

Perbandingan Metode Convolutional Neural Network pada Klasifikasi Sel Darah Putih Menggunakan Sistem CPU dan GPU

Arum Yumna Zahrah¹, Anditya Arifianto, S.T., M.T.², Febryanti Sthevanie, S.T., M.T.³

^{1,2,3} Fakultas Informatika, Universitas Telkom, Bandung

¹arumyumnaz@student.telkomuniversity.ac.id, ²anditya@telkomuniversity.ac.id,

³shevanie@telkomuniversity.ac.id

Abstrak

Saat ini penggunaan metode Deep Learning dapat menjadi salah satu metode yang sering digunakan pada penelitian. Salah satunya adalah klasifikasi menggunakan metode Convolutional Neural Network. Banyak penelitian yang telah dilakukan mengenai bidang pemrosesan gambar yang digabungkan dengan berbagai teknik klasifikasi dan segmentasi untuk mendapatkan hasil alternatif pada klasifikasi. Penelitian ini menerapkan metode CNN untuk klasifikasi sel darah putih. Penetapan jumlah dan klasifikasi sel darah putih sangat penting dalam deteksi suatu penyakit pada tubuh seseorang, yang dapat mengakibatkan komplikasi pada suatu sistem kekebalan tubuh sehingga mengarah ke berbagai jenis penyakit. Klasifikasi sel darah putih dengan menerapkan metode CNN digunakan untuk membedakan 4 jenis sel darah putih antara lain Neutrofil, Eosinofil, Monosit, dan Limfosit. Untuk mengetahui kinerja klasifikasi yang paling optimal dengan waktu eksekusi yang paling cepat, penelitian ini membandingkan antara performansi proses klasifikasi menggunakan CPU dan GPU. Hasil yang diperoleh pada proses klasifikasi ini yaitu penggunaan GPU lebih unggul dengan nilai Speedup hingga 29 kali dan nilai akurasi hingga 99,93%.

Kata kunci : Convolutional neural network, CPU, deep learning, GPU, sel darah putih.

Abstract

Nowadays, the use of the Deep Learning method can be one method that is often used in research. One of them is the classification using the Convolutional Neural Network method. Much research has been done on the field of image processing combined with various classification and segmentation techniques to obtain alternative results in classification. This study applies the CNN method for the classification of white blood cells. Determination of the number and classification of white blood cells is very important in the detection of a disease in a person's body, which can lead to complications in an immune system that leads to various types of diseases. Classification of white blood cells by applying the CNN method is used to distinguish 4 types of white blood cells, including Neutrophils, Eosinophils, Monocytes, and Lymphocytes. To find out the most optimal classification performance with the fastest execution time, this study compares the performance of the classification process using CPU and GPU. The results obtained in this classification process are the use of GPU is superior with Speedup values up to 29 times and accuracy values up to 99.93%.

Keywords: Convolutional neural network, CPU, deep learning, GPU, white blood cell.

1. Pendahuluan

Sel darah putih merupakan bagian tubuh manusia yang sangat penting dan bertanggung jawab untuk melindungi tubuh dari jutaan penyakit yang disebabkan bakteri, parasit, dan virus [5]. Sel darah putih merupakan bagian dari sistem kekebalan tubuh manusia berupa jaringan kompleks yang terdiri dari sel, jaringan, dan organ yang bekerja secara bersamaan untuk menjalankan fungsinya. Sel darah putih mempunyai 5 sub-kelompok, 3 diantaranya memiliki granula didalam sitoplasmanya yaitu basofil, eosinofil, dan neutrofil. Sedangkan 2 jenis lainnya tidak memiliki granula didalam sitoplasmanya yaitu limfosit dan monosit [1].

Klasifikasi dan perhitungan sel darah biasanya dilakukan secara visual oleh seorang spesialis medis menggunakan mikroskop. Kegiatan ini membutuhkan waktu yang lama dan lebih banyak energi sehingga dapat menyebabkan hasil akurasi rendah. Metode otomatis menggunakan mesin analisis sampel darah juga dapat digunakan tetapi membutuhkan kalibrasi yang tepat dan biaya mahal [8]. Untuk memproses dataset seperti klasifikasi gambar, teknik AI baru telah dikembangkan, yaitu teknik Deep Learning. Oleh karena itu, menggunakan Deep Learning diperlukan untuk menyelesaikan masalah ini. Metode yang cocok untuk diterapkan adalah Convolutional Neural Network karena dataset sel darah putih adalah objek gambar [3].

