


BAB II

TINJAUAN PUSTAKA

II.1 *Deep Learning*

Deep learning adalah bagian dari *machine learning* yang sangat populer dan banyak digunakan. *Deep learning* merupakan penggabungan dari kecerdasan buatan (*artificial intelligence*) dan *machine learning* (Alaskar & Saba, 2021). Berbeda dengan *machine learning* tradisional yang mengandalkan data terstruktur, *deep learning* dirancang untuk menganalisis data menggunakan teknologi canggih yang dikenal dengan *artificial neural networks* (Grieve, 2020). *Deep learning* dapat menggunakan operasi lanjutan misalnya konvolusi atau menggunakan beberapa fungsi aktivasi dalam satu *neuron* (Janiesch et al., 2021).



Gambar II.1 Perbedaan machine learning dengan *deep learning*

Pada gambar II.1 menunjukkan perbedaan *machine learning* dengan *deep learning* terletak pada *preprocessing*, *feature extraction* dan *feature selection*,

dimana untuk melakukan klasifikasi pada *machine learning* tahapan tersebut dilakukan secara terpisah, namun pada *deep learning* proses tersebut dapat disatukan menggunakan model *deep learning*.

Beberapa algoritma *deep learning* yang populer yaitu: *recurrent neural networks* (RNN), *multi-layer perceptron* (MLP), *convolutional neural network* (CNN). RNN merupakan algoritma yang umum digunakan dalam disiplin *deep learning*. RNN biasanya diterapkan dibidang pemrosesan suara dan konteks NLP. MLP merupakan jenis jaringan saraf tiruan *feed-forward*. *Output* dari jaringan MLP ditentukan oleh fungsi aktivasi seperti *relu (rectified linear unit)*, *tanh*, *sigmoid*, dan *softmax*. Sedangkan CNN menggunakan *max and pool layer*, serta *dense layer* dan *convolutional layer* yang lebih sesuai dengan klasifikasi citra gambar (Sarker, 2021).

II.2 Convolutional Neural Network

Convolutional neural network (CNN) merupakan salah satu algoritma *deep learning* terbaik dan telah menunjukkan kinerja yang patut dicontoh dalam segmentasi gambar, klasifikasi, deteksi, mesin terjemahan hingga tugas-tugas terkait pengambilan (Xin et al., 2020). CNN dirancang untuk menyerupai koneksi antara *neuron* pada otak manusia (Bhatt et al., 2021). Berbeda dengan jaringan saraf biasa, CNN berisi ekstraksi fitur, yang terdiri dari lapisan konvolusi dan lapisan down-sampling.

CNN memiliki struktur berlapis yang terdiri dari lapisan *input (input layer)*, lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*). Lapisan

input merupakan gambar asli yang belum diproses, lapisan *output* merupakan hasil dari klasifikasi fitur sedangkan pada lapisan tersembunyi merupakan lapisan *neuron* yang terdiri dari *convolutional layer*, *pooling layer*, *dropout layer*, *full connected layer* tergantung pada arsitektur dan jenis masalah (Kutlu et al., 2020; Tian, 2020). Struktur CNN dapat dilihat pada gambar II.2



Gambar II.2 Struktur *Convolutional Neural Network*


a. Convolutional Layer

Lapisan konvolusi merupakan lapisan pertama yang digunakan untuk melakukan ekstraksi fitur pada citra masukan. Pada lapisan konvolusi, jaringan akan secara otomatis mempelajari fitur tanpa pemilihan fitur secara manual. Konvolusi akan menerima dua sinyal atau gambar sebagai *input* dimana satu sebagai kernel *input* dan yang lainnya sebagai filter yang akan digunakan untuk menghasilkan *output* (Patel & Patel, 2020; Tian, 2020). Secara matematis, konvolusi 2 buah fungsi f dan g dinyatakan pada persamaan 2.1

$$(f * g)(i) = \sum_{j=1}^m g(j) \cdot f(i - j + \frac{m}{2}) \quad (2.1)$$

Konvolusi pada gambar dengan kombinasi berbagai filter dapat digunakan

untuk melakukan berbagai tugas seperti deteksi tepi, pertajam gambar dan blur. Proses pada operasi konvolusi dapat dilihat pada gambar II.3




