

Klasifikasi Citra Kanker Serviks Menggunakan *Deep Residual Network*

1st Revydo Bima Anshori

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

rvydobima@student.telkomuniversity.ac.id

2nd Hilman Fauzi TSP

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

hilmanfauzitsp@telkomuniversity.ac.id

3rd Thomhert S. Siadari

Fakultas Teknik Elektro

Universitas Telkom

Bandung, Indonesia

thomhert@telkomuniversity.ac.id

Abstrak—Penyakit kanker serviks menempati posisi ke dua dengan angka kematian tinggi kaum wanita setiap tahunnya menurut WHO. Penyebab penyakit ini karena adanya Human Papilloma Virus (HPV) yang menyerang langsung ke serviks, selain itu juga pola hidup yang kurang sehat dapat mempengaruhi tereserangnya penyakit ini. Deteksi dini kanker serviks dapat dilakukan dengan menggunakan pemeriksaan Inspeksi Visual Asam Asetat (IVA). Hasil dari pemeriksaan IVA dapat dilihat kasat mata tetapi ahli medis memiliki perbedaan diagnosis dikarenakan penglihatan sendiri. Untuk membantu ahli medis mendapatkan diagnosis yang sesuai maka pemeriksaan dapat dilakukan dengan pendekatan teknologi. Teknologi yang akan digunakan adalah citra digital. Pengambilan gambar hasil pemeriksaan IVA format .jpg. Penelitian ini dilakukan klasifikasi citra kanker serviks dari hasil pemeriksaan IVA yang telah dilakukan oleh Rumah Sakit Hasan Sadikin Bandung. Untuk pengolahan citra pemeriksaan IVA akan menggunakan citra hasil CLAHE dan citra hasil Canny Edge Detection. Untuk pengklasifikasian akan menggunakan deep learning dengan arsitektur ResNet-50 dan ResNet-101 serta melakukan pengujian terhadap hyperparameter yaitu optimizer, learning rate, batch size, dan input size. Pada penelitian ini hasil terbaik menggunakan citra hasil Canny Edge Detection dengan hyperparameter menggunakan optimizer SGD, learning rate 0.1, batch size 32, dan input size 224×224. Dari hyperparameter tersebut hasil akursi yang dicapai sebesar 98,26 %.

Kata kunci— Canny Edge Detection, CLAHE, Kanker Serviks, Pengolahan Citra Digital, Pemeriksaan IVA, ResNet.

I. PENDAHULUAN

Kanker adalah suatu penyakit yang ditandai dengan pertumbuhan sel abnormal di luar batas normal yang kemudian dapat menyerang bagian tubuh yang berdampingan dan/atau menyebar ke organ lain (WHO, 2018). Banyak sekali jenis kanker yang ganas salah satunya adalah kanker serviks. Kanker serviks menyerang bagian leher rahim wanita, kanker ini merupakan kanker ganas yang ditakuti wanita. Penyebab dari kanker serviks adalah virus HPV (*Human Papilloma Virus*) sub tipe onkogenik, terutama sub tipe 16 dan 18. Berdasarkan GLOBOCAN 2020 kanker serviks berada di posisi ke-8 sebagai penyebab kematian. Di Indonesia kanker serviks menduduki urutan kedua dari 10 kanker terbanyak berdasarkan data dari GLOBOCAN tahun 2020 dengan insidens sebesar 9,2%. Menurut perkiraan Departemen Kesehatan RI saat ini, jumlah wanita penderita baru kanker serviks berkisar 90-100 kasus per 100.000 penduduk dan setiap tahun terjadi 40 ribu kasus kanker serviks [1].

Deteksi dini kanker serviks dapat dilakukan dengan metode pap smear dan metode IVA. Deteksi dini dilakukan untuk mengetahui potensi kanker serviks, pemeriksaan IVA paling mudah dan murah untuk ditemukan. IVA merupakan tes visual dengan menggunakan larutan asam asetat sebesar

2-5% diusapkan di dinding rahim, tujuannya adalah untuk melihat adanya perubahan warna pada dinding rahim setelah diusapkan. Jika hasil dari pengusapan pada serviks ditemukan bercak putih maka ada potensi kanker serviks [2].

Beberapa penelitian telah dilakukan sebelumnya untuk mengklasifikasi citra kanker serviks hasil pemeriksaan IVA. Pada penelitian [3] dilakukan pengolahan citra digital hasil pemeriksaan IVA dengan menggunakan metode CNN (*Convolutional Neural Network*). Akurasi optimal yang didapatkan pada penelitian dengan menggunakan metode CNN (*Convolutional Neural Network*) adalah 96%. Hal ini menunjukkan bahwa mengklasifikasi citra kanker serviks hasil pemeriksaan IVA dapat dilakukan dengan metode CNN.

Terdapat berbagai macam model CNN salah satunya adalah *Deep Residual Network*. *Deep Residual Network* (ResNet) memperkenalkan fitur baru yang bernama *shortcut connection* yang dimana fitur ini memungkinkan untuk memiliki jaringan yang lebih dalam serta mampu mengurangi nilai *error rate*.

Pada penelitian [4] dilakukan klasifikasi citra kanker serviks menggunakan metode *Deep Residual Network*. Model *Deep Residual Network* yang digunakan pada penelitian ini adalah ResNet-18. Akurasi optimal pada penelitian adalah 97%. Akurasi yang didapatkan dengan menggunakan *Deep Residual Network* memiliki akurasi lebih baik dalam mengklasifikasi citra kanker serviks.