Selain itu, karena proses klasifikasi menggunakan metode CNN menggunakan dataset dengan jumlah dan ukuran yang besar, maka membutuhkan waktu eksekusi yang cukup lama saat menggunakan CPU. Oleh karena itu untuk mempersingkat waktu eksekusi, perlu menggunakan GPU dalam implementasi proses klasifikasi untuk meningkatkan efisiensi waktu [11].

Penelitian ini dilakukan untuk menyelesaikan masalah dan mendapatkan solusi dari hasil penelitian. Berdasarkan latar belakang yang telah diuraikan di atas, maka dapat dirumuskan beberapa masalah yang diangkat antara lain cara mengklasifikasikan sel darah putih sesuai dengan jenisnya, implementasi klasifikasi sel darah putih dengan metode Convolutional Neural Network untuk memperoleh akurasi yang tinggi, dan cara untuk meningkatkan kecepatan running time pada klasifikasi sel darah putih.

Dalam melakukan penelitian, terdapat batasan masalah yang digunakan diantaranya penggunaan dataset sel darah putih yang berasal dari situs web kaggle.com dan software yang digunakan adalah Jupyter Notebook.

Berdasarkan latar belakang dan rumusan masalah yang telah diuraikan diatas, berikut adalah tujuan yang ingin dicapai pada penelitian ini antara lain untuk mengetahui cara mengklasifikasikan sel darah putih sesuai dengan jenisnya, untuk mempelajari implementasi klasifikasi sel darah putih dengan metode Convolutional Neural Network agar memperoleh akurasi yang tinggi, dan untuk mengetahui cara meningkatkan kecepatan running time pada klasifikasi sel darah putih.

Pada penulisan jurnal penelitian ini dibagi menjadi 5 bagian antara lain pendahuluan, studi terkait, sistem yang dibangun, evaluasi, dan kesimpulan.

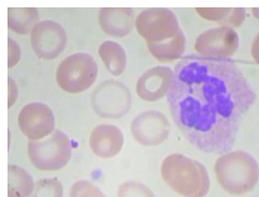
2. Studi Terkait

2.1 Sel Darah Putih

Darah merupakan cairan yang terdiri dari sel-sel dan partikel yang menyerupai sel yang berfungsi untuk mengangkut oksigen, zat makanan, bahan kimia hasil metabolisme, dan hormon yang dibutuhkan oleh jaringan tubuh manusia yang mengalir di dalam arteri, kapiler, dan vena.

Sistem kekebalan tubuh merupakan jaringan yang kompleks terdiri dari sel, jaringan, dan organ yang saling bekerja sama untuk melindungi tubuh dari jutaan penyakit yang disebabkan oleh bakteri, parasit, dan virus [10]. Sel darah putih (leukosit) merupakan komponen tubuh yang paling penting dari sistem kekebalan tubuh [5]. Tugas leukosit adalah menetralkan bakteri dan kuman yang masuk melalui aliran darah atau dari luka yang terbuka. Leukosit mempunyai sifat amoeboid sehingga dapat bergerak dengan bebas dan sifat fagositosis agar dapat memangsa bakteri dan sel-sel yang telah mati. Jika dilihat dari bentuk inti leukosit dan sitoplasmanya, sel darah putih terdiri dari lima jenis berdasarkan klasifikasi bergranula dan tidak bergranula antara lain; neutrofil, eosinofil, monosit, limfosit, dan basofil [1].

1. Neutrofil

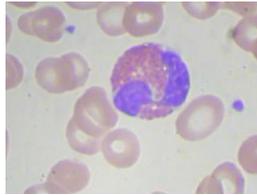


Gambar 1. Neutrofil

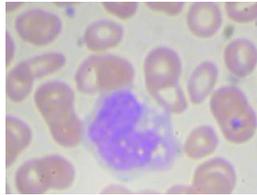
Neutrofil merupakan salah satu jenis sel darah putih yang memiliki granula pada sitoplasmanya (granulosit). Neutrofil berperan dalam sistem kekebalan dan pertahanan tubuh terhadap infeksi bakteri serta proses peradangan lainnya. Inti sel pada neutrofil berbentuk seperti "C" atau batang melengkung yang tersegmentasi dan memiliki 2 hingga 5 lobus yang dihubungkan dengan kromatin. Pada sirkulasi sel darah putih, neutrofil merupakan granulosit dengan populasi paling tinggi yaitu berkisar antara 50% hingga 70% [5]. Gambar 1 menunjukkan contoh dataset neutrofil.

