

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penulis menemukan beberapa penelitian terdahulu terkait klasifikasi dari penyakit ALL dengan metode yang berbeda, seperti model yang berbeda, dataset yang berbeda, dan cara pengolahan data yang berbeda.

2.1.1 Lightweight EfficientNetB3 Model based on Depthwise Separable Convolutions for Enhancing Classification of Leukemia White Blood Cell Images[4]

Penelitian dengan judul “Lightweight EfficientNetB3 Model based on Depthwise Separable Convolutions for Enhancing Classification of Leukemia White Blood Cell Images” yang dilakukan oleh Amreen Batool dan Yung-Cheol Byun. Penelitian ini bertujuan untuk mempercepat dan meningkatkan performa dari klasifikasi sel darah putih leukemia dengan menggunakan EfficientNetB3 yang diubah supaya menjadi model yang lebih ringan. Dataset yang dipakai pada penelitian ini didapat dari C_NMC 2019 yang berjumlah 15114 gambar ALL yang didapat dari 118 subjek. Hasil akurasi dari penelitian ini adalah 97.94% dengan F1 score 98.48%

Beberapa poin penting yang dapat diambil oleh penulis adalah :

- Dataset yang digunakan memiliki gambar lebih dari 15 ribu
- Model yang dipakai yaitu EfficientNetB3 merupakan model yang relatif ringan dan memiliki performa yang baik pada penelitian ini, menjadi acuan bagi penulis

2.1.2 Customized Deep Learning Classifier for Detection of Acute Lymphoblastic Leukemia Using Blood Smear Images[5]

Penelitian dengan judul “Customized Deep Learning Classifier for Detection of Acute Lymphoblastic Leukemia Using Blood Smear Images” dilakukan oleh Niranjana Sampathila, Krishnaraj Chadaga, dkk. Penelitian ini bertujuan untuk membuat sebuah model klasifikasi berbasis CNN khusus untuk penyakit ALL yang dinamakan ALLNET. Penelitian ini juga menggunakan gambar mikroskopik dari sel leukemia tersebut yang didapat dari dataset C_NMC 2019. Hasil akurasi maksimum yang didapat adalah 95.54% dengan F1 score 95.43%. Menurut peneliti, teknik yang mereka gunakan bisa membantu pada saat *pre-screening* untuk mendeteksi sel leukemia pada saat *complete blood count (CBC)* dan *peripheral blood tests*.

Beberapa poin penting yang dapat diambil oleh penulis adalah:

- Model yang dikustomisasi khusus untuk ALL dapat meraih performa yang sangat baik
- Penggunaan epoch yang berlebihan membuat model tersebut menjadi *overfitting*. *Overfitting* ini terjadi pada epoch lebih dari 70, maka dari itu peneliti menggunakan epoch sebanyak 65.
- Dataset pada penelitian ini dibagi dengan rasio 80:20 antara data train dan test, lalu diberikan lagi *5 fold cross validation* pada data train tersebut

2.1.3 Classification of Leukemia and Leukemoid Using VGG-16 Convolutional Neural Network Architecture[8]

Penelitian dengan judul “Classification of Leukemia and Leukemoid Using VGG-16 Convolutional Neural Network Architecture” dilakukan oleh G. Sriram, T. R. Ganesh Babu, R. Praveena, dan J. V. Anand. Penelitian ini bertujuan untuk membuat model yang bisa mengklasifikasikan antara leukemia dan leukemoid dimana di kedua reaksi

tersebut bisa memiliki leukocytosis, dan bisa membuat dokter salah mendiagnosa. Model yang dipakai pada penelitian ini adalah VGG-16 dan dataset yang dipakai adalah BCCD untuk pengujian penghitungan sel darah putih, dan ALL-IDB untuk pengujian klasifikasi penyakit ALL. Akurasi yang didapat untuk kedua pengujian tersebut berkisar dari 98.4% sampai 98.8%.