Berdasarkan uraian penelitian yang telah dilakukan sebelumnya. Pada tugas akhir ini dibuat perancangan sistem klasifikasi citra kanker serviks menggunakan arsitektur *Deep Residual Network*. Jenis arsitektur *Deep Residual Network* yang akan digunakan pada penelitian adalah ResNet-50 dan ResNet-101. Dataset yang akan digunakan pada penelitian ini berasal dari Rumah Sakit Hasan Sadikin, Bandung. Tujuan dari penelitian ini untuk membantu dokter untuk mengetahui pola lesi putih dengan menggunakan bantuan metode *Deep Residual Network* dalam mengklasifikasi citra kanker serviks hasil pemeriksaan IVA.

II. KAJIAN TEORI

A. Kanker Serviks

Serviks berasal bahasa latin yang artinya leher. Serviks terdiri dari dua bagian yaitu mulut rahim dan leher rahim. Leher rahim adalah bagian sempit dari bagian bawah rahim sedangkan mulut rahim adalah bagian terendah rahim, keduanya merupakan bagian dari serviks [5]. Kanker leher rahim atau disebut juga kanker serviks merupakan jenis

kanker yang disebabkan oleh virus *human papilloma virus* (HPV) onkogenik, yang dimana virus ini menyerang bagian leher rahim. Virus yang menyerang leher rahim adalah HPV tipe 16 dan 18[6]. Untuk lebih mengenal bagian bagian serviks dapat dilihat pada gambar 1. Pada gambar 1 dapat dilihat bahwa bagian leher rahim (serviks) terletak pada bagian bawah rahim. Rahim terdiri dari 2 bagian, yaitu bagian atas disebut juga tubuh rahim tempat berkembangnya janin dan bagian bawah rahim disebut juga leher rahim sebagai penghubung antara tubuh rahim dan vagina.

Terdapat banyak faktor penyebab terjadinya kanker serviks antara lain:

1. Aktivitas seksual pada usia muda
2. Berhubungan seksual dengan *multipartner*
3. Merokok



B. Inspeksi Visual Asam Asetat (IVA)

Inspeksi Visual Asam Asetat atau biasa disebut juga IVA merupakan salah satu metode skrining untuk mencegah kanker serviks. Metode IVA merupakan skrining untuk mengidentifikasi kanker serviks yang cukup efisien dan efektif karena dapat dilakukan oleh tenaga kesehatan selain itu juga biaya pemeriksaan IVA tergolong murah. Pemeriksaan IVA dilakukan dengan mengusapkan asam asetat 3-5% ke serviks. Setelah dilakukan pengusapan ditunggu kurang lebih 1 menit supaya asam asetat bereaksi[7]. Setelah menunggu 1 menit lalu dilakukan pengamatan warna serviks setelah dilakukan pengusapan, jika dalam pengamatan ditemukan bercak putih atau lesi putih maka dapat disebut lesi IVA (+) dan diduga memiliki sel kanker serviks. Karakteristik hasil pemeriksaan IVA dapat dilihat pada tabel 1 berikut.

TABEL 1
KARAKTERISTIK HASIL PEMERIKSAAN IVA

Hasil Uji	Karakteristik
Normal	Serviks tampak normal
Negatif	Muncul bercak putih namun tidak menutupi semua bagian serviks
Positif	Muncul bercak putih banyak serta menutupi bagian serviks

Menurut penelitian hasil pemeriksaan deteksi dini kanker serviks menggunakan metode IVA memiliki sensitivitas dan spesifisitas yang tinggi untuk digunakan sebagai metode pendeteksian lesi kanker dibandingkan metode *pap smear*.

C. Sambungan Skuamosa Kolumnar (SSK)

Sambungan *Skuamosa Kolumnar* (SSK) memiliki warna yang berbeda dengan warna yang ada di sekitar daerah

serviks. SSK memiliki bentuk seperti garis yang merupakan batas antara epitel yang melapisi ektoserviks (porsio) dan endoserviks kanalis serviks[8]. Letak SSK dipengaruhi berbagai faktor seperti umur, aktivitas seksual dan pertumbuhan hormon. Pada wanita usia muda SSK berada di luar. Sedangkan wanita usia lanjut diatas 35 tahun SSK berada di dalam kanalis. Untuk mengenal bagian SSK dapat dilihat pada gambar 2.



GAMBAR 2
SSK

D. Pengolahan Citra

Image processing atau biasa disebut juga dengan pengolahan citra merupakan suatu proses pengolahan citra menggunakan komputer. Tujuan dari pengolahan citra adalah mentransformasikan kualitas dari citra agar menjadi informasi yang dapat dipahami oleh manusia atau komputer. Pengolahan citra memiliki masukan dalam bentuk citra dan keluarannya berbentuk citra dengan kualitas yang lebih baik dari masukannya. Teknik pengolahan citra diawali dengan menangkap citra analog lalu mengubahnya menjadi citra digital dengan bantuan kamera digital[10]. Proses selanjutnya citra akan dihilangkan *noise* nya, proses ini disebut *preprocessing*. *Noise* yang terdapa pada citra digital akan dihilangkan agar tidak merusak citra dan dapat memilih bagian citra yang akan dilakukan obeservasi.

E. Canny Edge Detection

Terdapat berbagai macam jenis algoritma yang digunakan untuk mendeteksi tepi, salah satunya adalah *Canny Edge Detection* (Deteksi Tepi Canny). *Canny Edge Detection* dikembangkan oleh John F. Canny pada tahun 1986 dan menggunakan algoritma multi tahap untuk dapat mendeteksi berbagai jenis dalam gambar[11]. Metode ini sudah berumur cukup lama, namun metode ini masih sering dipakai dalam penelitian sampai saat ini. Terdapat kategori algoritma yang dikembangkan oleh John F Canny adalah sebagai berikut :

1. Deteksi

Pendeteksian titik koordinat tepi yang benar harus dimaksimalkan sementara itu untuk kemungkinan salah pendeteksian titik koordinat tepi harus diminimalkan.

