

BAB II
TINJAUAN PUSTAKA

2.1 Studi Literatur

Penelitian mengenai klasifikasi telah dilakukan oleh berbagai peneliti sebelumnya. Penelitian-penelitian tersebut menjadi acuan penting dalam menentukan langkah-langkah sistematis dalam penyusunan penelitian ini. Beberapa studi sebelumnya telah mengkaji klasifikasi kanker serviks dengan menggunakan berbagai metode yang berbeda. Pada **Tabel 2.1** menjelaskan penelitian-penelitian tersebut.

Tabel 2. 1 Rincian Penelitian Terdahulu

No	Penulis	Judul	Dataset	Metode	Hasil
1	Za'imatun Niswati, Rahayuning Hardatin, Meia Noer Muslimah, Siti Nur Hasanah	Perbandingan Arsitektur ResNet50 dan ResNet 101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear	Data yang digunakan untuk pelatihan model merupakan data sel SIPaKMe D http://www.cs.uoi.gr/~marina/sipakmed.html	Metode CNN dengan model arsitektur ResNet50 dan Resnet101	91% untuk ResNet50 dan 89% untuk ResNet101.
2	Jalu Nusantoro, Faldo Fajri Afrinanto, Wana Salma Labibah, Zamah Sari, Yufis Azhar	Detection of Covid-19 on X-Ray Image of Human Chest Using CNN	VGG-16, VGG-19 dan ResNet-50	Covid-19 (COVID-19 and Normal) Radiographic Database	hasil CNN skenario 1 akurasi sebesar 95%, pada skenario 2

		and Transfer Learning			VGG-16 akurasi sebesar 93%, skenario 3 VGG-19 akurasi sebesar 90% dan ResNet-50 dengan akurasi sebesar 80%
3	Andrian, Steele, Edward Suwandhy Salim, , Hartato Bindan, Endy Pranoto, Abdi Dharma	Analisa Metode Random Forest Tree dan K-Nearest Neighbor dalam Mendeteksi Kanker Serviks	Dataset dari direkam pada rumah sakit Hospital Universita rio de Caracas di Caracas, Venezuela	Random forest tree dan K-Neast Neighbor	88,7% untuk Random Forest dan 90,6% untuk KNN.

Berdasarkan pada tabel 2.1 diatas terdapat beberapa penelitian terdahulu yang menggunakan dataset, model, dan kasus yang serupa yang dapat mendukung penelitian ini. Pada penelitian 1 melakukan klasifikasi citra dengan menggunakan dataset yang sama terkait klasifikasi kanker serviks melalui citra

pap smear. Pada penelitian [8] dilakukan penelitian menggunakan metode CNN dengan arsitektur ResNet50 dan Resnet101 dengan akurasi masing masing 91% pada ResNet50 dan 89% pada Resnet101. Berdasarkan hasilnya, arsitektur ResNet50 direkomendasikan untuk mengklasifikasikan gambar Pap smear karena kinerjanya yang unggul. Akurasi ResNet101 yang lebih rendah menunjukkan bahwa model yang lebih kompleks tidak selalu menjamin hasil yang lebih baik, terutama dengan data pelatihan yang terbatas. Meskipun ResNet101 adalah arsitektur yang lebih kompleks, penelitian ini menemukan bahwa kinerjanya tidak mengungguli ResNet50. Hal ini menimbulkan pertanyaan tentang efektivitas penggunaan jaringan yang lebih dalam ketika data pelatihan terbatas. Kompleksitas ResNet101 mungkin tidak dapat dibenarkan dalam konteks ini, sehingga menunjukkan bahwa model yang lebih sederhana bisa lebih efektif untuk tugas serupa.

Pada penelitian 2 dilakukan klasifikasi dengan model VGG-19, VGG-19 dan ResNet-50 dengan judul “Detection of Covid-19 on X-Ray Image of Human Chest Using CNN and Transfer Learning” dengan hasil CNN skenario 1 akurasi sebesar 95%, pada skenario 2 VGG-16 akurasi sebesar 93%, skenario 3 VGG-19 akurasi sebesar 90% dan ResNet-50 dengan akurasi sebesar 80%[13]. Pada penelitian tersebut dapat disimpulkan bahwa model VGG-19 lebih unggul daripada Resnet-50.