2. Eosinofil

Eosinofil merupakan granulosit yang mempunyai peran berhubungan dengan infeksi parasit sehingga memiliki kemampuan untuk melepaskan racun dan membunuh patogen seperti parasit dan cacing. Seperti pada Gambar 2, inti pada eosinofil memiliki 2 lobus yang dihubungkan oleh pita bahan nuklir. Persentase populasi eosinofil yaitu antara 0% hingga 5% pada sirkulasi sel darah putih [5].



Gambar 2. Eosinofil

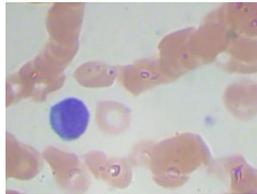


Gambar 3. Monosit

3. Monosit

Monosit merangsang sel-sel osteoklas yang memiliki kemampuan untuk melarutkan tulang. Seperti yang ditunjukkan pada Gambar 3, monosit memiliki inti terbesar dalam darah yang berbentuk "U" dan memiliki 2 jenis, yaitu makrofag dan sel dendritik. Makrofag memakan semua jenis sel mati dalam tubuh, sedangkan sel dendritik membantu perkembangan imunitas antigen. Monosit mempunyai populasi sebesar 3% hingga 9% pada sirkulasi sel darah putih [5].

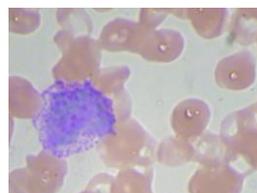
4. Limfosit



Gambar 4. Limfosit

Limfosit berperan dalam perlawanan terhadap infeksi virus. Sesuai dengan diameter nukleusnya, limfosit dibagi menjadi limfosit B (sel-B) dan limfosit T (sel-T). Limfosit B menghasilkan antibodi dan protein yang terhubung ke mikroba atau sel tubuh yang terinfeksi dan berdiferensiasi menjadi sel plasma. Sedangkan limfosit T menghasilkan protein yang disebut sitokin yang dapat membantu mengarahkan respon sel-sel lain. Populasi limfosit berkisar antara 25% hingga 30% pada sirkulasi sel darah putih [5]. Limfosit ditunjukkan pada Gambar 4.

5. Basofil



Gambar 5. Basofil

Basofil bertanggung jawab untuk memberikan reaksi alergi dan antigen dengan cara mengeluarkan histamin kimia yang dapat menyebabkan peradangan. Basofil memiliki populasi paling minim yaitu berkisar antara 0% hingga 1% dari sirkulasi sel darah putih [5]. Contoh dataset basophil ditunjukkan pada Gambar 5.

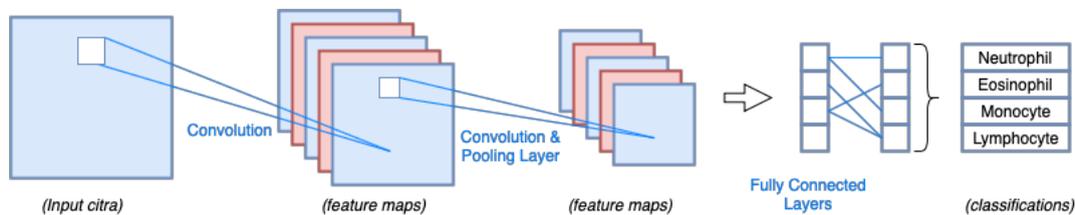
2.2 Deep Learning

Deep Learning merupakan subset dari Artificial Intelligence dan machine learning yang menggunakan jaringan saraf tiruan berlapis untuk memberikan akurasi canggih pada tugas kecerdasan buatan, antara lain deteksi objek, pengenalan suara, terjemahan bahasa, dan lain-lain[2].

Deep Learning berbeda dengan teknik machine learning tradisional karena dapat mempelajari representasi data secara otomatis. Misalnya gambar, video, atau teks tanpa memperkenalkan aturan kode hand-coded atau pengetahuan domain manusia. Arsitektur Deep Learning sangat fleksibel sehingga dapat mempelajari data mentah secara langsung dan dapat meningkatkan akurasi prediktif saat diberikan data yang lebih banyak[2].

