

Deteksi Lesi Pra-Kanker Serviks Pada Citra Kolposkopi Menggunakan Convolutional Neural Network dengan Arsitektur YOLOv7

Fatihani Nurqolbiah¹, Siti Nurmaini^{2,*}, Tommy Saputra³

¹Magister Ilmu Komputer, Faculty of Computer Science, Universitas Sriwijaya, Palembang, Indonesia

²Intelligent System Research Group, Faculty of Computer Science, Universitas Sriwijaya, Palembang, Indonesia

³USS Artificial Intelligence Research Group, Faculty of Computer Science, Universitas Sumatera Selatan, Palembang, Indonesia

Email: ¹09012682226008@students.ilkom.unsri.ac.id, ^{2,*}siti_nurmaini@unsri.ac.id, ³tommysaputra@uss.ac.id

Email Penulis Korespondensi: siti_nurmaini@unsri.ac.id

Submitted: 14/12/2023; Accepted: 26/12/2023; Published: 29/12/2023

Abstrak—Deteksi lesi prakanker serviks sangat penting dalam diagnosa dan analisis pada citra medis. Karena pengamatan kelemahan pengamatan secara visual, sehingga dibutuhkan deteksi berbasis komputer. Dalam penelitian ini diusulkan model deteksi lesi prakanker serviks menggunakan Convolutional Neural Network dengan arsitektur YOLOv7 yang dapat mendeteksi lesi prakanker serviks secara akurat. Data yang digunakan berupa data citra kolposkopi sebanyak 913 data dari 200 kasus. Dataset yang digunakan dibagi menjadi data pelatihan dan pengujian. Penelitian menghasilkan model deteksi untuk lesi prakanker serviks. Model mencapai mAP 91,9%, presicion 87,7%, recall 96%, dan F1-score 93%. Penelitian menunjukkan kinerja YOLOv7 menunjukkan kemampuan model untuk mendeteksi lesi prakanker secara akurat.

Kata Kunci: Deteksi; Pra-Kanker Serviks; Kolposkopi; Convolutional Neural Network; YOLOv7

Abstract—Pre-cancerous cervical lesions detection is crucial in the diagnosis and analysis of medical images. Because visual observations are weak, computer-based detection is needed. This research proposes a pre-cancerous cervical lesion detection model using a Convolutional Neural Network with the YOLOv7 architecture, capable of accurately detecting these lesions. The data used was 913 colposcopy image data from 200 cases. The dataset is divided into training and testing data, resulting in a detection model for pre-cancerous cervical lesions. The model achieves an mAP of 91.9%, precision of 87.7%, recall of 96%, and an F1-score of 93%. The study demonstrates that the performance of YOLOv7 indicates the model's ability to accurately detect pre-cancerous lesions in the cervix.

Keywords: Detection; Cervical Pre-Cancer; Colposcopy; Convolutional Neural Network; YOLOv7

1. PENDAHULUAN

Kecerdasan Buatan (AI) adalah bagian dari ilmu komputer yang berkonsentrasi pada pengembangan perangkat lunak dan perangkat keras yang dapat meniru kemampuan berpikir manusia [1]. Penerapan AI mencakup penyelesaian masalah dalam berbagai konteks seperti aplikasi bisnis [2], robotika, bahasa alami, matematika, game, pemrosesan informasi, diagnosis medis, teknik, analisis keuangan, analisis sains, dan penalaran.

Salah satu cabang AI yang sering digunakan untuk mengatasi berbagai masalah adalah Machine Learning (ML). ML memudahkan eksplorasi data dengan berbagai teknik tertentu [3]. Algoritma ML juga banyak digunakan untuk memecahkan berbagai masalah, seperti diagnosis objek seperti mendeteksi penyakit, dengan akurasi dan kecepatan lebih tinggi dari pada manusia [4].

Deteksi Objek (Object Detection) merupakan salah satu metode dalam pengolahan citra (image processing) dan penglihatan komputer, objek deteksi atau deteksi objek bertujuan untuk mengenali dan menemukan lokasi objek tertentu pada gambar atau video [5]. Algoritma deep learning seperti CNN biasanya digunakan dalam teknik deteksi objek.. Algoritma CNN banyak digunakan oleh para peneliti dalam menganalisis suatu objek, sebab algoritma ini telah diklaim sebagai model terbaik dalam menyelesaikan permasalahan pengenalan objek [6].