Pada penelitian 3 dilakukan klasifikasi dengan kasus sama yang menggunakan dataset pada rumah sakit Hospital Universitario de Caracas di Caracas, Venezuela. Pada penelitian ini menggunakan metode Random forest tree dan K-Neast Neighbor dengan akurasi 88,7% untuk Random Forest dan 90,6% untuk KNN [18].

Dengan demikian, berdasarkan penjelasan di atas, penelitian ini bertujuan untuk mencapai hasil optimal dalam mengenali kanker serviks menggunakan metode CNN dengan menggunakan model VGG-19.

2.2 Kanker Serviks

Kanker serviks terjadi ketika pembelahan sel tidak terkendali yang menyerang organ intim wanita, tepatnya di daerah leher rahim yang merupakan bagian paling bawah dari uterus. Kanker serviks merupakan penyebab kanker

terbesar kedua pada wanita di seluruh dunia. Menurut data dari WHO (World Health Organization), setiap tahun 500.000 wanita didiagnosis menderita kanker serviks dan 300.000 di antaranya meninggal dunia. Angka kematian akibat kanker serviks terus meningkat setiap tahun [2]. Tingginya angka penderita kanker serviks dapat disebabkan oleh kurangnya informasi dan pemahaman masyarakat mengenai gejala kanker serviks yang dapat muncul sedari dini, sehingga meningkatkan risiko kematian akibat penyakit ini[3].

2.3 Pap Smear

Pap smear adalah pemeriksaan mikroskopis pada sel-sel yang diambil dari serviks (leher Rahim). Tes ini berguna untuk mendeteksi perubahan pada sel serviks yang disebabkan oleh infeksi virus, seperti human papilloma virus (HPV) [19]. Meskipun tes ini penting untuk pencegahan kanker serviks, terdapat beberapa kelemahan yang menjadi perhatian. Sensitivitas yang rendah dari tes ini dapat disebabkan oleh beberapa faktor, termasuk waktu yang dibutuhkan oleh tenaga medis untuk mendiagnosis sel serviks, terutama pada tahap awal keterlibatan sel epitel (Grade 1), visibilitas gambar sampel yang kurang optimal, serta risiko kesalahan dalam analisis mikroskopis meskipun berbagai tindakan pencegahan telah diterapkan untuk meminimalkan ketidakakuratan. Selain itu, peningkatan kesadaran akan infeksi Human Papilloma Virus (HPV), yang merupakan penyebab utama kanker serviks, mendorong pengembangan metode baru untuk pencegahan dan pengobatan penyakit ini [15].

2.4 Augmentasi Data

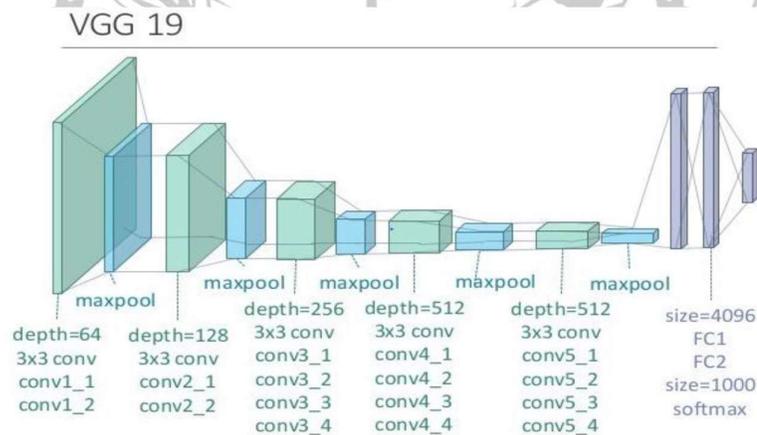
Augmentasi data merupakan teknik yang sering digunakan untuk mengatasi overfitting dalam pembelajaran mesin. Teknik ini akan memperluas data asli dengan menciptakan data baru melalui berbagai transformasi, Dengan augmentasi data, model dapat meningkatkan generalisasinya, yang berarti mampu mengaplikasikan pengetahuannya pada yang belum pernah dilihat sebelumnya. Variasi yang diperkenalkan oleh augmentasi data memungkinkan model untuk belajar dari berbagai macam data, sehingga lebih tahan terhadap berbagai variasi yg ditemukan ketika data di uji [11].