2.3 Convolutional Neural Network

Convolutional Neural Network adalah salah satu arsitektur dari Deep Learning. Metode ini banyak digunakan dalam pengenalan pola dan pemrosesan gambar dengan lebih sedikit parameter pelatihan dan kemampuan adaptasi yang kuat. Keuntungan dari metode ini adalah bahwa input jaringan akan menjadi jelas ketika input dan gambar multidimensi dapat langsung masuk ke dalam jaringan, sehingga dapat menghindari penggalan fitur yang kompleks dan rekonstruksi data. Jaringan konvolusi adalah perceptron multilayer yang dirancang untuk mengenali dua dimensi yang sangat berbeda dari terjemahan, skala, kemiringan, atau bentuk deformasi lain [13]. Dalam menggunakan CNN, langkah penting pertama adalah memastikan bahwa dimensi gambar yang digunakan untuk memenuhi dimensi gambar dalam persyaratan CNN [5]. Contoh arsitektur CNN ditunjukkan pada Gambar 6.



Gambar 6. Arsitektur CNN

2.4 CPU

Industri pada central processing unit (CPU) telah berkembang seiring dengan kecepatan dan kemampuan CPU untuk melakukan tugas-tugas komputasi umum, dan menurut hukum Moores jumlah transistor dan kekuatan pemrosesan prosesor berlipat ganda setiap dua tahun hingga saat ini [7].

2.5 GPU

Penggunaan graphic processing units (GPU) merupakan peran yang penting dalam penggunaan grafik komputer [12]. Fitur yang umumnya terdiri dari puluhan atau bahkan ratusan prosesor stream GPU tersebut sesuai untuk pemrosesan paralel. Dikarenakan GPU menyediakan lebih banyak transistor untuk pemrosesan data, GPU dipandang sebagai coprocessor untuk menjalankan beberapa thread secara paralel, dan tugas untuk mengendalikan alur algoritma akan diselesaikan oleh CPU. Sub-tugas dalam algoritma akan diproses secara paralel yang didefinisikan sebagai fungsi kernel akan dieksekusi oleh beberapa thread yang melakukan instruksi yang sama tetapi dapat beroperasi pada elemen yang berbeda [4].

2.6 Speedup

Dalam arsitektur komputer, speedup merupakan angka yang menunjukkan performansi dan peningkatan dalam kecepatan pemrosesan suatu masalah pada dua arsitektur dengan sumber daya yang berbeda. Rumus speedup ditunjukkan pada (1).

$$S = \frac{T_1}{T_2} \quad (1)$$

Keterangan:

1. S : percepatan waktu eksekusi tugas

2. T_1 : waktu eksekusi pada arsitektur pertama
3. T_1 : waktu eksekusi pada arsitektur kedua

2.7 Akurasi

Akurasi adalah perhitungan rasio semua sampel per kelas dan jumlah total sampel [5]. Akurasi merupakan proporsi hasil yang benar (baik true positive atau true negative) di antara jumlah total kasus yang diperiksa [6]. Rumus akurasi ditunjukkan pada (2).

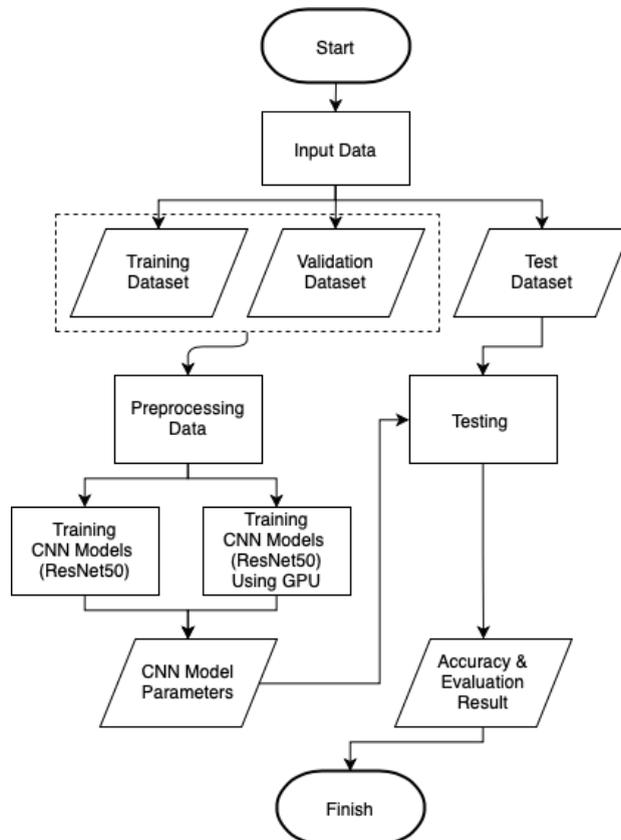
$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \tag{2}$$