You Only Look Once (YOLO) adalah model deep learning yang digunakan untuk mendeteksi objek. Algoritma ini dirancang untuk deteksi objek secara real-time. YOLO menggunakan klasifikator atau lokasi yang dapat digunakan kembali untuk mendeteksi [7]. Objek dapat diidentifikasi pada gambar dengan menerapkan model dengan variasi lokasi dan skala. Area pada gambar yang menerima skor tertinggi dianggap sebagai objek yang terdeteksi.

Lesi pra-kanker serviks memerlukan waktu hampir satu dekade untuk berubah menjadi kanker, dan deteksi dini menjadi kunci penyembuhan [8]. Kolposkopi, sebuah teknik deteksi dini kanker serviks, menggunakan alat untuk melihat kondisi leher rahim yang tidak normal untuk analisis pengamatan visual. Karena kelemahan pengamatan visual, hasil yang dihasilkan menjadi tidak akurat, sehingga diperlukan suatu sistem deteksi otomatis berbasis komputer untuk mengurangi kemungkinan kesalahan pada. Faktor keakuratan sistem pengolahan citra bergantung pada analisis citra pap smear. Analisis citra mengarah pada cara mengetahui tingkat keganasan sel abnormal yang dapat diwakili oleh fitur yang dihitung dari nukleus dan sitoplasma yang tersegmentasi, misalnya, rasio nukleus-sitoplasma atau fitur tekstur yang terkait dengan penyimpangan pola kromatin [9]. Kolposkopi adalah tes diagnostik yang digunakan untuk mengevaluasi displasia vagina, vulva, dan serviks [10]. Deteksi dini kanker serviks dapat dilakukan dengan tes kolposkopi. Kolposkopi termasuk penilaian visual dari sistem saluran genital bagian bawah (serviks, vulva dan vagina), terutama untuk penampilan metaplastik epitel, terdiri dari zona transformasi pada serviks [11].

Karena kelemahan pengamatan visual, hasil yang dihasilkan menjadi tidak akurat, sehingga diperlukan suatu sistem deteksi otomatis berbasis komputer untuk mengurangi kemungkinan kesalahan pada. Faktor keakuratan sistem pengolahan citra bergantung pada analisis citra pap smear. Analisis citra mengarah pada cara mengetahui tingkat keganasan sel abnormal yang dapat diwakili oleh fitur yang dihitung dari nukleus dan sitoplasma yang tersegmentasi, misalnya, rasio nukleus-sitoplasma atau fitur tekstur yang terkait dengan penyimpangan pola kromatin[12]. Deep Learning memiliki keuntungan dalam membangun arsitektur yang mendalam untuk mempelajari informasi yang lebih abstrak. Sifat terpenting dari metode pembelajaran mendalam adalah bahwa metode ini dapat secara otomatis mempelajari representasi fitur sehingga menghindari banyak rekayasa yang memakan waktu [13]

Penelitian mengenai kanker serviks dalam beberapa tahun terakhir banyak berkembang. Namun, penelitian banyak menggunakan gambar sel (pap smear) [14][15], dan test IVA [16][17] namun sangat sedikit yang menggunakan citra kolposkopi.

Seperti yang dilakukan oleh [18] [19] [20] dengan metode machine learning mengusulkan model jaringan deteksi lesi serviks berdasarkan jaringan syaraf konvolusi yang dalam (CNN) dapat mengolah data citra medis dengan baik. Namun, setiap penelitian masih memiliki kekurangan, yaitu membutuhkan kemampuan filter convolutional layer untuk meningkatkan tepi daerah acetowhite dan menambahkan tekstur di dalam daerah acetowhite untuk meningkatkan akurasi kinerja model. Maka dari itu pada penelitian ini akan dilakukan mengenai deteksi Lesi Pra-kanker Serviks pada citra kolposkopi menggunakan metode CNN dengan arsitektur YOLOv7.