Beberapa poin penting yang dapat diambil oleh penulis adalah:

- Hasil train accuracy dan validation accuracy memiliki jarak yang cukup jauh, hal ini menandakan bahwa model tersebut mengalami overfitting dan memiliki kemungkinan untuk tidak berperforma baik dengan dataset baru yang sedikit berbeda dengan dataset yang digunakan untuk pelatihan.
- Grafik akurasi dan loss dari validasi memiliki variasi yang cukup besar setiap beberapa epoch, hal ini menandakan bahwa model belum stabil dan ada kemungkinan model belum mempelajari pola data secara benar. Dengan begitu dikhawatirkan bahwa model tidak akan memiliki performa yang bagus dengan data yang sedikit berbeda dari data latih yang dipakai

2.1.4 Deep Learning Approach for Segmentation and Classification of Blood Cells Using Enhanced CNN[9]

Penelitian dengan judul “Deep learning approach for segmentation and classification of blood cells using enhanced CNN” dibuat oleh B. Hemalatha, B. Karthik, C. V. Krishna Reddy, A Latha. Penelitian ini memiliki tujuan untuk membantu dalam penghitungan jumlah sel darah pada tubuh. Penelitian ini lebih memfokuskan dibagian sel darah merah, dimana akan dilakukan klasifikasi antara sel darah merah yang normal dan abnormal. Gambar mikroskopik dari dataset akan dilakukan segmentasi menggunakan K-Means berdasarkan nilai K-Centroid. Setelah itu akan

dilakukan *feature extraction* dilanjutkan dengan klasifikasi dengan model *Enhanced CNN* yang memiliki konsep dengan basis *Feed Forward Neural Networks*. Model tersebut memiliki akurasi maksimum 95.2% dan presisi maksimum 93%.

Beberapa poin penting yang dapat diambil oleh penulis adalah:

- Menggunakan model berbasis CNN bisa memiliki performa yang tinggi dalam pengklasifikasian gambar
- Penggunaan gambar dengan jumlah semakin banyak dapat meningkatkan performa kedua model yaitu CNN dan ECNN

2.2 Tinjauan Teori

2.2.1 Deep Learning

Deep learning adalah salah satu bagian dari *machine learning*, yang sebenarnya adalah *neural network* dengan 3 atau lebih lapisan[10]. *Neural network* ini mencoba untuk menirukan cara otak manusia berperilaku, terutama dalam hal pembelajaran, sehingga bisa mempelajari data dalam jumlah besar. Walaupun satu lapisan *neural network* bisa melakukan prediksi, akan tetapi lapisan yang tersembunyi dapat membantu memperbaiki dan mengoptimisasi dari segi akurasi. .

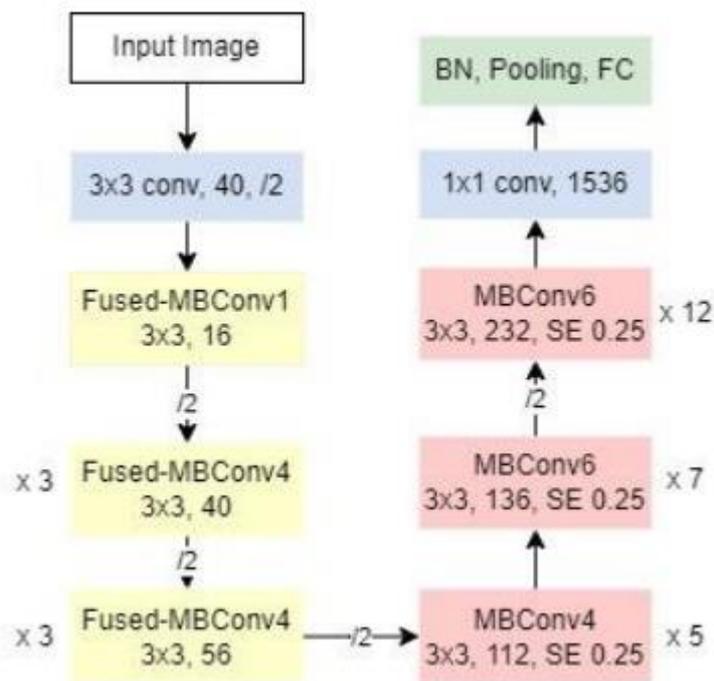
Deep learning bisa dibagi menjadi 3 kategori yaitu *unsupervised learning*, *semi-supervised learning* dan *supervised learning*. *Unsupervised learning* adalah sistem pembelajaran yang dimana datanya tidak diberikan label sama sekali, contohnya yaitu autoencoders. *Supervised learning* adalah sistem pembelajaran yang dimana semua datanya sudah diberikan label, contohnya yaitu CNN. Sementara *semi-supervised learning* adalah sistem pembelajaran dimana sebagian data memiliki label, dan sisanya tidak, dengan contohnya yaitu *Generative Adversarial Network*.

