

BAB II

TINJAUAN PUSTAKA

2.1 Studi Literatur

Pada bab ini, akan diuraikan tinjauan pustaka mengenai Klasifikasi Citra Sel Acute Lymphoblastic Leukemia menggunakan Jaringan Konvolusi dengan Transfer Learning Arsitektur ResNet 18. Bab tinjauan pustaka ini memberikan landasan teori serta penelitian – penelitian terkait yang telah dilakukan sebelumnya yang juga terkait dengan bidang ini. Diharapkan tinjauan pustaka yang diberikan dapat memberikan pemahaman yang lebih baik mengenai topik permasalahan yang dibahas. Adapun penelitian sebelumnya yang digunakan sebagai rujukan pada penelitian ini adalah sebagai berikut :

Penelitian dengan judul “*Acute Lymphoblastic Leukemia Detection and Classification of Its Subtypes Using Pretrained Deep Convolutional Neural Networks*” yang dilakukan oleh Sarmad Shafique dan Samabia Tenshin untuk melakukan deteksi dan klasifikasi sel leukemia dan subtype-subtipenya. Pada penelitian ini tugas yang dilakukan diantaranya adalah melakukan deteksi ALL untuk mendeteksi yang mana sel ALL dan sel normal dengan akurasi yang diperoleh 99.50%, dan klasifikasi subtype-subtype sel ALL yang terdiri dari 4 kelas dengan akurasi yang diperoleh sebesar 96.06% [9]. Dataset yang digunakan diperoleh dari ALL-Image DataBase (IDB) yang merupakan dataset publik yang tersedia *online* dengan total data sebanyak 260 citra, terdiri dari 130 citra sel pasien yang menderita leukemia dan 130 citra sel sisanya adalah sel sehat dengan resolusi 257×257 pixel dengan 24 bit *color depth*. Tahap *preprocessing* yang dilakukan menggunakan data augmentasi seperti *image rotation* dan *image mirroring* untuk meningkatkan jumlah data latih. Kemudian, untuk arsitektur jaringan yang digunakan adalah AlexNet dengan *input* citra *Red Green Blue* (RGB). Arsitektur terdiri dari 5 layer konvolusi dengan 3 layer *max pooling*.

Penelitian oleh Hanan Aljuaid, Nazik Alturki, Najah Alsubaie, Lucia Cavallaro, dan Antonio Liotta [10] yang berjudul “*Computer-aided diagnosis for breast cancer classification using deep neural networks and transfer learning*”. Penelitian ini menggunakan citra medis yaitu citra sel kanker payudara untuk kasus klasifikasi *binary* dan *multiclass* dengan mengusulkan beberapa metode *deep neural network* diantaranya ResNet 18, ShuffleNet, dan Inception-V3Net) dan *transfer learning* pada dataset BreakHis publicity. Metode yang diusulkan mendapatkan rata – rata akurasi untuk *binary*

classification sebesar 99.7%, 97.66%, dan 96.94% secara berurutan oleh ResNet, InceptionV3Net dan ShuffleNet. Rata – rata akurasi yang diperoleh untuk *multiclass classification* adalah 97.81%, 96.07%, dan 95.79% secara berurutan didapatkan oleh ResNet, InceptionV3Net dan ShuffleNet.

2.2 Konsep Dasar Klasifikasi Citra

Klasifikasi citra merupakan salah satu teknik pada pengolahan citra dimana metode ini bertujuan untuk melakukan pengelompokan citra kedalam kategori tertentu berdasarkan fitur – fitur yang ada pada citra tersebut, dengan tujuan untuk mengenali dan membedakan objek maupun pola yang ada pada citra tersebut [11]. Fokus utama klasifikasi citra dalam suatu penelitian selalu mengenai *feature extraction* (ekstraksi fitur), yang mana merupakan basis utama pada klasifikasi citra [12]. Teknik ini tentunya memberikan banyak manfaat seperti dapat melakukan tugas untuk mendeteksi dan membedakan penyakit berdasarkan citra yang diperoleh seperti citra sel darah, dan lain sebagainya.

Dalam dunia ilmu komputer dan pembelajaran mesin, masalah klasifikasi adalah salah satu jenis tugas penting yang sering dihadapi. Dalam tugas klasifikasi, kita berupaya untuk mengkategorikan data ke dalam satu dari beberapa kelas atau kategori berdasarkan ciri-ciri atau fitur tertentu yang ada dalam data tersebut. Terdapat dua jenis utama dari masalah klasifikasi: klasifikasi biner (*binary classification*) dan klasifikasi *multiclass*.