Gambar II.3 Proses pada operasi konvolusi

Sumber: (Patterson & Gibson, 2017)

b. Pooling Layer

Pooling layer merupakan jenis lapisan tersembunyi yang sangat umum digunakan pada CNN. Tujuan utama dari *pooling* adalah untuk menurunkan sampel representasi *input*, matriks *output* pada lapisan tersembunyi dengan mengurangi dimensinya (Patel & Patel, 2020). Terdapat beberapa metode *pooling* yang umum digunakan yaitu: *average pooling*, *max pooling*, *min pooling* dan *mixed pooling* (Gholamalinezhad & Khosravi, 2020).



Gambar II.4 Contoh operasi Max-Pooling

c. *DropOut Layer*

Teknik *dropout* merupakan teknik regularisasi yang digunakan pada CNN yang dibangun dengan *neuron* dimana setiap *neuron* memiliki bobot seperti 0, 0.1, 0.2...1.0. *input* dari *dropout layer* merupakan *output* dari lapisan sebelumnya yang bertujuan untuk mengurangi waktu pelatihan komputasi dan meminimalkan jaringan dari *overfitting* (Nandini et al., 2021).


d. *Full Connected Layer*

Full connected layer dapat dianggap sebagai jaringan saraf tradisional yang melakukan inferensi logis (Ali et al., 2021). Jaringan ini umumnya digunakan untuk meratakan matriks menjadi vector yang selanjutnya akan dimasukkan kedalam jenis jaringan saraf yang terhubung sepenuhnya. Operasi matematika dari *full connected layer* penuh dinyatakan pada persamaan 2.2.

$$\mathbf{Z}_{v_0 \times 1} = \mathbf{Weight}_{v_0 \times v_1} \mathbf{l}_{v_1 \times 1} \cdot \mathbf{Bias}_{v_0 \times 1} \quad (2.2)$$

Dimana, v_1 dan v_0 merupakan ukuran vektor *input* dan *output*, Z merupakan *output* dari lapisan *full connected layer*. Dan bobot dan bias matriks masing masing diwakili oleh bobot dan bias.

Lapisan ini merupakan beberapa lapisan terakhir pada cnn dan bertindak sebagai pengklasifikasi di seluruh jaringan. Ilustrasi pada *fully connected layer* dapat dilihat pada gambar II.4



Gambar II.5 Ilustrasi fully connected layer


Sumber: (Patel & Patel, 2020)

II.3 *Arsitektur Convolutional Neural Network*

Beberapa tahun terakhir, arsitektur CNN telah disajikan dan berbagai modifikasi telah dicapai dalam arsitektur CNN sejak tahun 1989 hingga saat ini. Beberapa arsitektur dari CNN yang populer dan umum digunakan yaitu: *ResNet 50*, *VGG 16*, *VGG19*, *Alexnet*, *Googlenet*, *Imagenet*.

II.3.1 Alexnet

Alexnet pertama kali diusulkan oleh Alex Krizhevsky pada tahun 2012 dan dianggap sebagai arsitektur CNN mendalam pertama yang menunjukkan hasil terobosan dalam pengenalan gambar dan tugas klasifikasi (Thalagala & Walgampaya, 2021). Alexnet terdiri dari lima lapisan konvolusi, dua lapisan tersembunyi yang terhubung penuh, satu lapisan keluaran yang terhubung dan beberapa komponen CNN umum (Salih et al., 2020). Pembangunan arsitektur Alexnet diilustrasikan pada gambar II.5.