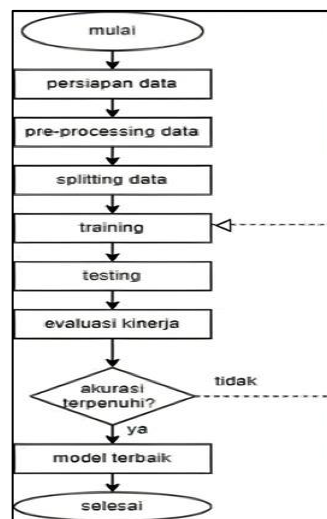
2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan yang dilakukan digambarkan dalam kerangka kerja penelitian. Secara ringkas metodologi dalam penyusunan penelitian ini terdiri dari persiapan data, pra-pengolahan data, pembangunan model CNN, analisis hasil, evaluasi hasil serta penarikan kesimpulan. Pada proses pra-pengolahan data dilakukan agar dapat dilakukan analisis dengan cara memproses pra-pengolahan data sebelum dilakukan ke tahap selanjutnya. Kemudian keseluruhan data di Splitting menjadi 80% Training dan 20% testing dan dilakukan proses training menggunakan arsitektur YOLO. Adapun tahapan penyelesaian penelitian Tesis ini adalah bagaimana sistem menyelesaikan masalah deteksi antara kelas normal dan abnormal yang terjadi pada kanker serviks.

2.2 Kerangka Kerja

Sistem deteksi kanker serviks yang dilakukan dalam penelitian ini diuraikan dalam beberapa tahapan proses. Tahapan-tahapan tersebut sesuai dengan kerangka kerja yang dirancang, sehingga proses yang dilalui terstruktur dan penyusunan tesis ini pun sesuai mengikuti alur kerja. Proses tahapan yang dilakukan dalam penelitian ini digambarkan melalui gambar 1, terdiri dari proses persiapan data, pra-pengolahan data, pengklasifikasian citra pap smear, evaluasi hasil, analisis hasil dan terakhir penarikan kesimpulan.



Gambar 1. Kerangka Kerja Penelitian

1. Persiapan Data

Pada tahap ini, akan dibahas mengenai persiapan data yang akan digunakan oleh penulis. Dataset yang akan digunakan berasal IARS (International Agency for Research for Cancer) Cervical Cancer Image Bank dan terdiri dari hasil test kolposkopi dengan total gambar sebanyak 913 dari 200 kasus. Data ini dikelompokkan menjadi dua kelas yaitu normal dan abnormal. Kelas normal berjumlah 157 data dan kelas abnormal sebanyak

756 data. Contoh data citra kolposkopi yang digunakan pada penelitian ini dapat dilihat pada gambar 4 yang menunjukkan citra kolposkopi normal (gambar a) dan citra kolposkopi abnormal (gambar b). Berdasarkan gambar ini, perbedaan yang dapat dilihat adalah adanya perubahan warna dan tekstur pada wilayah serviks pada citra kolposkopi



Gambar 2. Contoh Gambar Citra Kolposkopi (a) citra kolposkopi normal (b) citra kolposkopi abnormal

Pada gambar diatas kondisi normal, gambar kolposkopi akan menunjukkan lesi dengan warna merah muda hingga merah tua, pola pembuluh darah yang teratur, dan epitel yang rata. Saat menggunakan cuka, jaringan normal mungkin menunjukkan perubahan warna sementara. Sebaliknya, pada gambar citra kolposkopi abnormal, dapat terlihat lesi putih (asap) atau berawan setelah pemaparan cuka, pembuluh darah yang tidak teratur, dan perubahan warna atau pola epitel yang mencolok. Batas antara jaringan abnormal dan normal mungkin kabur, dan ada kemungkinan adanya area dengan warna yang berbeda atau pertumbuhan tidak teratur. Perlu dicatat bahwa interpretasi gambar kolposkopi membutuhkan keahlian klinis yang kuat, dan diagnosis akhir sering memerlukan tindakan lanjutan, seperti biopsi, untuk konfirmasi yang lebih pasti. Hanya melalui evaluasi oleh profesional kesehatan yang berpengalaman, kita dapat memahami secara mendalam hasil kolposkopi dan mengarahkan langkah-langkah pengelolaan yang sesuai.