2. Lokalisasi

Lokasi tepi yang terdeteksi harus sedekat mungkin dengan tepi yang nyata, sehingga hasil lebih maksimal.

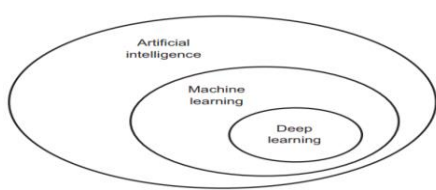
3. Jumlah Tanggapan

Tiap tepi hanya memiliki satu respon sehingga mempermudah proses deteksi selain itu juga hasil dari pengolahan citra baik.

Dengan menggunakan kategori sesuai dengan John F Canny ini, maka *Canny Edge Detection* optimal untuk kelas tepian tertentu. Tidak dapat dipungkiri bahwa semua gambar yang di ambil melalui kamera akan berisi banyak *noise*. Untuk mencegah adanya *noise* salah deteksi sebagai tepian, maka *noise* pada gambar harus dikurangi.

F. Artificial Intelligence (AI)

Artificial Intelligence (AI) atau kecerdasan buatan lahir pertama kali pada tahun 1950 an pada saat para ilmuwan komputer memikirkan bagaimana komputer dapat berpikir seperti manusia[12]. Pada dasarnya AI (*Artificial Intelligence*) adalah bagian ilmu komputer yang membuat agar mesin komputer dapat melakukan pekerjaan seperti dan sebaik yang dilakukan manusia. Secara umum AI mencakup *machine learning* dan *deep learning*, tetapi AI juga mencakup pendekatan yang tidak memerlukan pembelajaran. Berikut pada gambar 3 merupakan himpunan bagian dari AI.



GAMBAR 3
HIMPUNAN BAGIAN DARI AI

G. Deep Learning

Sejak dikenalkan pada awal tahun 2006, penggunaan DL telah diterapkan diberbagai bidang bagian yang luas dan beragam, diantaranya adalah pengenalan suara, pengenalan citra, pengenalan bahasa, dan lain sebagainya. *Deep Learning* (DL) merupakan sub bagian dari *machine learning*. *Deep Learning* terdiri dari banyak lapisan (*hidden layer*) dan membentuk tumpukan. Dengan adanya *Deep Learning*, waktu yang dibutuhkan untuk training akan semakin sedikit karena masalah hilangnya gradien pada propagasi balik akan semakin rendah. *Feature Engineering* adalah salah satu fitur utama yang ada di *Deep Learning*, fitur ini berguna untuk mengekstrak pola dari data sehingga memudahkan model untuk membedakan kelompok[13].

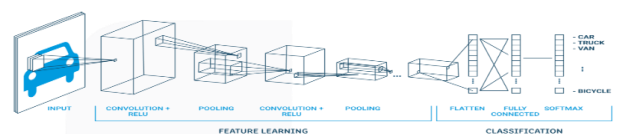
Penggunaan algoritma pada *Feature Engineering* dapat menemukan pola umum yang penting pada data dengan tujuan untuk membedakan antara kelompok pada *Deep Learning*. Seperti halnya *Machine Learning* algoritma ini memiliki jenis pembelajaran terawasi dan tidak terawasi. Model pembelajaran terawasi pada *Deep Learning* misalnya *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), *Long Short Term Memory* (LSTM), *Gated Recurrent Units* (GRU) dan lain sebagainya. [13].

H. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu dari metode *deep learning* dimana metode ini merupakan operasi konvolusi yang menggabungkan beberapa lapisan proses, dengan menggunakan beberapa elemen yang beroperasi secara paralel dan terinspirasi dari sistem saraf tiruan. Algoritma banyak digunakan oleh peneliti untuk melakukan analisis pada suatu objek, algoritma ini merupakan salah satu model terbaik dalam melakukan penyelesaian

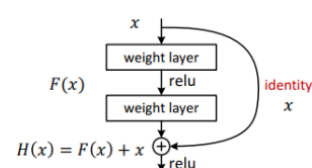
permasalahan pengenalan objek[14]. Struktur CNN terdiri dari input, proses ekstraksi fitur, proses klasifikasi dan output. Terdapat beberapa lapisan tersembunyi dalam proses ekstraksi di CNN, lapisan ini biasa disebut *hidden layer*. Berikut merupakan *hidden layer* yang terdapat di CNN, yaitu :

1. *Convolution layer*, dimana lapisan konvolusi ini bekerja menggunakan *filter* untuk mengekstraksi objek dari citra input. *Filter* ini digunakan untuk melakukan deteksi karakter dari citra input seperti kurva, tepi, dan warna[15].
2. *ReLU (Rectification Linear Unit)*, merupakan suatu operasi untuk memperkenalkan non linearitas dan melakukan peningkatan representasi dari model. Dengan adanya fungsi ReLU maka *layers* yang berbeda dapat dilakukan penumpukan. Fungsi dari ReLU merupakan fungsi aktivasi yang paling umum digunakan dalam metode CNN[15].
3. *Pooling layer*, merupakan *layer* yang biasanya diletakan di antara *convolution layer* dan *ReLU layer* dimana *layer* ini berfungsi untuk mengurangi jumlah parameter perhitungan, seperti tinggi dan lebar inputan berupa citra. *Pooling* akan membagi hasil keluaran *convolutional layer* menjadi beberapa grid. Terdapat dua jenis model *pooling* yang biasa digunakan di *pooling layer* yaitu *Max Pooling* dan *Average Pooling*[15].