Gambar II.6 Ilustrasi arsitektur Alexnet

Seperti yang ditunjukkan pada Gambar II.5, *input* gambar pada Alexnet harus diskalarkan ke ukuran tetap yaitu $227 \times 227 \times 3$. Pada lapisan konvolusi pertama diterapkan filter konvolusi 96 dengan ukuran 11×11 , sedangkan pada lapisan kedua menggunakan filter konvolusi 256 dengan ukuran 5×5 , yang kemudian tiga lapisan berikutnya diterapkan filter konvolusi 384, 384 dan 256 dengan ukuran jendela 3×3 . Selain 5 lapisan konvolusi, terdapat dua lapisan yang terhubung penuh dengan 4096 *output neuron* yang kemudian diikuti oleh satu lapisan keluaran terhubung penuh yang ditempatkan pada ujung jaringan dengan jumlah kelas keluaran. Selanjutnya, *dropout relu* dan *preprocessing* merupakan langkah penting untuk mencapai kinerja yang baik dalam melakukan klasifikasi.

II.3.2 Visual Geometry Group 16 (VGG16)

Visual geometry group 16 (VGG16) adalah model CNN yang diusulkan oleh K. Simonyan dan A. Zisserman dari University of Oxford pada kompetisi ILSVR pada tahun 2014 (Ganakwar, 2020). VGG16 merupakan arsitektur CNN

yang memiliki enam belas lapisan yang terdiri dari tiga belas lapisan konvolusi, dua lapisan yang terhubung penuh dan satu lapisan klasifikasi (Rismiyati & Luthfiarta, 2021). Arsitektur VGG16 diilustrasikan pada gambar II.6.




Gambar II.7 Ilustrasi Arsitektur VGG 16

Pada Gambar II.6, ukuran kernel dari semua lapisan konvolusi VGG 16 adalah 3 x 3. Perbedaan utama antara setiap lapisan konvolusi adalah jumlah filter di setiap lapisan. Pada dua lapisan pertama dari konvolusi memiliki 64 filter, dan lapisan 3 dan 4 memiliki 128 filter. Demikian pula, pada lapisan 4, 5, dan 6 yang memiliki jumlah filter yang berbeda yaitu 256 sedangkan pada enam lapisan berikutnya memiliki 512 filter. Pooling maksimal 2 x 2 dilakukan pada lapisan konvolusi 2, 4, 7, 10, dan 13. Keluaran pooling terakhir akan terhubung pada lapisan yang terhubung penuh dan terhubung pada lapisan klasifikasi yang akan menentukan kelas.

II.3.3 Visual Geometry Group 19 (VGG19)

Visual Geometry Group 19 (VGG19) yang diusulkan oleh Simonyan dan Zisserman pada tahun 2015 adalah arsitektur CNN yang terdiri dari sembilan belas


lapisan dengan enam belas lapisan konvolusi dan tiga lapisan tersembunyi yang terhubung penuh untuk mengklasifikasikan gambar (Bansal et al., 2021; Dahmane et al., 2021). Ilustrasi arsitektur VGG19 dapat dilihat pada gambar II.7.



Gambar II.8 Ilustrasi Arsitektur VGG 19

II.3.4 Residual Network 50 (ResNet50)

Residual network (ResNet50) diusulkan pertama kali oleh He et al pada tahun 2016. Resnet telah memperkenalkan koneksi residual antar lapisan yang membantu mengurangi loss, mempertahankan pengetahuan, dan meningkatkan kinerja selama fase pelatihan (Ali et al., 2021). Seperti arsitektur VGG, ukuran lapisan konvolusi adalah 3 x 3, ukuran *input* pada model ditetapkan dengan ukuran 224 x 224. Model diakhiri dengan lapisan *average pooling* dan lapisan yang terhubung penuh dengan fungsi aktivasi *softmax* (Bendjillali et al., 2020). Lapisan konfigurasi pada jaringan resnet50 ditunjukkan pada gambar II.7