2. Preprocessing

Proses pra-pengolahan data ini dapat membantu proses latih pata model yang dibangun pada penelitian ini sehingga diharapkan mendapatkan output yang baik dalam menganalisis data sesuai dengan kebutuhan yang diinginkan. Pada pengolahan gambar, tahap awal yang dilakukan adalah pre-processing data. Tujuannya adalah untuk mengubah bentuk data gambar asli agar lebih mudah diolah oleh algoritma pengolahan gambar. Dengan melakukan pre-processing data pada pengolahan gambar, gambar akan lebih mudah dan akurat dalam dianalisis, sehingga memberikan informasi yang lebih baik bagi pengguna. Tahapan dari proses pra-pengolahan data pada penelitian ini dapat dilihat pada gambar 5 berikut.



Gambar 3. Tahapan pra-pengolahan Data

a. Resize Gambar


Metode yang diterapkan untuk mengubah ukuran gambar tanpa menghapus sebagian kecil dan mengekstrak elemen penting dari gambar yang sedang diproses disebut dengan resize. Perubahan ukuran gambar merupakan proses mengubah ukuran dimensi lebar dan tinggi pada gambar. Pada tahap ini mengubah ukuran semua gambar yang sebelumnya berbeda menjadi ukuran yang sama, yaitu 800 × 600 piksel. Ukuran gambar ini dipilih karena sesuai dengan spesifikasi yang dibutuhkan pada tahap selanjutnya, yaitu memberikan label pada setiap gambar. Hal ini dilakukan sebagai salah satu contoh untuk memberikan hasil kinerja yang baik pada penelitian ini.

b. Anotasi Label

Annotation Label adalah sebuah teknik pemberian label pada data gambar struktur jantung. Pada tahapan ini melakukan proses penglabelan daerah serviks citra kolposkopi pada kelas normal dan abnormal menggunakan data yang telah dilah sebelumnya. Untuk data normal kelasnya satu digunakan adalah Columnar dan data abnormal terdapat dua kelas yaitu Columnar dan Lesi. Proses penambahan label pada gambar ini dilakukan secara manual dengan menggunakan bantuan library python labelme. Label ini akan digunakan sebagai inputan pada saat tahap pelatihan dan pengujian pada proses pengolahan gambar. Hasil yang didapatkan pada proses annotation label ini berupa label dengan format (json). Berikut merupakan proses annotation label yang dilakukan dapat dilihat pada gambar 6 merepresentasikan proses annotation label pada kelas normal dan pada gambar 7 merepresentasikan proses annotation label abnormal dibawah ini.



Gambar 4. Annotation label normal



Gambar 5. Annotation label abnormal

c. Convert data

Dalam tahap ini file yang awalnya memiliki label dengan format coco (Json) akan di convert kedalam bentuk format text (txt). Format data YOLO yang asli digunakan dalam bentuk file teks atau txt, sehingga data harus diubah atau di- convert menjadi file txt agar dapat dibaca dan diproses oleh algoritma pelatihan YOLO. Selain itu, file txt juga lebih mudah untuk dimanipulasi dan diakses oleh program-program pelatihan YOLO. Dalam file txt tersebut akan terdapat informasi mengenai letak objek dalam gambar dan label objek tersebut. Sehingga, format file txt sangat penting dalam proses pelatihan model deteksi objek menggunakan algoritma YOLO. Format txt pada YOLO terdiri dari beberapa baris, di mana setiap baris merepresentasikan sebuah objek yang terdeteksi pada gambar.

3. Spliting Data

Dalam tahap ini, gambar hasil label yang sudah diberikan akan dipecah menjadi tiga folder yang terdiri dari data train, data testing dan data unseen. Pembagian data training dan data testing tersebut dilakukan dengan ukuran yang telah ditentukan, yaitu masing-masing 80% dan 20%. Sebaran dataset yang digunakan pada proses training dapat dilihat pada Tabel 1.

Tabel 1. Dataset

Citra Kolposkopi	Data Pelatihan	Data Pengujian
Normal	105	27
Abnormal	545	136
Total	650	163

Dari tabel 1 diatas data training sebanyak 650 data yang terdiri dari 105 data dari kelas normal dan 545 data dari kelas abnormal. Sebaran dataset yang digunakan pada proses testing dapat dilihat pada tabel 1. Sedangkan untuk data berjumlah 163 data yang terdiri dari 27 data dari kelas normal dan 136 data dari kelas abnormal.