I. Deep Residual Network

Deep Residual Network merupakan salah satu arsitektur dari CNN yang diusulkan oleh He, dkk pada tahun 2015. Arsitektur ini dibangun untuk mengatasi permasalahan pada pelatihan *Deep Learning*, karena pelatihan *Deep Learning* pada umumnya memakan waktu cukup banyak dan terbatas pada jumlah lapisan tertentu. Untuk mengatasi hal tersebut metode *deep residual network* memberikan solusi dengan menggunakan fitur *skip connection* atau *shortcut connection*[16]. Kelebihan dari arsitektur *deep residual network* adalah kinerja dari model ini tidak menurun walaupun arsitekturnya semakin dalam dan semakin banyak *layer* yang digunakan. Selain itu, perhitungan komputasi yang dilakukan lebih ringan dan kemampuan untuk melatih jaringan yang lebih baik sehingga hal ini membuat hasil pengujian tidak menurun. *Deep residual network* memiliki beberapa macam jenis arsitektur yang dibedakan berdasarkan jumlah *layer* yang digunakan, mulai dari 18 *layer*, 34 *layer*, 50 *layer*, 101 *layer*, sampai 152 *layer*[17].



J. Optimizer

Optimizer adalah suatu algoritma yang dimana algoritma ini bertujuan untuk memperbarui *weight* dan *bias* pada proses pembelajaran model yang telah dibuat untuk meminimalisir nilai *loss function* dengan menyamakan *output* yang diinginkan dengan *output* yang diprediksi[18]. Pada penelitian ini dilakukan pengujian terhadap tiga jenis *optimizer*, yaitu *Adaptive Moment* (Adam), Adamax, dan *Stochastic Gradient Descent* (SGD).

K. Learning Rate

Learning rate merupakan salah satu parameter pembelajaran yang berfungsi untuk menghitung nilai koreksi *weight* atau bobot dalam pembelajaran model yang telah dibuat. Nilai *learning rate* beragam namun umumnya nilai yang digunakan berkisar antara 0.1 sampai dengan 1[19]. Jika memilih nilai *learning rate* dengan nilai terlalu kecil maka hal yang akan terjadi adalah waktu *training* yang dilakukan lama sedangkan jika menggunakan nilai *learning rate* yang besar maka hasil dari pembelajaran akan kurang baik atau tidak optimal.

L. Batch Size

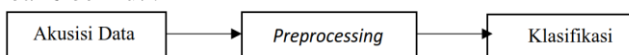
Batch size adalah parameter pada pembelajaran *deep learning* yang bertugas untuk mengatur banyaknya sampel pada saat dilakukan proses optimasi[20]. Ukuran nilai *batch size* yang umumnya digunakan mulai dari 4 hingga 1024. Semakin besar nilai *batch size* maka semakin cepat proses komputasi. Ukuran *batch size* mempengaruhi hasil dari komputasi yang dimana bila nilai *batch size* terlalu besar maka hasil yang didapatkan bisa kurang maksimal.

M. Input Size

Input size merupakan salah satu parameter yang akan digunakan pada penelitian ini. *Input size* adalah ukuran dimensi citra yang digunakan pada saat proses komputasi[28]. Nilai *Input size* yang umumnya digunakan adalah 128×128 , 224×224 , dan 256×256 .

III. METODE

Pada perancangan sistem klasifikasi kanker serviks menggunakan arsitektur *Deep Residual Network* kali ini akan dibuat beberapa tahapan dalam bentuk diagram alir pada gambar 6 berikut :



GAMBAR 6
BLOK DIAGRAM DESAIN SISTEM

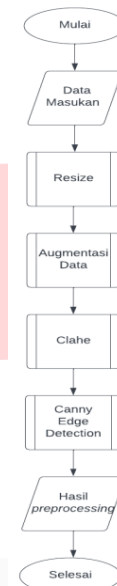
A. Akusisi Data

Pada penelitian ini untuk data masukan didapatkan dari citra yang diambil dari pemeriksaan menggunakan pemeriksaan IVA yang dilakukan di Rumah Sakit Hasan Sadikin, Bandung. Pengambilan data dilakukan secara langsung menggunakan kamera dengan minimum resolusi 8 MP pada OS android. Pengambilan gambar dilakukan dengan jarak kurang lebih 10 – 18 cm dengan fokus dekat pada mulut

rahim, untuk pencahayaan dalam ruangan sebesar 300 – 500 lux dan hasil gambar disimpan dalam bentuk format .jpg. Dalam pengujian sistem ini data yang digunakan terbagi dalam dua kelas yaitu kelas positif dan kelas negatif.

B. Preprocessing

Tahap *preprocessing* data merupakan suatu proses yang dilakukan dengan tujuan mendapatkan citra yang lebih baik untuk dilakukan tahap selanjutnya. Dibawah ini merupakan *flowchart* dari proses *preprocessing* pada Gambar 7.



GAMBAR 7
FLOWCHART PREPROCESSING

1. Resize

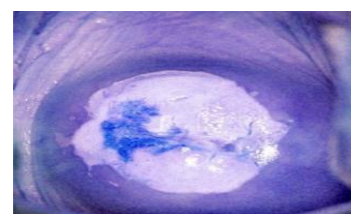
Pada tahap *resize* ini merupakan sebuah proses untuk mengubah ukuran citra. Ukuran citra masukan sangat beragam maka dari itu tahap *resize* ini sangat diperlukan agar ukuran dari masing masing citra masukan sama. Ukuran citra dapat diperbesar maupun diperkecil. Untuk pengujian ini akan menggunakan beberapa ukuran citra yaitu 128×128 , 224×224 , dan 256×256 .

2. Augmentasi Data

Pada tahap Augmentasi Data adalah suatu teknik untuk memanipulasi data citra. Tujuan dari Augmentasi Data adalah untuk menambahkan atau mengurangi data jika banyak datanya tidak sama banyaknya dari masing-masing kelas.