Keterangan:

1. True Positive (TP) : jumlah data klasifikasi yang diprediksi bernilai positif dan benar.
2. True Negative (TN) : jumlah data klasifikasi yang diprediksi bernilai negatif dan benar.
3. False Positive (FP) : jumlah data klasifikasi yang diprediksi bernilai positif dan salah.
4. False Negative (TP) : jumlah data klasifikasi yang diprediksi bernilai negatif dan salah.

3. Sistem yang Dibangun

Gambar 7 menunjukkan alur sistem klasifikasi menggunakan metode CNN. Sistem ini terdiri dari 4 proses utama termasuk input data, preprocessing data, training model CNN menggunakan CPU dan GPU, dan testing data.



Gambar 7. Alur Sistem

3.1 Input Data

Dataset yang digunakan adalah gambar mikroskopis sel darah putih. Dataset diperoleh dari platform kompetisi untuk data science yang menyediakan beragam dataset yaitu kaggle.com. Dataset adalah 12.479 gambar yang terdiri dari 8.382 dataset pelatihan, 1.605 dataset validasi, dan 2.492 dataset uji dengan perbandingan 67:13:20 dari total dataset. Penelitian ini hanya menggunakan 4 kelas sel darah putih, antara lain neutrofil, eosinofil, monosit, dan limfosit. Basofil tidak termasuk input karena jumlahnya kurang dari 1% pada tubuh manusia.

3.2 Preprocessing Data

Untuk meningkatkan kualitas gambar asli dan memudahkan langkah pemrosesan selanjutnya, data preprocessing dilakukan dengan mengolah data mentah yang telah diinput. Proses ini memungkinkan data mentah diproses lebih cepat dalam program karena data telah disederhanakan. Sebelum data diproses lebih lanjut, data mentah yang telah diinput diproses terlebih dahulu sehingga dapat diproses lebih cepat di program utama. Data preprocessing dalam penelitian ini menggunakan fungsi preprocess_input() dari ResNet50 yang terdiri dari pengambilan gambar dengan piksel tertentu untuk memastikan jaringan diberi gambar dengan ukuran konstan, dan kemudian dipusatkan dengan dikurangi oleh rata-rata.

3.3 Training CNN Models

Dataset preprocessing telah dilakukan, dan pelatihan dilakukan pada proses klasifikasi menggunakan metode CNN (Convolutional Neural Network). Model CNN yang digunakan dalam penelitian ini adalah ResNet50. Dalam melaksanakan proses klasifikasi untuk mendapatkan kelas data yang tepat, dua percobaan telah dilakukan, antara lain implementasi percobaan menggunakan CPU dan GPU. Setiap percobaan dilakukan oleh komputer dengan spesifikasi seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Tabel Spesifikasi Komputer

Komponen	CPU	GPU
Prosesor	Intel(R) Core(TM) i3-9100F CPU @ 3.60GHz	NVIDIA GeForce GTX 1660 6 GB
Cores	4	1408 CUDA
RAM Sistem	8 GB	6 GB GDDR5/X
Operasi	Windows 10 Pro N 64-bit	Windows 10 Pro N 64-bit

3.4 Testing Data

Pada tahap ini, model CNN yang telah diperoleh dari tahap sebelumnya diuji pada dataset uji yang tersedia. Tahap ini menghasilkan output yang merupakan nilai akurasi dan confusion matrix dari setiap percobaan.

