.*, vol. 30, no. 6, pp. 361–365, 2023, doi: 10.1016/j.arcped.2023.03.008.
- [2] Z. Li, “The association between white blood cell counts and metabolic health obesity among US adults,” *Front. Nutr.*, vol. 12, 2025, doi: 10.3389/fnut.2025.1458764.
- [3] K. Ryan, “White blood cell estimates correlate to measures of population and individual health in an endangered population of Marbled Murrelets (*Brachyramphus marmoratus*),” *Front. Vet. Sci.*, vol. 12, 2025, doi: 10.3389/fvets.2025.1545905.
- [4] H. A. Beydoun, “Periodontal disease, sleep duration, and white blood cell markers in the 2009 to 2014 National Health and Nutrition Examination Surveys,” *J. Periodontol.*, vol. 91, no. 5, pp. 582–595, 2020, doi: 10.1002/JPER.19-0055.
- [5] L. Amalia, “Clinical significance of Platelet-to-White Blood Cell Ratio (PWR) and National Institute of Health Stroke Scale

- (NIHSS) in acute ischemic stroke,” *Heliyon*, vol. 6, no. 10, 2020, doi: 10.1016/j.heliyon.2020.e05033.
- [6] Y. Liu, “Association of the Total White Blood Cell, Neutrophils, and Monocytes Count With the Presence, Severity, and Types of Carotid Atherosclerotic Plaque,” *Front. Med.*, vol. 7, 2020, doi: 10.3389/fmed.2020.00313.
- [7] M. M. Ahsan, “COVID-19 Symptoms Detection Based on NasNetMobile with Explainable AI Using Various Imaging Modalities,” *Mach. Learn. Knowl. Extr.*, vol. 2, no. 4, pp. 490–504, 2020, doi: 10.3390/make2040027.
- [8] P. R. Tammanashastri, “Deep Learning-Based Analysis of Pediatric Pneumonia Detection in Children using Fine-tuned NasNetMobile Model,” *3rd Int. Conf. Commun. Control Intell. Syst. Ccis 2024*, 2024, doi: 10.1109/CCIS63231.2024.10931870.
- [9] M. A. S. A. G. Abdullah, “Face Mask Detection During COVID-19 Pandemic using NASNetMobile and CNN Deep Learning Algorithms,” *4th Int. Conf. Curr. Res. Eng. Sci. Appl. Iccresa 2022*, pp. 137–142, 2022, doi: 10.1109/ICCRESA57091.2022.10352501.
- [10] H. K. Dishar, “Detection Brain Tumor Disease Using a Combination of Xception and NASNetMobile,” *Int. J. Adv. Soft Comput. Its Appl.*, vol. 15, no. 2, pp. 325–336, 2023, doi: 10.15849/IJASCA.230720.22.
- [11] Z. A. Altomi, “Autism Spectrum Disorder Diagnosis Based on Attentional Feature Fusion Using NasNetMobile and DeiT Networks,” *Electron. Switz.*, vol. 14, no. 9, 2025, doi: 10.3390/electronics14091822.
- [12] I. Hestningsih, “Mobile Skin Disease Classification using MobileNetV2 and NASNetMobile,” *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 13, no. 4, pp. 1472–1479, 2023, doi: 10.18517/ijaseit.13.4.18290.
- [13] E. Elfatimi, R. Eryigit, and L. Elfatimi, “Beans Leaf Diseases Classification Using MobileNet Models,” *IEEE Access*, vol. 10, pp. 9471–9482, 2022, doi: 10.1109/ACCESS.2022.3142817.
- [14] D. Mamadou, “Cocoa Pods Diseases Detection by MobileNet Confluence and Classification Algorithms,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 9, pp. 344–352, 2023, doi: 10.14569/IJACSA.2023.0140937.
- [15] S. Z. M. Zaki, “Classification of tomato leaf diseases using mobilenet v2,” *Iaes Int. J. Artif. Intell.*, vol. 9, no. 2, pp. 290–296, 2020, doi: 10.11591/ijai.v9.i2.pp290-296.
- [16] A. Mahalaxmi, “Alzheimer’s Disease Multi-task Classification Using ResNet, MobileNet,” *Lect. Notes Networks Syst.*, vol. 1200, pp. 645–656, 2025, doi: 10.1007/978-981-97-9926-8_49.
- [17] X. Sang, “A real-time and high-performance MobileNet accelerator based on adaptive dataflow scheduling for image classification,” *J. Real Time Image Process.*, vol. 21, no. 1, 2024, doi: 10.1007/s11554-023-01378-5.
- [18] L. Wang, “Classification of Breast Lesions on DCE-MRI Data Using a Fine-Tuned MobileNet,” *Diagnostics*, vol. 13, no. 6, 2023, doi: 10.3390/diagnostics13061067.
- [19] Y. Zou, L. Wu, C. Zuo, L. Chen, B. Zhou, and H. Zhang, “White blood cell classification network using MobileNetv2 with multiscale feature extraction module and attention mechanism,” *Biomed. Signal Process. Control*, vol. 99, p. 106820, 2025, doi: <https://doi.org/10.1016/j.bspc.2024.106820>.
- [20] A. Girdhar, “Classification of White blood cell using Convolution Neural Network,” *Biomed. Signal Process. Control*, vol. 71, 2022, doi: 10.1016/j.bspc.2021.103156.
- [21] A. Çınar, “Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-GoogleNet-SVM,” *SN Appl. Sci.*, vol. 3, no. 4, 2021, doi: 10.1007/s42452-021-04485-9.
- [22] T. S. Almurayziq, “Deep and Hybrid Learning Techniques for Diagnosing Microscopic Blood Samples for Early Detection of White Blood Cell Diseases,” *Electron. Switz.*, vol. 12, no. 8, 2023, doi: 10.3390/electronics12081853.
- [23] M. A. Tahiri, “White blood cell automatic classification using deep learning and optimized quaternion hybrid moments,” *Biomed. Signal Process. Control*, vol. 86, 2023, doi: 10.1016/j.bspc.2023.105128.