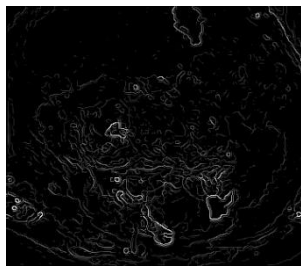
3. CLAHE

CLAHE merupakan singkatan dari *Contrast Limited Adaptive Histogram Equalization* (CLAHE). CLAHE merupakan salah satu proses dari *preprocessing* untuk meningkatkan kualitas citra. CLAHE sendiri mampu menghilangkan *noise* yang terdapat pada citra dengan melakukan pembatasan nilai kontras.



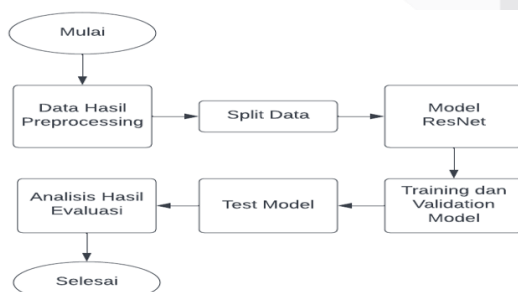
4. Canny Edge Detection

Pada proses *Canny Edge Detection* akan dilakukan pengambilan gambar skala abu-abu sebagai input dan akan memberikan hasil gambar yang menunjukkan lokasi diskontinuitas intensitas citra sebagai output dari proses ini yaitu tepi. *Canny Edge Detection* pertama kali akan melakukan proses *Gaussian convolution* dengan tujuan menghaluskan gambar masukan dan menghapus *noise* yang terdapat pada inputan. Selanjutnya operator turunan pertama setelah dihaluskan dan dihilangkan dari *noise* akan dilakukan penerapan untuk menyoroti lokasi yang diskontinuitas pertama yang paling tinggi. Data masukan citra hasil pemeriksaan IVA yang beragam akan dibagi menjadi 2 kelompok yaitu data pelatihan dan data pengujian. Dimana porsi dari data pelatihan adalah 90 % dan data pengujian 10 %. Data yang akan digunakan untuk pelatihan dan data untuk dilakukan pengujian akan diambil secara acak dari data set yang digunakan.



C. Klasifikasi

Pada tahapan ini merupakan tahapan klasifikasi. Data yang telah dilakukan proses *preprocessing* selanjutnya akan dilakukan proses klasifikasi. Terdapat beberapa tahapan klasifikasi pada penelitian ini. Berikut ini merupakan *flowchart* klasifikasi dari mulai memasukan data hasil *preprocessing* hingga didapatkan model yang terbaik untuk klasifikasi dapat dilihat pada gambar 9.



GAMBAR 9
FLOWCHART KLASIFIKASI

Flowchart proses klasifikasi dapat dilihat pada Gambar 9 setelah proses *prerprocessing* terhadap dataset dilakukan proses *split data* yang dimana proses ini bertujuan untuk

membagi data *training*, *validation* dan *test*. Proses selanjutnya adalah melakukan konfigurasi model arsitektur, model arsitektur yang digunakan pada penelitian ini adalah ResNet-50 dan ResNet-101. Tahap selanjutnya adalah melakukan konfigurasi *hyperparameter* sebelum melakukan proses pelatihan dan pengujian. *Hyperparameter* yang digunakan adalah *Optimizer*, *Learning rate*, *Batch size*, dan *Input size*, pada proses pelatihan nilai *epoch* yang digunakan adalah 40. Setelah pengaturan konfigurasi *hyperparameter* dilakukan tahapan selanjutnya adalah melakukan pelatihan dan pengujian terhadap model arsitektur ResNet-50 dan ResNet-101. Selanjutnya dilakukan analisis terhadap hasil pelatihan dan pengujian yang telah dilakukan.

D. Parameter Performansi

Parameter performansi digunakan sebagai tolak ukur penilaian kinerja dan kualitas dari sistem yang telah dibuat. Fungsi dari parameter performansi untuk mengetahui apakah sistem sudah mampu mempelajari data dari setiap kelas. Untuk mengetahui kualitas sistem dapat dilihat dari nilai *Confusion Matrix* dengan tujuan untuk memudahkan dalam menganalisis hasil akurasi, presisi, *recall*, dan *F1-Score*.

1. Confusion Matrix

Confusion Matrix merupakan suatu parameter yang dapat digunakan untuk melakukan evaluasi kualitas dan kinerja dari model yang sudah di buat. Dapat dilihat pada Tabel 2 merupakan tabel *confusion matrix*. Nilai dari *Confusion Matrix* digunakan untuk menghitung nilai akurasi, presisi, *recall* dan *F1-Score*.

TABEL 2 CONFUSION MATRIX

Confusion Matrix		Kelas Aktual	
		Positif	Negatif
Kelas Prediksi	Positif	TP	FP
	Negatif	FN	TN

Keterangan :

True Positive (TP): Kondisi dimana data IVA (+) diprediksi dengan benar

True Negative (TN): Kondisi dimana data IVA (-) diprediksi dengan benar

False Positive (FP): Kondisi dimana data IVA (-) diprediksi sebagai IVA (+)

False Negative (FN): Kondisi dimana data IVA (+) diprediksi sebagai IVA (-)