Gambar II.9 Ilustrasi Arsitektur ResNet50

Tabel II.1 Tabel perbandingan Arsitektur CNN

Alexnet	VGG16	VGG19	Resnet50
Input (227 x 227 x 3)	Input (224 x 224 x 3)	Input (224 x 224 x 3)	Input (224 x 224 x 3)
Conv 1 96 x 11 x 11 (55 x 55 x 96)	Conv 64 x 3 x 3 (224 x 224 x 64) x2	Conv 64 x 3 x 3 (224 x 224 x 64) x2	Conv 64 x 7 x 7 (112 x 112 x 64)
Max Pool 3 x 3 (27 x 27 x 96)	Max Pool 3 x 3 (112 x 112 x 64)	Max Pool 3 x 3 (112 x 112 x 64)	Conv 64 x 1 x 1 Conv 64 x 3 x 3 x3 Conv 256 x 1 x 1
Conv 256 x 5 x 5 (27 x 27 x 256)	Conv 128 x 3 x 3 (112 x 112 x 128) x2	Conv 128 x 3 x 3 (112 x 112 x 128) x2	Conv 128 x 1 x 1 Conv 128 x 3 x 3 x3 Conv 512 x 1 x 1
Max Pool 3 x 3 (13 x 13 x 256)	Max Pool 3 x 3 (56 x 64 x 128)	Max Pool 3 x 3 (56 x 64 x 128)	Conv 256 x 1 x 1 Conv 256 x 3 x 3 x3 Conv 1024 x 1 x 1
Conv 384 x 3 x 3 (13 x 13 x 384)	Conv 256 x 3 x 3 (56 x 64 x 256) x3	Conv 256 x 3 x 3 (56 x 64 x 256) x4	Conv 512 x 1 x 1 Conv 512 x 3 x 3 x3 Conv 2048 x 1 x 1
Conv 384 x 3 x 3 (13 x 13 x 384)	Max Pool 3 x 3 (28 x 28 x 512)	Max Pool 3 x 3 (28 x 28 x 512)	Max Pool 3 x 2
Conv 256 x 3 x 3 (13 x 13 x 256)	Conv 512 x 3 x 3 (28 x 28 x 512) x3	Conv 512 x 3 x 3 (28 x 28 x 512) x4	Fully Connected (1000)
Max Pool 3 x 3 (6 x 6 x 256)	Max Pool 3 x 3 (28 x 28 x 512)	Max Pool 3 x 3 (28 x 28 x 512)	
Fully Connected (4096)	Conv 512 x 3 x 3 (14 x 14 x 512) x3	Conv 512 x 3 x 3 (14 x 14 x 512) x4	
Fully Connected (4096)	Max Pool 3 x 3 (7 x 7 x 512)	Max Pool 3 x 3 (7 x 7 x 512)	
Fully Connected (1000)	Fully Connected (4096) x2	Fully Connected (4096) x2	

II.4 Fungsi Optimasi Pada Arsitektur CNN

Pengoptimal adalah fungsi atau algoritme yang memodifikasi atribut jaringan saraf, seperti bobot dan kecepatan pembelajaran. Dalam pembelajaran mesin dan statistik, kecepatan pembelajaran adalah parameter penyetelan dalam algoritme pengoptimalan yang menentukan ukuran langkah pada setiap iterasi sambil bergerak menuju fungsi kerugian minimum. *Gradient Descent* adalah algoritme optimisasi untuk meminimkan *objective function* $J(\theta)$ yang diparameterisasi oleh sebuah model parameter $\theta \in \mathbb{R}^d$ dengan cara melakukan update parameter dengan arah terbalik dari *gradient objective function* $\nabla_{\theta} J(\theta)$ dengan memperhitungkan parameter sebelumnya