2.2.1 Binary Classification

Binary classification adalah jenis klasifikasi yang paling sederhana, di mana data harus diklasifikasikan ke dalam satu dari dua kelas yang mungkin. Dalam konteks klasifikasi citra sel darah putih untuk mendeteksi keberadaan Acute Lymphoblastic Leukemia (ALL) pada penelitian ini, tujuan klasifikasi yang dilakukan adalah untuk memisahkan citra sel menjadi dua kategori, yaitu “Normal” dan “Blast”. Hasil dari klasifikasi ini adalah prediksi apakah sel darah tersebut adalah sehat atau mengidap leukemia.

2.2.2 Multiclass Classification

Multiclass classification merupakan jenis klasifikasi yang melibatkan lebih dari dua kategori. Dalam konteks yang sama pada penelitian ini, diantaranya mencakup klasifikasi sel darah dan menjadikannya beberapa kelas seperti

“Normal”, “L1”, “L2”, dan “L3”, yang mewakili berbagai sub tipe leukemia. Dalam masalah ini, model harus membedakan dan mengidentifikasi sel darah menjadi salah satu dari beberapa kategori yang mungkin.

Pada kasus *multiclass classification* untuk sub tipe sel ALL, hal ini menjadi penting karena diagnosis yang tepat dan cepat dari leukemia dapat menjadi perbedaan antara kesembuhan dan perkembangan penyakit yang lebih serius. *Multiclass classification* pada citra sel darah memberikan kemampuan untuk mendeteksi penyakit ini pada tingkat sel, yang mana dapat memungkinkan pengobatan yang lebih dini dan lebih efektif [13]. Oleh karena itu, pemahaman mendalam tentang klasifikasi *multiclass* maupun *binary* serta implementasinya dalam dunia medis adalah langkah kunci untuk meningkatkan diagnosis dan pengobatan leukemia.

2.3 Machine Learning

Machine Learning (ML) merupakan studi tentang alat dan metode dalam mengidentifikasi pola pada data [14]. Teknik *deep learning* dalam ML dapat melakukan deteksi dan klasifikasi dengan akurasi yang sangat baik apabila menggunakan dataset, model, dan teknik yang benar [15]. Menggunakan pendekatan *transfer learning* dapat membantu menjawab permasalahan utama di bidang medis, yaitu keterbatasan tersedianya kumpulan data besar yang berisi anotasi kebenaran dasar yang andal [16]. *Transfer learning* sendiri merupakan teknik pada *deep learning* yang mana mentransfer *weights* dari model yang sudah dilatih pada sejumlah besar data dan mempelajari *weight* dan bias model selama pelatihan [5].

2.4 Transfer Learning

Transfer Learning (TL) merupakan teknik yang ada pada *deep learning* dimana menyalurkan pengetahuan yang sudah dipelajari oleh suatu model dari satu tugas atau domain untuk tugas atau domain yang berbeda dengan tujuan untuk meningkatkan performa [17]. Pada *image classification*, TL memanfaatkan model yang telah di latih menggunakan dataset yang besar dan juga kompleks (ImageNet misalnya) sehingga mempercepat dan juga meningkatkan performa dalam melakukan pengklasifikasian citra pada tugas tertentu.

TL memanfaatkan pengetahuan yang sudah didapatkan oleh model pada lapisan – lapisan awal dalam proses *train* data. Lapisan tersebut dapat melakukan identifikasi fitur

umum pada berbagai jenis citra, seperti garis, sudut, maupun tekstur pada citra tersebut. Dalam konsep TL, lapisan – lapisan awal ini tetap digunakan dan tidak diubah, dan lapisan – lapisan akhir dimodifikasi untuk tugas yang spesifik.

Penggunaan TL pada klasifikasi citra juga membantu mengatasi permasalahan umum seperti kurangnya jumlah data yang digunakan untuk proses pelatihan. Menggunakan model yang telah dilatih pada dataset yang besar, model dapat mendapatkan pemahaman lebih baik mengenai fitur – fitur yang relevan, bahkan dengan jumlah data *train* yang terbatas. TL memungkinkan kita untuk dapat menggunakan pengetahuan yang telah didapatkan oleh model untuk meningkatkan dan mempercepat performa dalam tugas klasifikasi citra yang lebih spesifik, contohnya seperti klasifikasi sel leukemia. Menggunakan TL dengan memanfaatkan model yang telah dilatih pada dataset yang lebih luas, kita dapat menggunakan arsitektur seperti arsitektur ResNet 18 untuk kasus klasifikasi citra.