2. Akurasi

Akurasi merupakan parameter performansi untuk membandingkan antara kelas yang diprediksi benar terhadap total keseluruhan data yang digunakan. Akurasi pada penelitian ini berfungsi untuk mengetahui efektifitas dari masing-masing kelas dalam melakukan klasifikasi. Untuk menghitung nilai akurasi dapat menggunakan rumus 3.1 berikut :

$$Akurasi = \frac{(TP+TN)}{TP+FP+FN+TN} \times 100\% \quad (3.1)$$

3. Presisi

Presisi merupakan parameter untuk menentukan nilai ketepatan antara informasi yang diminta *user* dengan hasil yang diberikan oleh sistem yang telah dibuat. Presisi akan memberikan hasil dalam bentuk persen dan bagaimana sistem mengklasifikasikan

kelas yang benar terhadap data yang diprediksi benar. Untuk menghitung nilai presisi dapat menggunakan rumus 3.2 berikut:

$$Presisi = \frac{TP}{TP+FP} \quad (3.1)$$

4. Recall

Recall merupakan suatu parameter untuk mengidentifikasi nilai data positif atau *True Positive* dan selanjutnya dilakukan perbandingan dengan total data benar terprediksi positif. Semakin tinggi nilai positif yang terdeteksi maka semakin tinggi nilai *recall*. Untuk menghitung nilai *recall* dapat menggunakan rumus 3.3 berikut :

$$Recall = \frac{TP}{TP+FN} \quad (3.2)$$

5. Specificity

Specificity merupakan suatu parameter untuk mengidentifikasi nilai data *True Negatif* lalu dibandingkan dengan total data benar terprediksi negative. Untuk menghitung nilai *specificity* dapat menggunakan rumus 3.4 berikut:

$$Specificity = \frac{TN}{TN+FP} \quad (3.3)$$

6. F1-Score

F1-Score merupakan nilai rata rata dari presisi dan *recall*. Untuk menghitung nilai *F1-score* dapat menggunakan rumus 3.5 berikut ini:

$$F1 - score = 2 \times \frac{recall \times presisi}{recall + presisi} \times 100\% \quad (3.5)$$

E. Parameter Pengujian Sistem

Parameter pengujian dilakukan untuk mengetahui pengaruh dari *preprocessing* terhadap arsitektur ResNet-50 dan ResNet-101 yang akan digunakan pada pengujian. Pengujian dilakukan pada data masukan citra hasil CLAHE dan citra hasil *Canny Edge Detection*. Pada pengujian ini akan dilakukan perbandingan terhadap hasil *hyperparameter* seperti :

1. *Optimizer* = Adam, Adamax, dan SGD
2. *Learning rate* = 0.1, 0.01, dan 0.001
3. *Batch size* = 32, 64, dan 128
4. *Input size* = 128×128, 224×224, dan 256×256

Epoch yang digunakan 40 dengan menggunakan *early stopping* dan untuk software yang digunakan untuk pelatihan dan pengujian adalah Google Colab.

IV. HASIL DAN PEMBAHASAN

Pada tahapan ini berisikan hasil pengujian sistem dan analisis sistem yang telah dibuat untuk dapat mengklasifikasikan citra kanker serviks dari hasil pemeriksaan IVA dengan menggunakan arsitektur *Deep Residual Network* (Res-Net). Data citra kanker serviks hasil pemeriksaan IVA yang dimana data terbagi menjadi dua kelas yaitu IVA negatif dan IVA positif. Pengujian yang dilakukan adalah membandingkan hasil dari citra masukan hasil CLAHE dan citra masukan hasil *Canny Edge Detection*.

A. Spesifikasi Hardware

Pada pengujian yang akan dilakukan penulis berikut merupakan spesifikasi laptop yang digunakan penulis dapat dilihat pada tabel 4.1 dibawah ini.

TABEL 3
SPESIFIKASI HARDWARE

Processor	Intel(R) Core(TM) i7-10870H CPU @ 2.20GHz 2.21 GHz
RAM	8 GB
Storage	450 GB
Operating system	Windows

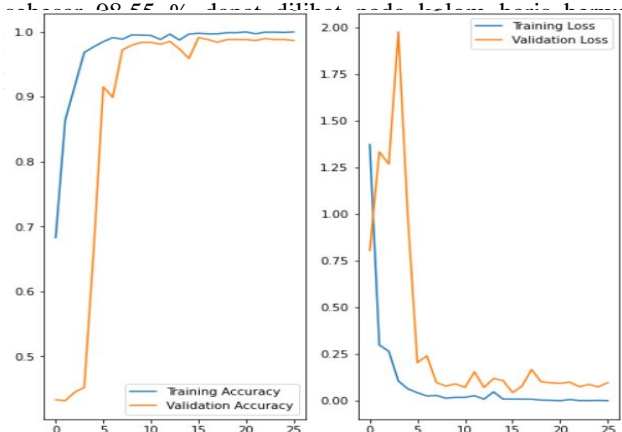
B. Analisis Hasil Pengujian Terbaik

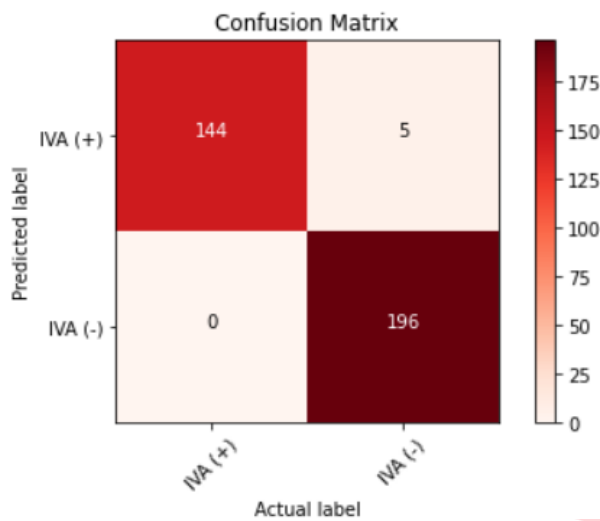
Pada bagian ini akan dilakukan analisis dari hasil pengujian yang telah dilakukan. Setelah dilakukan empat tahapan dari pengujian *optimizer*, *learning rate*, *batch size*, dan *input size* terhadap citra CLAHE dan citra *Canny Edge Detection* dengan menggunakan model arsitektur *Deep Residual Network* (ResNet) yang berbeda yaitu model ResNet-50 dan ResNet-101. Berikut ini adalah hasil pengujian yang telah dilakukan dapat dilihat pada tabel 4.