Dalam penerapannya *gradient descent* konvensional memiliki beberapa permasalahan sehingga untuk menyelesaikan masalah tersebut diperlukan teknik lain yaitu *stochastic gradient descent*, salah satu teknik terbaik yang dapat digunakan adalah teknik *adaptive learning rate* seperti *RMSProp*. *RMSProp* merupakan metode *adaptive learning rate* yang mendasar. Fitur dari metode ini adalah metode otomatis didalam menurunkan dan menaikkan *learning rate* itu sendiri. *RMSProp* dideskripsikan sebagai “membagi *learning rate* untuk setiap bobot dengan menjalankan magnitudes rata-rata pada gradient untuk bobot tersebut pada saat itu”. Perhitungan dari algoritma *RMSProp* dapat dilihat pada persamaan sebagai berikut.

$$E[(\nabla \theta_i^{t^2})] = \gamma E[(\nabla \theta_i^{t-1})^2] + (1 - \gamma)(\nabla \theta_i^t)^2 \quad (2.3)$$

$$\alpha_i^t = \frac{\alpha}{\sqrt{E[(\nabla \theta_i^{t^2})] + \epsilon}} \quad (2.4)$$

$$\theta_i^t = \theta_i^{t-1} - \alpha_i^t \nabla \theta_i^t \quad (2.5)$$

Dimana $E[(\nabla \theta_i^{t^2})]$ merupakan menu square t setelahnya, γ merupakan parameter rmsDecay yang biasanya diatur dengan nilai 0.9 atau 0.95, kemudian $\nabla \theta_i^{t-1}$ merupakan mean square saat ini, $\nabla \theta_i^t$ merupakan nilai parameter yang dikuadratkan, kemudian α merupakan learning rate, e adalah nilai epsilon, θ_i^t merupakan nilai parameter setelahnya.

II.5 Sel Darah Putih


Sel darah putih atau *white blood cell* (WBC) adalah bagian dari sistem imun yang bersirkulasi dalam darah dan meningkatkan respons inflamasi dan seluler terhadap cedera atau *pathogen* (Tigner et al., 2021). Sel darah putih dibagi menjadi dua kelompok berdasarkan keberadaan butiran dalam sitoplasmanya yaitu *granulosit* dan *agranulosit*. Pemeriksaan jumlah sel darah putih dalam darah biasanya merupakan bagian dari tes sel darah lengkap (CBC). Dapat digunakan untuk memeriksa kondisi seperti infeksi, peradangan, alergi, leukemia, dll .

Struktur sel darah putih, Sebagian besar terdiri dari *large lobed nucleus* yang digunakan untuk membedakan sel darah putih dengan jenis sel darah lainnya. Sel darah putih terbagi menjadi beberapa jenis yaitu:

a. Monocytes

Jumlah monosit dalam tubuh manusia yang sehat berkisar antara 6% sampai 9% dari total jumlah sel darah putih. Umur monosit bervariasi dari beberapa jam hingga beberapa hari. Monosit juga berperan dalam menghadirkan


patogen ini ke sel T, yang dapat dengan mudah dibunuh dan membantu mengurangi waktu respons antibodi pada manusia. Fungsi terpentingnya adalah membersihkan sel-sel mati di dalam tubuh.



Gambar II.10 Contoh jenis Monocytes

b. Eosinophil


Jumlah pasti eosinofil dalam tubuh bervariasi sepanjang hari, tergantung pada musim dan berbagai tahap tubuh manusia. Rata-rata, eosinofil membentuk 2-4% dari total jumlah sel darah putih dan dapat bertahan dalam aliran darah selama 8-12 hari. Ini berada di medula oblongata, korteks, saluran pencernaan bagian bawah, dan kelenjar getah bening (Singh et al., 2020). eosinofil mungkin paling dikenal karena perannya dalam memicu gejala alergi. Eosinofil dapat berlebihan dalam meningkatkan respons imun terhadap sesuatu yang tidak berbahaya.



Gambar II.11 Contoh jenis Eosinophil

c. *Neutrophils*


Jumlah neutrophil dalam tubuh manusia menyumbang sekitar 60-70%. neutrophil merupakan sel pertama dari sistem kekebalan yang merespons penyerang seperti bakteri atau virus. Neutrofil dapat dikenali sebagai nukleus berbentuk kacang tanah multi-lobus berwarna ungu di dalam sel berwarna merah kulit. Umumnya, ada tiga hingga lima lobus dalam nukleus dengan sitoplasma yang tampak transparan.