2.5 Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan pendekatan yang sangat efektif dalam pengenalan pola dan telah mencapai hasil yang luar biasa dalam dekade terakhir ini di berbagai bidang yang terkait dengan pengenalan pola, mulai dari pemrosesan citra, hingga suara [18]. CNN dirancang secara khusus untuk melakukan pemrosesan data yang memiliki struktur spasial, seperti data citra. CNN memiliki Konsep dasar operasi konvolusi untuk melakukan ekstraksi fitur dari data input.

2.6 Arsitektur resnet

ResNet (Residual Network) merupakan inovasi dalam *deep learning* yang mana membantu meningkatkan efektivitas pelatihan jaringan saraf dalam sehingga dapat mengatasi masalah penurunan kinerja. Konsep kunci ResNet ada pada lapisan residualnya, yang memungkinkan model mempelajari perbedaan yang ada pada representasi fitur, sehingga dapat mengurangi permasalahan dalam pelatihan yang terkait dengan *deep neural network*.

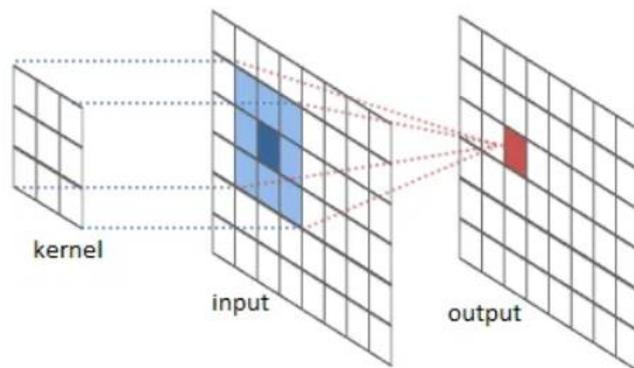
Ada beberapa varian arsitektur ResNet, diantaranya ResNet 18, ResNet 34, ResNet 50, ResNet 101, dan ResNet 152. Perbedaan yang ada pada masing – masing varian ini terletak pada jumlah lapisan dan juga kompleksitas model, semakin tinggi angka yang direpresentasikan, semakin dalam dan kompleks pula arsitektur ResNet tersebut. ResNet 18 dianggap arsitektur yang relatif ringan dan juga lebih mudah untuk dilatih.

2.6.1 ResNet 18

ResNet 18 merupakan salah satu dari sekian banyak arsitektur ResNet pada CNN yang terkenal dalam bidang deep learning, terutama pada tugas klasifikasi citra. Arsitektur ResNet 18 mempunyai struktur khas dan juga memanfaatkan lapisan residual nya untuk mengatasi masalah pada pelatihan *deep neural network*. Arsitektur ini diperkenalkan oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun [8] dalam paper yang berjudul “*Deep Residual Learning for Image Recognition*”.

2.6.2 Convolutional Layer

Convolutional layer dalam *neural network* digunakan untuk melakukan ekstraksi fitur dari data yang dimasukkan seperti citra atau video. Layer – layer ini mengatasi tantangan dengan menghubungkan tiap *input* neuron ke setiap neuron yang ada di *hidden layer*, yang tentunya memerlukan bobot *connections* yang besar [19].



Gambar 2.1 *Convolutional layer* [20]

Convolutional layer bekerja dengan menggeser jendela kecil (biasanya 3×3 atau 5×5) yang disebut kernel atau filter melintasi data *input*. Kernel melakukan perkalian elemen dengan nilai – nilai yang ada di *input window* dan kemudian menjumlahkan hasilnya untuk menghasilkan satu nilai *output*. Proses ini dilakukan berulang dengan memindahkan *window* ke seluruh data *input*, sehingga menghasilkan *feature map* yang mewakili kehadiran fitur atau pola tertentu.

2.7 PyTorch

PyTorch adalah salah satu framework deep learning yang populer dan banyak digunakan dalam penelitian di bidang kecerdasan buatan. PyTorch menyediakan lingkungan pengembangan yang kuat dan fleksibel untuk membangun dan melatih model neural network [21]. Framework ini menonjolkan fleksibilitas, ekspresivitas, serta mudahnya dalam pemahaman dan pemecahan masalah.

PyTorch digunakan pada penelitian ini untuk mengimpor model ResNet-18 yang telah dilatih sebelumnya. PyTorch menyediakan koleksi model pre-trained yang dapat diimpor dengan mudah, termasuk model ResNet-18 yang digunakan dalam penelitian ini. Selain itu, PyTorch juga menyediakan berbagai alat dan fungsi yang mendukung proses pelatihan, evaluasi, dan penyesuaian model. Dengan menggunakan PyTorch, peneliti dapat mengimpor model ResNet-18, melakukan penyesuaian pada lapisan-lapisan model, dan menjalankan pelatihan serta evaluasi dengan mudah. PyTorch juga menyediakan fitur-fitur seperti fungsi aktivasi, optimisasi, fungsi loss, dan alat visualisasi yang sangat berguna dalam mengembangkan dan memperbaiki model neural network.