2.2.2 CNN

CNN atau *Convolutional Neural Network*, adalah salah satu deep learning dengan kategori supervised learning, dimana *neural network* ini memiliki kemampuan khusus dalam memproses data yang memiliki topologi berbentuk *grid*, seperti gambar[11]. Sebuah gambar tersusun dari pixel-pixel yang dimana setiap pixel memiliki nilai yang menentukan warna dan kecerahan dari pixel tersebut. CNN sendiri biasa memiliki 3 jenis lapisan yang terdiri dari lapisan *convolutional*, lapisan *pooling*, dan lapisan *fully connected*. Ketiga lapisan itu bisa berjumlah puluh ribu atau bahkan ratus ribu lapisan yang dimana setiap lapisan tersebut belajar untuk mendeteksi fitur yang berbeda dari setiap gambar. Sebuah filter akan diaplikasikan kepada setiap data latih dengan resolusi yang berbeda, dan hasilnya akan digunakan sebagai masukan untuk lapisan selanjutnya.

2.2.3 EfficientNetV2B3

EfficientNetV2B3 adalah sebuah model yang sudah dilatih dari keluarga EfficientNet dan merupakan versi yang lebih baru dari model EfficientNetV2B3. EfficientNet sendiri adalah keluarga model yang diciptakan untuk menjadi model yang ringan dan dapat diproses dengan cepat. Keluarga model ini mengusung sebuah metode *scaling* yang baru dimana semua dimensi dari *depth*, *width*, dan *resolution* akan dilakukan *scale* secara merata[12]. Metode ini sangat mudah akan tetapi sangat efisien dan biasa juga disebut sebagai *compound scaling*. Tentu saja karena model ini adalah pembaharuan dari EfficientNetB3, maka model ini akan memiliki ciri-ciri yang sama, salah satunya yaitu *input shape* yang diharapkan adalah 300x300 dengan perubahan yaitu kecepatan pelatihan yang lebih cepat dan efisiensi parameter yang lebih bagus. Berikut gambar 2.1 yang menggambarkan arsitektur dari model EfficientNetV2B3.



Gambar 2.0.1 Arsitektur dari EfficientNetV2B3[13]

2.2.4 Explainable AI

Explainable AI atau XAI yang lebih dikenal juga sebagai Interpretable AI, adalah sebuah alat untuk menjelaskan hasil prediksi dari sebuah model AI. Bagian mana yang dilihat oleh model tersebut dan yang menjadi biasanya, bisa dijelaskan menggunakan XAI[14]. Seiring berkembangnya jaman, AI menjadi sangat kompleks sehingga insinyur atau *data scientists* yang menciptakan algoritma dan model AI tersebut tidak mengerti apa yang terjadi didalam proses penghitungan dari model tersebut. Metode ini sangat berguna terutama untuk memeriksa cara kerja dari model AI tersebut sehingga bisa memastikan apakah bagian yang diambil dari data yang diuji untuk dilakukan prediksi sudah sesuai keperluan dari pengguna. XAI sendiri ada berbagai macam, beberapa diantaranya adalah SHAP, LIME, dan ColorGrad.