TABEL 4
HASIL PENGUJIAN

Arsitekt ur	Jenis Citra	Optimiz er	Learnin g rate	Batc h size	Input size	Test acc
ResNet-50	CLAHE	SGD	0,1	32	224×224	95,4 5 %
	Canny Edge Detection	SGD	0,1	32	224×224	98,5 5 %
ResNet-101	CLAHE	SGD	0,1	32	224×224	92,9 0 %
	Canny Edge Detection	SGD	0,1	32	224×224	89,2 8 %

Hasil pengujian terbaik dapat dilihat pada Tabel 4. Hasil pengujian terbaik pada klasifikasi citra kanker serviks hasil pemeriksaan IVA yaitu menggunakan arsitektur ResNet-50 menggunakan citra hasil *preprocessing* Canny Edge Detection dengan *hyperparameter* berupa *optimizer* SGD, *learning rate* dengan nilai 0.1, *batch size* dengan nilai 32, dan *input size* dengan nilai 224×224 dengan nilai akurasi tes





GAMBAR 11
HASIL CONFUSION MATRIX

Pada Gambar 11 merupakan grafik dari pengujian terbaik yang dimana grafik ini merupakan bentuk grafik yang cukup baik. Untuk Gambar 11 merupakan hasil dari *confusion matrix* pada pengujian yang terbaik. Dapat dilihat pada Gambar 11 *confusion matrix* sistem belajar dengan cukup baik dalam melakukan pengklasifikasian. Untuk melakukan analisis hasil parameter performansi yang didapatkan dari model terbaik dari nilai akurasi, presisi, *recall* dan *F1-score* dapat dilihat pada Tabel 5.

TABEL 5
HASIL PARAMETER PERFORMANSI

Kelas	Presisi	Recall	Specificity	F1-score
IVA (+)	100 %	97 %	97 %	98 %
IVA (-)	98 %	100 %	97 %	99 %
Akurasi				99 %

Dari Tabel 5 dapat ditarik kesimpulan bahwa setiap kelas memiliki nilai presisi, *recall*, specificity, dan *F1-Score* dengan akurasi 99%. Dari nilai akurasi yang tinggi dalam penelitian ini menunjukkan performansi dari model yang telah dibuat ini baik serta mampu mengklasifikasi IVA (-) dan IVA (+).

C. Analisis Umum

Penelitian ini telah melakukan pengujian terhadap dua jenis *preprocessing* yaitu citra hasil CLAHE dan citra hasil *Canny Edge Detection*. Dari pengujian terhadap dua jenis *preprocessing* didapatkan hasil bahwa citra hasil *Canny Edge Detection* memiliki tingkat performansi yang tinggi karena pada citra hasil *Canny Edge Detection* sistem mempelajari pola dari lesi putih hasil inspeksi IVA. Dibandingkan dengan citra hasil *preprocessing* CLAHE yang hanya meningkatkan kualitas citra saja.

Pengujian selanjutnya pada penelitian ini adalah dengan membandingkan hasil akurasi yang di dapatkan dari dua

model arsitektur *deep residual network*. Model arsitektur yang digunakan untuk dilakukan perbandingan akurasinya adalah ResNet-50 dan ResNet-101. Masing-masing model ResNet dilakukan pengujian terhadap citra hasil *preprocessing* CLAHE dan *Canny Edge Detection* serta dilakukan pengujian terhadap *hyperparameter* seperti jenis *optimizer*, *learning rate*, *batch size* dan *input size*.

Pada pengujian dua model arsitektur yaitu ResNet-50 dan ResNet-101 didapatkan hasil pengujian terbaik pada model ResNet-50 dengan menggunakan citra masukan hasil *Canny Edge Detection*. Untuk *hyperparameter* yang digunakan *optimizer* SGD, *learning rate* 0.1, *batch size* 32, dan *input size* 224×224. Dari kombinasi antara model ResNet-50 dengan citra masukan hasil *Canny Edge Detection* dan *hyperparameter* yang terbaik didapatkan hasil akurasi mencapai 98,55%. Sedangkan untuk hasil akurasi ResNet-101 dengan menggunakan data masukan yang sama dan *hyperparameter* yang sama didapatkan akurasi 89,28%. Jika dilihat dari tingkat akurasi tes antara ResNet-50 dan ResNet-101 dengan citra masukan yang sama yaitu citra *Canny Edge Detection* nilai akurasi tes mengalami penurunan hal ini terjadi karena citra masukan *Canny Edge Detection* kurang baik digunakan di ResNet-101.

V. KESIMPULAN

A. Kesimpulan

Berdasarkan hasil pengujian pada tugas akhir klasifikasi citra kanker serviks hasil pemeriksaan IVA dengan arsitektur *Deep Residual Network*, didapatkan kesimpulan sebagai berikut:

1. Model arsitektur *Deep Residual Network* dengan jenis ResNet-50 dapat bekerja dengan baik dibandingkan ResNet-101 untuk mengklasifikasi citra kanker serviks hasil pemeriksaan IVA dengan nilai akurasi mencapai 98,55 %.
2. Citra masukan hasil *Canny Edge Detection* yang digunakan pada model arsitektur *Deep Residual Network* dengan jenis ResNet-50 memiliki nilai akurasi yang meningkat dibandingkan dengan citra masukan hasil CLAHE.
3. Jenis *optimizer* SGD (*Stochastic Gradient Descent*) yang digunakan pada model ResNet-50 dapat meningkatkan akurasi dibandingkan dengan *optimizer* Adam dan Adamax.