Gambar II.12 Contoh jenis Neutrophil

d. *Lymphocytes*

Jumlah limfosit dalam tubuh manusia yang sehat menyumbang sekitar 25-30% dari total sel darah putih. Sel-sel ini hadir dalam sistem limfatik tetapi tidak dalam darah. Limfosit terdiri dari dua jenis sel, sel B dan sel T. Sel-sel ini bertanggung jawab atas penghancuran langsung sel yang terinfeksi virus pada manusia.



Gambar II.13 Contoh jenis Lymphocytes

e. *Basophils*

Basofil hanya membentuk sekitar 1% dari sel darah putih. Sel-sel ini mungkin paling dikenal karena perannya dalam asma. Namun, mereka penting untuk meningkatkan respons imun nonspesifik terhadap patogen, organisme yang dapat menyebabkan penyakit. Ketika dirangsang, sel-sel ini melepaskan histamin, bersama dengan bahan kimia lainnya.

II.6 Penelitian Terdahulu

Untuk memudahkan proses penelitian ini, maka perlu dilakukan kajian terhadap penelitian-penelitian sebelumnya yang berkaitan dengan judul penelitian ini. Untuk menghindari penggunaan kata dan frasa yang sama seperti pada penelitian sebelumnya, tinjauan pustaka ini juga menyertakan temuan penelitian sebelumnya sebagai berikut:

Penelitian (Çınar & Tuncer, 2021), berjudul “*Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-Googlenet-SVM*” dalam penelitiannya mengusulkan model *deep learning* berbasis hybrid CNN. Untuk mengetahui keunggulan dari metode yang diusulkan peneliti juga melakukan klasifikasi menggunakan model yang dilatih dengan Alexnet dan googlenet. Dari penelitian yang dilakukan didapatkan hasil bahwa model hybrid Alexnet-googlenet-SVM memberikan akurasi yang lebih tinggi daripada Alexnet dan googlenet yaitu 99.73%.

Penelitian (Zakaria et al., 2021), berjudul “*VGG16, ResNet-50, and Googlenet deep learning architecture for breathing sound classification: a comparative study*”. Pada penelitiannya melakukan klasifikasi suara pernapasan dengan melakukan perbandingan tiga arsitektur *convolutional neural network* yaitu VGG16, ResNet-50 dan Googlenet. Hasil klasifikasi yang dijalankan pada google colaboratory, didapatkan tingkat akurasi dari masing masing arsitektur yaitu 62,50%, 62,29%, dan 63,69%.

Penelitian (Ullah et al., 2022), berjudul “*Comparative analysis of Alexnet, resnet18 and squeezeNet with diverse modification and arduous implementation*” dalam penelitiannya melakukan analisis perbandingan arsitektur Alexnet, resnet18, dan squeezeNet untuk klasifikasi retakan jalan. Pada proses percobaan gambar pelatihan dan pengujian dijaga tetap sama dalam epoch dan iterasi. Hasil penelitian didapatkan bahwa arsitektur ResNet18 mendapatkan akurasi superlatif sebesar 85.20%.

Penelitian (Harahap et al., 2020), berjudul “*Implementation of convolutional neural network in the classification of red blood cells have affected of malaria*” dalam penelitiannya melakukan analisis perbandingan jaringan LeNet-5 dan DRNet untuk klasifikasi sel darah. Sebelum melakukan pelatihan, dilakukan pre-processing data dan augmentasi data dari dataset. Jumlah lapisan yang digunakan pada model LeNet dan DRNet yaitu 4 dan 7. Hasil penelitian menunjukkan bahwa model DRNet memperoleh tingkat akurasi yang lebih tinggi yaitu 97,3%.