4. Evaluasi

4.1 Hasil Pengujian

Dengan menerapkan metode CNN pada klasifikasi sel darah putih, hasil yang sesuai telah diperoleh. Proses klasifikasi telah dilakukan dua kali menggunakan CPU dan GPU. Percobaan dilakukan pada 10, 20, 30, 40, dan 50 epoch. Satu epoch yaitu ketika seluruh dataset telah melalui proses training dengan satu kali forward pass dan satu kali backward pass pada semua sampel training. Pemilihan nilai epoch mengacu kepada [9]. Dikarenakan satu epoch terlalu besar untuk dimasukkan ke dalam komputer, maka dari itu perlu dibagi ke dalam satuan kecil (batches). Percobaan juga dilakukan dengan menggunakan 32 dan 64 batch. Batch size merupakan jumlah data sampel yang disebarkan dalam satu forward pass atau backward pass. Ukuran batch yang lebih besar membuat langkah gradien lebih besar dari ukuran batch yang lebih kecil untuk jumlah sampel yang sama. Semakin tinggi ukuran batch, maka semakin banyak ruang memori yang dibutuhkan. Oleh karena itu dipilih ukuran batch 32 dan 64.

Hasil perbandingan waktu eksekusi ditunjukkan pada Gambar 8 untuk perbandingan waktu eksekusi pada batch 32 dan Gambar 9 untuk perbandingan waktu eksekusi pada batch 64. Pengukuran kinerja dilakukan dengan menghitung speedup dari waktu eksekusi CPU time dan GPU time yang telah diperoleh, seperti yang ditunjukkan pada Tabel 2.



Gambar 8. Perbandingan Waktu Eksekusi Batch 32



Gambar 9. Perbandingan Waktu Eksekusi Batch 64

Tabel 2. Tabel Perbandingan Waktu Eksekusi

Epoch	Batch 32			Batch 64		
	CPU Time	GPU Time	Speedup	CPU Time	GPU Time	Speedup
10	265,44 ms	9,14 ms	29,04	163,12 ms	7,89 ms	20,67
20	529,76 ms	18,26 ms	29,01	329,29 ms	15,68 ms	21,00
30	796,98 ms	27,19 ms	29,31	493,07 ms	23,70 ms	20,80
40	1.064,25 ms	36,39 ms	29,24	656,68 ms	31,73 ms	20,69
50	1.330,43 ms	45,58 ms	29,18	821,09 ms	39,63 ms	20,71

Dari Tabel 2 dapat dilihat bahwa waktu eksekusi menggunakan GPU selalu jauh lebih cepat daripada penggunaan CPU, baik menggunakan batch 32 atau batch 64. Setelah dihitung menggunakan rumus speedup pada (1), penelitian ini mendapatkan nilai speedup sekitar 29 kali untuk batch 32, dan sekitar 21 kali untuk batch 64. Untuk melihat nilai akurasi klasifikasi sel darah putih dalam setiap percobaan, dapat dilihat pada Tabel 3.

Tabel 3. Tabel Akurasi

Epoch	Batch 32		Batch 64	
	CPU	GPU	CPU	GPU
10	98,43%	98,48%	97,78%	98,03%
20	98,54%	98,79%	98,88%	99,90%
30	97,54%	99,44%	99,32%	99,90%
40	98,53%	99,56%	98,92%	99,93%
50	96,97%	98,36%	99,59%	96,51%

Dalam Tabel 3, nilai akurasi tertinggi pada batch 32 yang diperoleh mencapai 98,54% untuk CPU dengan 20 epoch dan 99,56% untuk GPU dengan 40 epoch. Kemudian nilai akurasi tertinggi pada batch 64 yang diperoleh mencapai 99,59% untuk CPU dengan 50 epoch dan 99,93% untuk GPU dengan 40 epoch. Dapat dilihat bahwa nilai akurasi yang paling unggul adalah penggunaan GPU pada batch 64 dengan 40 epoch yaitu 99,93%. Nilai akurasi yang diperoleh pada setiap percobaan dapat memiliki perbedaan dikarenakan adanya initial random weights pada arsitektur CNN yang digunakan. Hasil akurasi yang diperoleh sudah cukup baik yaitu di atas 96,51% pada semua percobaan.