4. Object Detection YOLO

Pada deteksi objek YOLO, gambar input dibagi menjadi grid cell yang merupakan bagian dari gambar yang digunakan untuk memprediksi kotak pembatas (bounding box) yang berisi lokasi kemungkinan objek. Grid cell bertanggung jawab untuk mendeteksi objek pada area yang terdapat pada grid cell tersebut. Kemudian, untuk setiap grid cell, model akan menghasilkan beberapa kotak pembatas yang disebut dengan anchor box, yang digunakan untuk menandai kemungkinan lokasi objek. Selanjutnya, model akan memprediksi kelas objek yang terdapat dalam setiap anchor box beserta dengan koordinat dan nilai confidence score dari objek tersebut. Output dari proses deteksi objek adalah kotak pembatas dari objek yang terdeteksi beserta dengan label objek dan nilai confidence score.

a. Backbone Structure

Backbone pada deep learning adalah arsitektur jaringan yang terdiri dari beberapa lapisan konvolusi dan penggabungan fitur (feature merging) yang bertujuan untuk mengekstrak informasi yang relevan dari input dan menghasilkan representasi yang semantik dari input tersebut. Representasi semantik ini kemudian digunakan untuk melakukan tugas tertentu seperti klasifikasi, segmentasi, atau deteksi objek. Backbone sering digunakan dalam deep learning untuk memproses input berupa data gambar atau video, namun dapat juga digunakan untuk memproses data lain seperti teks atau suara. Arsitektur backbone yang baik harus mampu mengoptimalkan keseimbangan antara akurasi dan kecepatan proses, serta dapat diadaptasi untuk berbagai jenis tugas pengolahan data.

Backbone pada YOLO (You Only Look Once) bertanggung jawab untuk mengekstrak fitur dari gambar dan menghasilkan representasi semantik dari gambar yang akan digunakan untuk melakukan deteksi objek. Representasi semantik ini biasanya berupa matriks atau tensor yang merepresentasikan fitur-fitur penting dari gambar yang berkaitan dengan objek. Dalam YOLO, proses deteksi objek dilakukan pada setiap grid cell pada gambar. Backbone akan mengekstrak fitur- fitur dari seluruh gambar, kemudian hasil ekstraksi fitur tersebut akan dibagi-bagi untuk setiap grid cell. Hal ini memungkinkan YOLO untuk mengidentifikasi objek pada setiap grid cell secara independen, sehingga proses deteksi objek dapat dilakukan secara paralel dan lebih efisien.

Pada penelitian ini akan menggunakan YOLOv7 yang mana menggunakan backbone berupa CSPDarknet-53. CSPDarknet-53 adalah arsitektur model CNN (Convolutional Neural Network) yang digunakan sebagai bagian dari model deteksi objek YOLO (You Only Look Once). CSPDarknet53 adalah evolusi dari arsitektur Darknet-53 yang digunakan pada Yolov3. Arsitektur ini terdiri dari 53 lapisan konvolusi (convolutional layer) yang saling terhubung dan diorganisir dalam struktur residual block yang disebut Cross Stage Partial (CSP) block. Fitur ini kemudian akan diolah lebih lanjut pada bagian Head network untuk memprediksi bounding box dan kelas objek yang ada pada gambar. CSPDarknet53 mengintegrasikan konsep partial channel connection yang membuatnya lebih efisien dalam memproses informasi pada setiap blok dan menghasilkan akurasi yang lebih baik dalam deteksi objek.

b. Proses Training

Proses training pada penelitian ini akan melatih algoritma CNN dengan menggunakan Arsitektur YOLO pada dataset yang sudah dipersiapkan. Data yang digunakan merupakan data yang telah selesai melalui tahap Pre-Processing data sebelum masuk ke tahap training. Penerapan tuning pada model ini berfokus pada hyperparameter dan model dari YOLO yang digunakan. Tuning dilakukan bertujuan untuk meningkatkan performa dari model yang dibuat berdasarkan parameter-parameter yang di uji coba menggunakan data yang sudah diolah. Pada penelitian kali ini, data akan di uji menggunakan model dan YOLOv7 dengan backbone yang terdapat pada tiap pre-trained model YOLO yang digunakan.