2.2.5 LIME

Local Interpretable Model-agnostic Explanations atau yang lebih dikenal dengan sebutan LIME, adalah salah satu contoh dari XAI. Sesuai namanya

LIME bekerja di area lokal, atau hanya di salah satu *instance* saja, dan juga *model-agnostic* yang berarti bisa bekerja dengan model apapun. LIME bekerja dengan cara memanipulasi data input dan setelah itu akan membuat beberapa data buatan baru yang merupakan bagian-bagian dari data asli yang dipakai[15]. Seperti pada tulisan dimana beberapa versi akan dibuat dengan sebagian kata-kata dihilangkan dari data aslinya. Setelah itu data baru yang telah dibuat tersebut akan “ditimbang” menurut kemiripannya terhadap gambar asli yang ingin dijelaskan. Data tersebut akan dilatih menggunakan model yang local dan juga bisa diartikan hasilnya dengan tujuan untuk membuat model tersebut memiliki sikap yang semirip mungkin dengan model awal yang dipakai yang lebih kompleks dengan cara memperhatikan *global feature* dari data tersebut. Setelah itu akan terlihat bagian mana yang menjadi titik acuan dari model tersebut untuk klasifikasi dataset yang dipakai. LIME bekerja dengan rumus $explanation(x) = argmin_{g \in G} L(f, g, \pi x) + \Omega(g)$. Dimana x = data yang ingin kita lakukan penjelasan, f = model kompleks yang kita pakai seperti EfficientNet, g = salah satu *simple interpretable model* yang dipilih untuk penjelasan, G = kumpulan simple interpretable model, dengan $\pi x = proximity\ measure$. Sementara $\Omega(g)$ = regulasi agar model g tidak menjadi terlalu kompleks dan tetap mudah untuk dijelaskan. Secara umum, kita menginginkan *approximation* yang bagus antara model f yang kompleks dengan model g yang sederhana.

2.2.5 Augmentasi Data

Augmentasi data adalah salah satu teknik yang dipakai untuk mencegah atau meminimalisir *overfitting*, *balancing data*, serta meningkatkan performa dari model yang melakukan pelatihan tersebut[16]. Hal tersebut bisa dilakukan dengan cara memperbanyak jumlah dan juga variasi gambar dari suatu kelas ataupun beberapa kelas sehingga data bisa sama rata dengan cara mengambil data atau gambar asli, lalu diberikan perubahan sesuai yang kita mau. Ada banyak jenis augmentasi yang dilakukan, beberapa diantaranya

yang sering dipakai adalah pengaturan kecerahan, rotasi, *vertical flip* dan *horizontal flip*, zoom dan sebagainya.