Penelitian (Musliman et al., 2021), berjudul “*Identification of white blood cells using machine learning classification based on feature extraction*”. Pada penelitiannya melakukan identifikasi sel darah putih dengan membandingkan akurasi klasifikasi metode *k-nearest neighbor* (KNN), *naïve bayes classification* (NBC), dan *multilayer perceptron* (MLP). Proses klasifikasi dilakukan dengan menggunakan 100 data latih dan 50 data uji gambar sel darah putih. Hasil pengujian pada metode KNN, NBC, dan MLP memperoleh akurasi masing-masing sebesar 82%, 80%, dan 94%.

Penelitian (Athmaraman et al., 2021), berjudul “*White blood cells classification for the diagnosis of blood related diseases using neural network techniques*”. Dalam penelitian ini, model jaringan saraf *convolutional* (CNN) dieksploitasi untuk ekstraksi fitur otomatis dan gambar diklasifikasikan menggunakan pengklasifikasi tradisional seperti *linear discriminant analysis* (LDA) dan *logistic regression* (LR). Arsitektur CNN yang digunakan pada model Hybrid yaitu VGG19, inception V3 dan densenet169. Hasil penelitian menunjukkan bahwa model densenet169 – LDA memiliki performa terbaik dengan memperoleh tingkat akurasi 96%.

Penelitian (Girdhar et al., 2022), berjudul “*Classification of white blood cell using convolution neural network*” Mengusulkan sistem deteksi dan klasifikasi otomatis untuk sel darah putih berbasis CNN untuk mengenali 4 jenis sel darah yaitu *neutrophil*, *eosinophils*, *monocytes* dan *lymphocytes* dan memperoleh akurasi keseluruhan yang diperoleh dari pendekatan yang diusulkan adalah 98,55%.

Penelitian (Abou El-Seoud et al., 2020), berjudul “*Detection and classification of white blood cells through deep learning techniques*” dalam penelitiannya mengusulkan *convolutional neural network* untuk mendeteksi dan mengklasifikasi sel darah putih normal. Metode yang digunakan pada penelitian ini yaitu mengidentifikasi fitur tingkat tinggi dari sel darah putih normal kemudian melakukan klasifikasi sel darah putih menurut jenisnya. Hasil penelitian menunjukkan jaringan yang diusulkan mendapatkan akurasi hingga 96,78% dengan menggunakan 10.000 gambar sel darah.

Penelitian (Kousalya et al., 2020), berjudul “*Blood cells classification using convolutional neural network architecture*”. Pada penelitiannya melakukan klasifikasi sel darah putih dengan membandingkan arsitektur sederhana CNN, Lenet dan Alexnet. Dalam kerangka yang diusulkan lapisan konvolusi dan lapisan *pooling* digunakan untuk mengekstraksi fitur. Hasil penelitian menunjukkan arsitektur Alexnet memperoleh tingkat akurasi terbaik yaitu 80.37% sementara arsitektur sederhana CNN dan LeNet masing masing memperoleh akurasi yaitu 75.36% dan 65,21%.

Penelitian (Nishizaki, 2020), berjudul “*Classification of white blood cells using the convolutional neural network architecture*” melalui penelitiannya melakukan perbandingan arsitektur CNN yaitu Inception v3 dan ResNet untuk klasifikasi sel darah putih. Data set yang digunakan terdiri dari sekitar 2.500 gambar mikroskopis. Hasil penelitian menunjukkan bahwa model Inception v3 memiliki kinerja lebih baik dibandingkan ResNet, dengan memperoleh akurasi, presisi, dan recall masing masing yaitu 83% , 87%, dan 84%.