2.5 Transfer Learning

Transfer learning adalah teknik deep learning yang memanfaatkan model yang telah dilatih pada satu masalah untuk diterapkan pada masalah lain. Transfer learning memungkinkan pelatihan model deep learning dengan jumlah sampel yang lebih sedikit namun tetap mencapai akurasi yang tinggi [17]. Tujuan dari penggunaan transfer learning adalah untuk membuat pelatihan dengan dataset yang berbeda menjadi lebih efisien dan efektif. Hasil dari pelatihan ini adalah feature map yang berisi fitur-fitur terbaik dari setiap kelas[20].

2.6 VGG – 19

VGG-19 (*Visual Geometry Group-19*) merupakan versi terbaru dari arsitektur CNN VGG-16. Arsitektur ini terdiri dari 16 lapisan *convolutional layer* dengan aktivasi ReLU dan 3 lapisan *fully connected layer* juga dengan aktivasi ReLU. Setiap lapisan *convolutional layer* terakhir dilengkapi dengan lapisan max pooling untuk mengurangi dimensi spasial dari lapisan *convolutional layer* sebelumnya. Ukuran input dari arsitektur ini adalah 224 x 224 piksel, dan fungsi aktivasi softmax digunakan pada lapisan output untuk menampilkan hasil klasifikasi [10]. Berikut ini merupakan gambar arsitektur VGG-19 yang digunakan dalam penelitian ini. Gambar 2.1 merupakan arsitektur model VGG-19.



Gambar 2. 1 Arsitektur Model VGG-19 [19]

2.7 Uji Klasifikasi

Pada tahap ini uji klasifikasi dilakukan untuk mengevaluasi serta mengukur kinerja model yang didapatkan setelah melakukan pengujian dengan model yang cocok. Pada tahap ini uji klasifikasi dilakukan menggunakan Confusion matrix. Confusion matrix digunakan untuk mengukur akurasi, presisi, recall, F1-score, dan metrik evaluasi guna menilai sejauh mana model mampu memberikan prediksi yang tepat dan dapat diandalkan dalam mengklasifikasi kelas. Berikut adalah rumus-rumus untuk mencari hasil dengan metode *confusion matrix*. Penjelasan mengenai uji klasifikasi dapat dilihat pada Tabel 2.2.

Tabel 2. 2 Pengujian Klasifikasi

		Actual Class	
		Positive (P)	Negative (N)
Predicted Class	Positive (P)	True Positive (P)	False Positive (P)
	Negative (N)	False Negative (N)	True Negative (N)

Dalam pengujian klasifikasi, terdapat rumus untuk menghitung kinerja model diantaranya adalah precision, accuracy dan recall.

1. Recall, secara sistematis recall dihitung dengan membagi jumlah True Positive (TP) oleh jumlah keseluruhan instance yang seharusnya positif, yang dapat dijelaskan sebagai berikut :

$$\text{Recal} = \frac{TP}{TP+FN} \quad (1)$$

Dengan true positive adalah jumlah kasus positif yang berhasil diidentifikasi dengan benar oleh model, dan False Negative adalah jumlah kasus positif yang tidak terdeteksi oleh model.

2. Accuracy, merupakan salah satu metrik evaluasi yang mengukur sejauh mana model klasifikasi memberikan prediksi yang benar secara keseluruhan. Secara sistematis, accuracy dihitung dengan membagi jumlah

prediksi yang benar (True Positive + True Negative) oleh jumlah total instance atau sampel dalam dataset.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+F} \quad (2)$$

3. Precision, adalah metrik evaluasi dalam konteks klasifikasi yang mengatur sejauh mana prediksi positif yang dibuat oleh model adalah benar. Precision dihitung dengan membagi jumlah True Positive (TP) dengan jumlah keseluruhan prediksi positif yang dibuat oleh model, baik yang benar (TP) maupun yang salah (False Positive /FP)

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

4. F1-Score, adalah metrik evaluasi yang menggabungkan informasi tentang presisi (precision) dan recall. Metrik ini berguna untuk keseimbangan antara precision dan recall. F1-Score dihitung dengan menggunakan rumus berikut :

$$\text{F1-Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

F1-score memberikan bobot seimbang antara presisi dan recall, dan nilainya berkisar antara 0 hingga 1. Sebuah model yang memiliki F1-score tinggi menunjukkan bahwa model tersebut memiliki keseimbangan yang baik antara kemampuan untuk mengidentifikasi instance positif (recall) dan kecenderungan untuk membuat prediksi positif yang benar (precision).