2.8 Tensorflow

TensorFlow adalah salah satu framework deep learning yang populer dan kuat, dikembangkan oleh Google Brain Team. TensorFlow memberikan lingkungan yang komprehensif untuk mengembangkan, melatih, dan menerapkan model neural network. Framework ini menekankan pada skalabilitas, kecepatan, dan kinerja yang tinggi. Dalam konteks penelitian ini, TensorFlow digunakan untuk mendefinisikan arsitektur model, menyesuaikan lapisan-lapisan, melakukan tuning pada parameter, serta melaksanakan pelatihan dan evaluasi. TensorFlow menyediakan berbagai fungsi dan alat yang mendukung proses ini, termasuk fungsi aktivasi, optimisasi, fungsi loss, dan metrik evaluasi.

Salah satu keunggulan TensorFlow adalah kemampuannya dalam mengoptimalkan proses pelatihan model menggunakan GPU (Graphical Processing Unit), yang secara signifikan meningkatkan kecepatan dan kinerja pelatihan. TensorFlow juga menyediakan alat visualisasi yang berguna untuk memahami dan menganalisis performa model, seperti TensorBoard. Dengan menggunakan TensorFlow, peneliti dapat dengan mudah mendefinisikan arsitektur model yang kompleks, menyesuaikan lapisan-lapisan, dan mengoptimalkan parameter-model untuk mencapai hasil yang lebih baik. Framework ini memberikan fleksibilitas dan kekuatan yang diperlukan untuk melakukan eksplorasi

mendalam dalam klasifikasi citra dan mengoptimalkan model sesuai dengan kebutuhan penelitian.

2.9 Numpy

NumPy (Numerical Python) adalah pustaka Python yang populer untuk komputasi numerik. NumPy menyediakan objek array multidimensi yang efisien, bersama dengan berbagai fungsi dan operasi matematika yang kuat untuk bekerja dengan array tersebut [22]. Pustaka ini merupakan fondasi bagi banyak pustaka ilmiah Python lainnya, termasuk pandas, SciPy, dan scikit-learn. NumPy memungkinkan peneliti untuk melakukan operasi numerik dan matematika tingkat tinggi dengan mudah dan efisien.

2.10 Matplotlib

Matplotlib merupakan pustaka Python yang populer untuk visualisasi data. Pustaka ini menyediakan berbagai fungsi dan alat yang kuat untuk membuat grafik, plot, diagram, dan visualisasi lainnya. Matplotlib digunakan untuk membuat visualisasi yang informatif dan menarik dari data numerik dan statistik di python [23].

2.11 Evaluasi Klasifikasi

Evaluasi klasifikasi merupakan proses yang memiliki peran penting dalam menganalisis performa suatu model klasifikasi. Pada penelitian ini, evaluasi klasifikasi yang dilakukan menggunakan metode *Confussion Matrix* dan *Classification Report*. *Confussion matrix* merupakan alat evaluasi yang digunakan untuk menggambarkan performa dari model klasifikasi dengan melakukan perhitungan jumlah klasifikasi yang benar dan salah [24].

Tabel 2.1 *Confussion matrix*.

		Nilai Sebenarnya	
		Positive	Negative
Nilai Prediksi	Positive	TP	FP
	Negative	FN	TN

Matriks ini terdiri dari empat bagian utama, *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). TP merujuk pada jumlah data positif yang diklasifikasikan dengan benar oleh model sebagai positif. Dalam artian, model dengan benar mengidentifikasi data sebagai positif. TN merujuk pada jumlah data negatif yang diklasifikasikan dengan benar oleh model sebagai negatif. Dalam artian, model dengan benar mengidentifikasi data sebagai negatif. FP merujuk pada jumlah data negatif yang

salah diklasifikasikan oleh model sebagai positif. Dalam kata lain, model salah mengidentifikasi data sebagai positif yang seharusnya negatif. Matriks terakhir, FN merujuk pada jumlah data positif yang salah diklasifikasikan oleh model sebagai negatif yang seharusnya positif.

Selain *confussion matrix*, *classification report* juga digunakan untuk memberikan informasi yang lebih rinci terkait performa yang dihasilkan model klasifikasi. *Classification report* memberikan ringkasan informasi yang lebih lengkap dengan melaporkan metriks evaluasi untuk setiap kelas yang terdapat dalam dataset seperti *precision*, *recall*, dan *F1-score*.