2.2.6 Karakteristik dari ALL

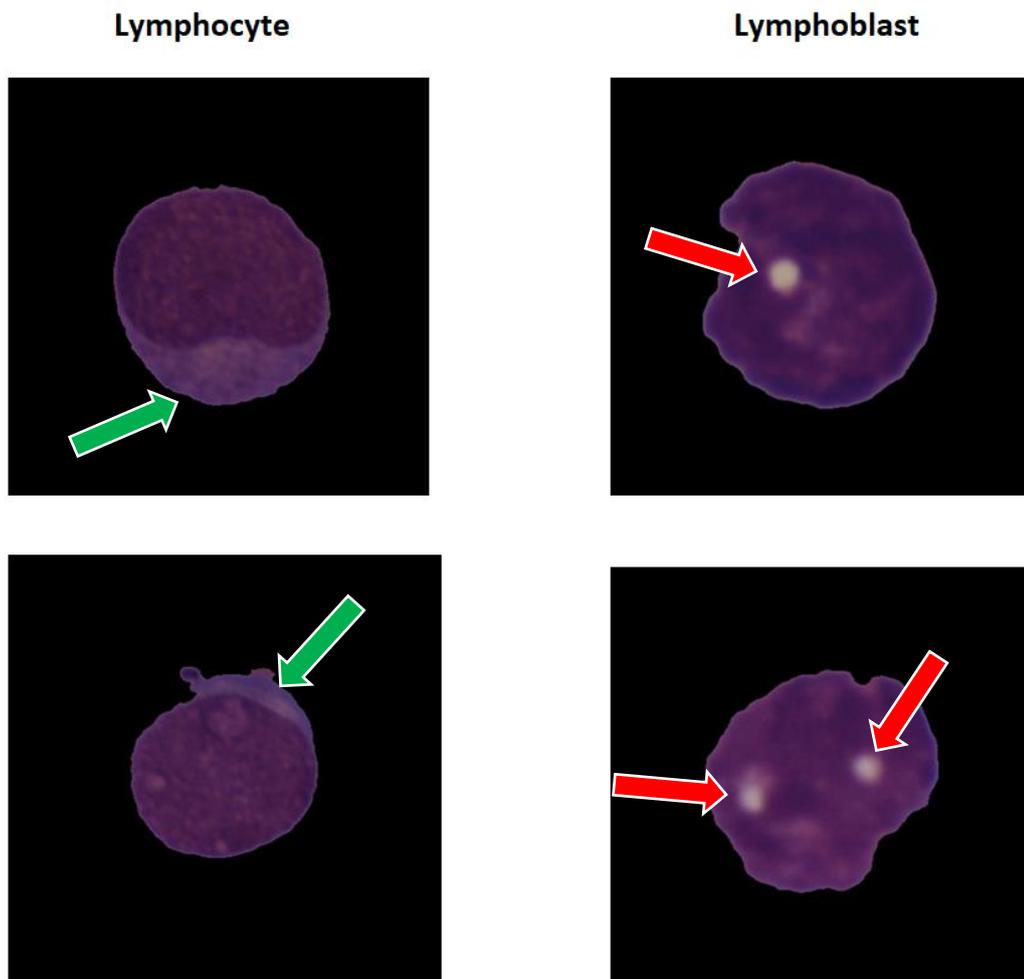
Leukemia adalah penyakit kanker yang terjadi ketika tubuh memproduksi terlalu banyak sel darah putih, sehingga menyebabkan ketidakseimbangan dalam jumlah sel darah dan sel darah putih tersebut alih-alih menjadi pelindung bagi tubuh, berubah menjadi sel yang menyerang tubuh. Ada beberapa jenis leukemia, salah satu diantaranya adalah *Acute Lymphocytic Leukemia*, atau biasa dikenal juga dengan *Acute Lymphoblastic Leukemia* atau disingkat menjadi ALL. Sesuai namanya, penyakit ini bersifat akut yang berarti pertumbuhan sel kanker tersebut sangat cepat dan harus segera ditangani. *Lymphoblastic* atau *Lymphocytic* berarti bahwa penyakit ini menyerang sel darah putih dengan jenis *lymphocyte* dengan memperbanyak bentuk muda dari jenis *lymphocyte* tersebut yang belum sempat dewasa yang dinamai sebagai *lymphoblast*. Bahkan menurut WHO, klasifikasi untuk penyakit ALL dinyatakan dengan adanya *lymphoblast* sebanyak 20% pada saat melakukan *complete blood count* atau CBC[17]. Tentu saja ada perbedaan karakteristik antara sel *lymphoblast* dengan sel *lymphocyte* yang sudah dewasa[6]. Perbedaan kedua sel tersebut dapat dilihat pada tabel 2.1.

Tabel 1 Tabel karakteristik *lymphocyte* dan *lymphoblast*

Lymphoblast	Lymphocyte
Rasio nuclear to cytoplasmic yang lebih kecil	Rasio nuclear to cytoplasmic yang lebih besar
Chromatin terlihat datar, mulus, dan terlihat homogen	Chromatin berbentuk mengelompok dan lebih kasar, seperti permukaan tanah yang kasar
Dapat terlihat 1-2 nucleoli	Tidak terdapat nucleoli

Dapat dilihat pada gambar 2.2 karakteristik dari *lymphoblast* dan *lymphocyte* yang sudah dijelaskan sebelumnya. 4 gambar tersebut sudah penulis

pilih dari dataset C-NMC 2019 yang menonjolkan karakteristik dari masing-masing sel. Dapat dilihat *nucleoli* berwarna putih yang ditandai panah merah, dan permukaan dari nukleus yang terlihat mulus serta sitoplasma yang sangat sedikit yang mengelilingi sel tersebut yang merupakan karakteristik dari *lymphoblast*. Dapat dilihat juga pada sel *lymphocyte*, permukaan nukleus yang kasar seperti permukaan tanah yang tidak rata, ukuran sitoplasma yang cukup besar dibandingkan dengan *lymphoblast* yang ditandai dengan panah hijau, serta tidak adanya *nucleoli* atau titik berwarna putih.



Gambar 2.0.2 Perbandingan antara lymphocyte dan lymphoblast [18]

M U L T I M E D I A
N U S A N T A R A