c. Proses Validasi dan Evaluasi

Setelah melakukan penelitian terhadap pembuatan Model Deep Learning, diperlukan tahap validasi dan evaluasi untuk mengetahui seberapa bagus performa Model Deep Learning yang sudah dibuat. Evaluasi dalam object detection adalah proses untuk mengukur kinerja model deteksi objek dalam mengenali dan menentukan lokasi objek pada suatu gambar. Ada beberapa metrik evaluasi yang digunakan dalam object detection seperti mAP, F1 score, Precision, Recall dan Confusion Matrix digunakan pada YOLO object detection untuk mengukur performa dan keakuratan model. Evaluasi digunakan untuk mengukur kinerja model deteksi objek pada berbagai dataset. Kinerja model yang baik pada dataset yang digunakan menunjukkan bahwa model tersebut dapat digunakan dengan baik pada kasus-kasus praktis di dunia nyata.

a) Mean Average Precision

Mean Average Precision (mAP) adalah ukuran evaluasi yang menghitung rata-rata dari nilai AP pada seluruh kelas objek yang ada. mAP memberikan gambaran keseluruhan tentang kinerja model deteksi objek pada berbagai kelas objek. mAP menghitung rata-rata precision pada berbagai tingkat recall. Presisi mengukur seberapa akurat model dalam mengenali objek, sedangkan recall mengukur seberapa banyak objek yang dapat dikenali oleh model. mAP digunakan untuk mengukur akurasi secara keseluruhan pada berbagai tingkat threshold deteksi. Adapun rumus untuk menghitung mAP menggunakan persamaan sebagai berikut:

$$mAP = \frac{(AP_1 + AP_2 + \dots + AP_n)}{n} \tag{1}$$

Keterangan:

N = jumlah total kelas

AP = Average Precision pada setiap kelas

mAP merupakan metrik evaluasi yang umum digunakan dalam object detection untuk mengukur kinerja model. mAP dihitung berdasarkan nilai AP dari masing-masing kelas objek. AP dihitung dengan memplot precision-recall curve dari hasil prediksi model dan menghitung luas area di bawah kurva tersebut. Precision-recall curve menunjukkan trade-off antara precision dan recall pada berbagai nilai threshold untuk mendeteksi objek. Lalu mAP dihitung dengan mengambil rata-rata dari AP untuk semua kelas objek yang ada pada dataset. Oleh karena itu, semakin besar nilai mAP, semakin baik kinerja model dalam mendeteksi objek pada dataset yang diberikan.

b) F1 Score

F1 Score adalah salah satu metrik evaluasi dalam machine learning yang digunakan untuk mengukur seberapa baik model dalam mengkombinasikan precision dan recall. F1 Score mencoba untuk mencari keseimbangan antara precision dan recall, sehingga dapat memberikan gambaran keseluruhan tentang kinerja model pada dataset yang digunakan. F1 Score dihitung dari harmonic mean antara precision dan recall. Rumus untuk menghitung F1 Score adalah sebagai berikut:

$$F1\ Score = \frac{2 \times (\text{precision} \times \text{recall})}{(\text{precision} + \text{recall})} \tag{2}$$

F1 Score memiliki rentang nilai antara 0 hingga 1, dimana nilai 1 menunjukkan kinerja model yang sempurna dan nilai 0 menunjukkan kinerja model yang sangat buruk. F1 Score sering digunakan dalam kasus-kasus di mana kelas positif dan negatif pada dataset tidak seimbang (imbalanced). Dalam kasus seperti ini, F1 Score dapat memberikan gambaran yang lebih baik tentang kinerja model daripada accuracy karena accuracy tidak dapat menangani ketidakseimbangan kelas pada dataset.

c) Precision

Precision adalah salah satu metrik evaluasi dalam machine learning yang digunakan untuk mengukur seberapa akurat model dalam mengklasifikasikan data positif. Precision mengukur rasio antara jumlah prediksi benar positif (TP) dengan jumlah prediksi positif yang dilakukan oleh model (True Positive + False Positive). Dalam kata lain, precision mengukur persentase dari data yang diklasifikasikan sebagai positif oleh model yang benar-benar positif. Precision sangat penting dalam tugas-tugas di mana klasifikasi positif sangat penting, seperti dalam diagnosis medis. Precision dapat dihitung dengan menggunakan rumus berikut:

$$Precision = \frac{TP}{TP + FP} \tag{3}$$

Dimana TP adalah jumlah prediksi benar positif (True Positive) dan FP adalah jumlah prediksi salah positif (False Positive).