4.2 Analisis Hasil Pengujian

Berdasarkan Tabel 2, ada perbedaan yang signifikan antara waktu eksekusi pada penggunaan CPU dan GPU. Waktu eksekusi menggunakan GPU pada batch 64 merupakan waktu eksekusi tercepat di antara waktu eksekusi pada percobaan lainnya. Hal ini dikarenakan semakin besar ukuran batch, maka persebaran dataset juga semakin besar, sehingga waktu yang dibutuhkan menjadi lebih cepat. Jika dilihat dari nilai speedup, penggunaan GPU yang paling unggul adalah penggunaan GPU pada batch 32, yaitu lebih cepat 29 kali daripada penggunaan CPU. Dikarenakan model CNN yang telah dibangun cukup baik, maka pada Tabel 3 nilai akurasi yang diperoleh di atas 96,51% untuk semua percobaan. Penggunaan epoch juga mempengaruhi hasil akurasi karena seiring bertambahnya jumlah epoch, semakin banyak pula weight (bobot) yang berubah dalam CNN. Oleh karena itu, percobaan yang paling efisien dan efektif adalah penggunaan GPU pada batch 32 dengan nilai speedup tertinggi yaitu sekitar 29 kali dengan nilai akurasi tinggi yaitu di atas 98,36% pada semua epoch.

5. Kesimpulan

Penelitian ini mengimplementasikan klasifikasi otomatis yang dapat membedakan jenis sel darah putih menggunakan metode CNN (Convolutional Neural Network). Penelitian ini juga membuat perbandingan antara proses klasifikasi yang menggunakan CPU dan GPU. Perbandingan di sini didasarkan pada running time antara kedua program dengan beban kerja yang sama. Dari hasil running time dari kedua program, speedup atau peningkatan waktu eksekusi dan efisiensi klasifikasi dapat dihitung. Berdasarkan analisis hasil pengujian, proses klasifikasi menggunakan GPU lebih unggul jika dibandingkan dengan penggunaan CPU, baik pada epoch kecil maupun epoch besar dengan nilai speedup hingga 29 kali. Karena model CNN yang telah dibangun cukup baik, maka hasil nilai akurasi yang diperoleh dari penelitian ini di atas 96% pada semua percobaan.

Daftar Pustaka

- [1] M. L. Brooks. Exploring medical language: A student-directed approach, 7e. 2005.
- [2] J. Chen, K. Li, K. Bilal, X. Zhou, K. Li, and P. Yu. A bi-layered parallel training architecture for large-scale convolutional neural networks. *IEEE transactions on parallel and distributed systems*, 2018.
- [3] D. C. Ciresan, U. Meier, J. Masci, L. M. Gambardella, and J. Schmidhuber. Flexible, high performance convolutional neural networks for image classification. In *Twenty-Second International Joint Conference on Artificial Intelligence*, 2011.
- [4] J. Gao, L. Gao, X. Sun, Y. Wu, and B. Zhang. Gpu implementation of ant colony optimization algorithm for endmember extraction from hyperspectral image. In *2012 4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, pages 1–4. IEEE, 2012.
- [5] M. J. Macawile, V. V. Quiñones, A. Ballado, J. D. Cruz, and M. V. Caya. White blood cell classification and counting using convolutional neural network. In *2018 3rd International Conference on Control and Robotics Engineering (ICCRE)*, pages 259–263. IEEE, 2018.
- [6] C. E. Metz. Basic principles of roc analysis. In *Seminars in nuclear medicine*, volume 8, pages 283–298. Elsevier, 1978.
- [7] G. Moore. Moore's law. *Electronics Magazine*, 38(8):114, 1965.
- [8] F. Novoselnik, R. Grbić, I. Galić, and F. Dorić. Automatic white blood cell detection and identification using convolutional neural network. In *2018 International Conference on Smart Systems and Technologies (SST)*, pages 163–167. IEEE, 2018.
- [9] A. W. Qurashi and V. Holmes. Comparison of deep neural network approach in text and image classification using cpu and gpu systems. 04 2019.
- [10] T. Rosyadi, A. Arif, B. Achmad, et al. Classification of leukocyte images using k-means clustering based on geometry features. In *2016 6th International Annual Engineering Seminar (InAES)*, pages 245–249. IEEE, 2016.
- [11] K. S. Sundar, L. R. Bonta, P. K. Baruah, S. S. Sankara, et al. Evaluating training time of inception-v3 and resnet-50,101 models using tensorflow across cpu and gpu. In *2018 Second International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, pages 1964–1968. IEEE, 2018.

- [12] N. Zhao and X. Zheng. Multi-band blending of aerial images using gpu acceleration. In 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), pages 1–5. IEEE, 2017.
- [13] J. Zhou, W. Chen, G. Peng, H. Xiao, H. Wang, and Z. Chen. Parallelizing convolutional neural network for the handwriting recognition problems with different architectures. In 2017 International Conference on Progress in Informatics and Computing (PIC), pages 71–76. IEEE, 2017.