B. Saran

Berdasarkan hasil dari penelitian ini masih ada beberapa kekurangan yang perlu untuk dilakukan perbaikan pada data selanjutnya, diantaranya adalah:

1. Menggunakan model arsitektur *deep residual network* yang lain seperti ResNet-50V2, ResNet-152 dan masih banyak lagi.
2. Menggunakan dataset yang lebih banyak agar sistem dapat belajar lebih variatif.
3. Menggunakan teknik *preprocessing* yang lain agar akurasi sistem dapat lebih baik lagi.

REFERENSI

- [1] S. Pangribowo, "Beban Kanker di Indonesia," *Pus. Data dan Inf. Kemeterian Kesehat. RI*, pp. 1–16, 2019.
- [2] S. Pustaka and I. Rasjidi, "Epidemiologi Kanker Serviks," *Cancer*, vol. III, no. 3, pp. 103–108, 2009.
- [3] D. N. Agustyawati, H. Fauzi, and A. Pratondo, "Perancangan Aplikasi Deteksi Kanker Serviks Menggunakan Metode Convolutional Neural Network," *eProceedings Eng.*, vol. 8, no. 4, pp. 3908–3924, 2022.
- [4] K. M. A. Adweb, N. Cavus, and B. Sekeroglu, "Cervical Cancer Diagnosis Using Very Deep Networks over Different Activation Functions," *IEEE Access*, vol. 9, pp. 46612–46625, 2021.
- [5] D. H. Nurwijaya, D. Andrijono, and D. H. K. Suheimi, *Cegah dan Deteksi Kanker Serviks*. 2010.
- [6] D. Setiawati, "Human Papilloma Virus Dan Kanker Serviks," *Al-Sihah Public Heal. Sci. J.*, vol. VI, no. 2, pp. 450–451, 2014.
- [7] L. Dewi, E. Supriati, and A. P. Dewi, "Faktor-Faktor yang Berhubungan dengan Perilaku Wanita Usia Subur dalam Deteksi Dini Kanker Serviks dengan Metode Pemeriksaan Inspeksi Visual Asam Asetat (IVA) Di Wilayah Kerja Puskesmas Tanjung Hulu Pontianak Timur Tahun 2014," *J. Proners*, vol. 1, no. 1, pp. 1–10, 2014.
- [8] N. Ylitalo, S. Stuver, and H. O. Adami, "Cervical Cancer," *Textb. Cancer Epidemiol.*, pp. 6–28, 2009.
- [9] A. Basuki, *Metode Numerik dan Algoritma Komputasi*. 2005.
- [10] T. Sutoyo, E. Mulyanto, V. Suhartono, Nurhayati, and Wijanarto, *Teori Pengolahan Citra Digital*, vol. 1, no. 1. 2009.
- [11] C. Danil, "Edge Detection dengan Algoritma Canny," no. 18, pp. 197–203, 2008.
- [12] C. J. Philip, *Introduction to Artificial Intelligence: Third Edition*. 2019.
- [13] R. Nurfiti, "Implementasi Deep Learning Berbasis Tensorflow," *J. Emit.*, vol. 18, no. 01, pp. 22–27, 2018.
- [14] S. Ilahiyah and A. Nilogiri, "Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 3, no. 2, pp. 49–56, 2018.
- [15] J. Wu, "Introduction to Convolutional Neural Networks," *Introd. to Convolutional Neural Networks*, pp. 1–31, 2017.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, *Deep Residual learning of Image recognition*. 2016.
- [17] M. Arpana and C. Sanjay, "Categorical Image Classification Based On Representational Deep Network (RESNET)."
- [18] A. Çınar, M. Yıldırım, and Y. Eroğlu, "Classification of pneumonia cell images using improved ResNet50 model," *Trait. du Signal*, vol. 38, no. 1, pp. 165–173, 2021, doi: 10.18280/TS.380117.
- [19] Faiz Nashrullah, Suryo Adhi Wibowo, and Gelar Budiman, "The Investigation of Epoch Parameters in ResNet-50 Architecture for Pornographic Classification," *J. Comput. Electron. Telecommun.*, vol. 1, no. 1, pp. 1–8, 2020, doi: 10.52435/complete.v1i1.51.
- [20] W. Long, L. Xinyu, and G. Liang, "A transfer convolutional neural network for fault diagnosis based on ResNet-50," 2019.
- [21] X. Zhengguang, S. Kuo, and M. Junying, "Research on ResNet101 Network Chemical Reagent Label Image Classification Based on Transfer Learning," 2020.
- [22] B. Somenath and K. S. Vimal, "Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification."
- [23] Z. Zijun, "Improved Adam Optimizer for Deep Neural Networks," 2018.
- [24] L. Ricardo, E. Y. Samira, F. Allyx, and L. Pablo, "Comparison between Adam, AdaMax and Adam W optimizers to implement a Weather Forecast based on Neural Networks for the Andean city of Quito."
- [25] N. S. Keskar and R. Socher, "Improving Generalization Performance by Switching from Adam to SGD," no. 1, 2017.
- [26] O. A. Nii, *Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance.* .
- [27] J. Brownlee, "What is the Difference Between a Batch and an Epoch in a Neural Network?," *Mach. Learn. Mastery*, no. July, pp. 3–4, 2018.
- [28] S. S. Gauresh and A. Dessai, "Classification of Cervical MR Images using," no. 6, pp. 2–5, 2019.