d) Recall

Recall adalah salah satu metrik evaluasi dalam machine learning yang digunakan untuk mengukur seberapa baik model dalam menemukan kembali data yang benar-benar positif (TP) pada dataset yang digunakan. Recall juga dikenal sebagai sensitivity atau true positive rate (TPR). Recall mengukur rasio antara jumlah prediksi benar positif (TP) dengan jumlah data positif yang sebenarnya. Dengan kata lain, recall mengukur persentase dari data positif yang diklasifikasikan oleh model sebagai positif. Rumus untuk menghitung recall adalah sebagai berikut:

$$Recall = \frac{TP}{TP + FN} \tag{4}$$

Dimana TP adalah jumlah prediksi benar positif (True Positive) dan FN adalah jumlah prediksi salah negatif (False Negative).

e) Confusion Matrix

Confusion matrix adalah sebuah tabel yang digunakan untuk mengevaluasi performa model machine learning dengan membandingkan prediksi model dengan hasil yang sebenarnya. Confusion matrix terdiri dari empat jenis nilai yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). TP adalah jumlah prediksi benar positif (model memprediksi positif dan benar), TN adalah jumlah prediksi benar negatif (model memprediksi negatif dan benar), FP adalah jumlah prediksi salah positif (model memprediksi positif tetapi sebenarnya negatif), dan FN adalah jumlah prediksi salah negatif (model memprediksi negatif tetapi sebenarnya positif). Confusion matrix biasanya digunakan dalam tugas-tugas klasifikasi biner, yaitu di mana model diminta untuk memprediksi antara dua kelas, seperti antara kelas positif dan negatif, benar atau salah, atau ya atau tidak. Namun, confusion matrix juga dapat digunakan dalam tugas-tugas klasifikasi multi-kelas (kelas lebih dari 2), di mana setiap kelas dianggap sebagai positif dan kelas-kelas lainnya sebagai negatif.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 6. Contoh Confusion Matrix

Dapat dilihat pada gambar 6 contoh Confusion matrix menunjukkan jumlah prediksi yang benar (true positive dan true negative) dan jumlah prediksi yang salah (false positive dan false negative) pada setiap kelas objek.

3. HASIL DAN PEMBAHASAN

Penelitian ini melakukan pengujian dengan melakukan object detection dengan menggunakan pre-trained model dan hyperparameter dari masing-masing model. Output dari hasil pengujian model ini akan menghasilkan Metrics evaluation yang terdiri dari Mean Average Precision (mAP), F1 Score, Precision, dan Recall. Perhitungan performa model diperlukan untuk membandingkan dan mencari hasil terbaik dari model yang telah diuji.

Proses penelitian deteksi objek ini menggunakan arsitektur YOLO yaitu YOLOv7 dengan pre-trained model pada masing-masing arsitektur berupa YOLOv7, YOLOv7x, YOLOv7-w6, YOLOv7-e6, YOLOv7-d6, dan YOLOv7-e6e sehingga akan menghasilkan 6 model yang berbeda. Pada tahap ini juga akan membahas hasil dari model yang sudah di training dengan menggunakan nilai dari metrics evaluation yang didapat. Tahap ini juga akan menampilkan hasil predict dan perbandingan masing-masing model untuk mencari hasil model yang terbaik.


Kami melakukan proses pengujian model YOLOv7 menggunakan Backbone CSPDarknet-53 dengan hyperparameter yang digunakan yaitu Epoch sebesar 300, batch size sebesar 16, dan learning rate sebesar 0,0001. Berdasarkan percobaan ini, evaluasi akan menghasilkan nilai berupa Mean Average Precision (mAP), F1 score, precision, recall, dan confusion matrix. Untuk output dari hasil pengujian model YOLOv7 ini dapat dilihat pada tabel 2 berikut.