Tabel II.2 Tabel penelitian terdahulu

Peneliti (Tahun)	Metode	Keterangan
Çınar & Tuncer, (2021)	Alexnet, Googlenet, SVM	Melakukan klasifikasi sel darah putih dengan menggunakan model hybrid Alexnet, Googlenet dan SVM. Hasil Penelitian menghasilkan akurasi sebesar 99,73%.
Zakaria et al, (2021)	VGG16, ResNet50, Googlenet	Melakukan klasifikasi suara pernapasan dengan membandingkan tiga arsitektur CNN. Hasil Penelitian menunjukkan bahwa model Googlenet memperoleh tingkat akurasi terbaik yaitu 63,69%.
Ullah et al, (2022)	Alexnet, ResNet18, SqueezeNet	Melakukan klasifikasi retakan jalan dengan membandingkan arsitektur Alexnet, ResNet18 dan SqueezeNet. Hasil Penelitian menunjukkan arsitektur ResNet memperoleh akurasi superlative yaitu 85,20%.
Harahap et al, (2020)	LeNet, DRNet	Melakukan klasifikasi sel darah dengan membandingkan arsitektur LeNet dan DRNet. Hasil penelitian menunjukkan model DRNet memperoleh tingkat akurasi yang lebih baik yaitu 97.3%.

Tabel II.2 Tabel penelitian terdahulu (lanjutan)

Musliman et al, (2021)	KNN, Naïve Bayes, dan MLP	Melakukan identifikasi sel darah putih dengan membandingkan akurasi dari KNN, Naïve Bayes dan MLP. Hasil penelitian menunjukkan model MLP memperoleh tingkat akurasi sebesar 94%.
Athmaraman et al, (2021)	Hybrid VGG19, Inception V3, Densenet169	Melakukan Klasifikasi sel darah dengan membandingkan model hybrid VGG19, Inception V3, dan Densenet169. Hasil penelitian menunjukkan model Densenet169 – LDA memperoleh tingkat akurasi 96%.
Girdhar et al, (2022)	CNN	Mengusulkan sistem deteksi dan klasifikasi menggunakan CNN. Hasil penelitian menghasilkan tingkat akurasi 98,55%.
Abou El-Seoud et al, (2020)	CNN	Melakukan klasifikasi sel darah putih dengan menerapkan metode CNN. Hasil Penelitian menghasilkan tingkat akurasi hingga 96,78% dengan menggunakan 10.000 gambar sel darah.

Tabel II.2 Tabel penelitian terdahulu (lanjutan)

Kousalya et al, (2020)	Simple CNN, LeNet dan Alexnet	Melakukan klasifikasi sel darah putih dengan membandingkan arsitektur Simple CNN, LeNet dan Alexnet. Hasil penelitian menunjukkan arsitektur Alexnet memperoleh akurasi terbaik yaitu 80,37%.
Nishizaki, (2020)	Inception V3, ResNet	Melakukan perbandingan arsitektur Inception v3 dan ResNet untuk klasifikasi sel darah putih. Hasil penelitian menunjukkan arsitektur Inception V3 memiliki kinerja yang lebih baik yaitu 83%.

II.7 Perbedaan Dengan Penelitian Terdahulu

Dalam penelitian sebelumnya, terdapat beberapa celah yang perlu diperhatikan. Keterbatasan pada penelitian (Girdhar et al., 2022) dan (Abou El-Seoud et al., 2020) adalah model yang diusulkan menggunakan arsitektur sederhana CNN dan tidak terdapat studi perbandingan antar arsitektur yang ada. Selain itu pada beberapa penelitian lain hasil evaluasi kinerja arsitektur masih memiliki peluang untuk ditingkatkan. Oleh karena itu, kontribusi penelitian ini antara lain:

1. Membangun model pembelajaran mendalam untuk mengklasifikasikan sel darah putih menggunakan arsitektur CNN

2. Perbandingan kinerja dari antar arsitektur CNN: Alexnet, VGG16, VGG19 dan Resnet50 untuk mengetahui perbandingan performansi dan waktu pelatihan antara masing masing arsitektur dalam melakukan klasifikasi sel darah.
3. Meningkatkan hasil evaluasi kinerja dari arsitektur Alexnet, VGG16, VGG19 dan Resnet 50 dengan menggunakan fungsi optimasi RMSProp.