Tabel 2. Hasil dari YOLOv7

Model	Precision	Recall	F1-score	mAP50
YOLOv7	0,819	0,92	0,89	0,908
YOLOvx	0,876	0,89	0,84	0,855
YOLOv7-w6	0,834	0,96	0,90	0,919
YOLOv7-e6	0,812	0,801	0,93	0,810
YOLOv7-d6	0,877	0,809	0,806	0,815
YOLOv7-e6e	0,869	0,801	0,93	0,832

Dalam tabel diatas analisis performa berbagai versi YOLO (You Only Look Once) pada dataset yang diukur dengan metrik Precision, Recall, F1-score, dan mAP50, terdapat perbedaan signifikan antara model-model tersebut. YOLOv7 mencapai tingkat Precision yang tinggi sebesar 0,819, tetapi memperoleh Recall dan F1-score yang lebih tinggi dibandingkan dengan YOLOvx yang mencapai 0,92 dan 0,89 secara berturut-turut. Meskipun YOLOvx memiliki nilai Precision yang lebih tinggi, F1-score yang lebih rendah menunjukkan adanya trade-off antara Precision dan Recall.

YOLOv7-w6 menunjukkan hasil yang konsisten dengan nilai Precision, Recall, dan F1-score yang tinggi sebesar 0,834, 0,96, dan 0,90 secara berturut-turut, menandakan kemampuan model untuk mengenali objek dengan baik. YOLOv7-e6e juga menunjukkan performa yang baik dengan nilai F1-score sebesar 0,93, walaupun nilai Recall dan mAP50 yang lebih rendah. Namun, YOLOv7-e6 dan YOLOv7-d6 menunjukkan trade-off antara Precision, Recall, dan F1-score. YOLOv7-d6 mencapai nilai Precision yang tinggi sebesar 0,877, tetapi mengorbankan Recall dan F1-score, sedangkan YOLOv7-e6 memiliki nilai Recall yang tinggi sebesar 0,801, namun Precision yang lebih rendah. Secara umum, analisis menunjukkan bahwa setiap versi YOLO memiliki kekuatan dan kelemahan masing-masing. Pengembang dapat memilih model berdasarkan kebutuhan spesifik tugas deteksi objek. Hasil ini menunjukkan bahwa YOLOv7 memiliki potensi besar untuk deteksi lesi prakanker serviks. Selanjutnya hasil prediksi YOLOv7 dapat dilihat pada gambar 6 berikut ini:



Gambar 7. Hasil Prediksi (a) kelas columnar (b) lesi dan columnar

Dapat disimpulkan dari hasil predict pada 7 model yang telah diatit diatas. Model dapat melakukan predict dengan cukup akurat dan presisi, dikarenakan hasil mAP yang dihasilkan tinggi dan baik serta hasil prediksi dari arsitektur YOLOv7 sudah sesuai dengan penentuan kelas.

4. KESIMPULAN

Diagnosa lesi prakanker serviks yang cepat dan akurat membutuhkan model yang handal dalam deep learning. Penelitian menunjukkan kinerja YOLOv7 menunjukkan kemampuan model untuk mendeteksi lesi prakanker secara akurat dan dapat disimpulkan bahwa YOLOv7-w6 menonjol dengan nilai tertinggi pada parameter Recall (0,96) dan mAP50 (0,919). Hal ini menunjukkan bahwa YOLOv7-w6 memiliki kemampuan yang sangat baik

dalam mengidentifikasi dan mendeteksi objek target dengan tingkat keakuratan yang tinggi. Di sisi lain, YOLOvx juga memberikan performa yang baik dengan nilai Precision tertinggi (0,876), menunjukkan kemampuan model untuk menghindari kesalahan positif. YOLOv7 dan YOLOv7-e6 juga menunjukkan kinerja yang solid dengan F1-score di sekitar 0,89, sementara YOLOv7-e6e menonjol dengan nilai F1-score tertinggi (0,93). Namun, YOLOv7-d6 menunjukkan performa yang relatif lebih rendah dalam parameter Precision dan Recall. Kesimpulan ini menyoroti bahwa pemilihan model deteksi objek perlu mempertimbangkan trade-off antara Precision dan Recall, dengan memperhatikan kebutuhan spesifik aplikasi atau tujuan penggunaan.

REFERENCES

- [1] Ferlay J, Ervik M, Lam F. "Global cancer observatory: cancer today," Lyon, France: International Agency for Research on Cancer, 2018
- [2] Novitasari DCR, Asyhar AH, Thohir M, Arifin AZ, Mu'jizah H, Foeady AZ. "Cervical cancer identification based texture analysis using glcm-kelm on colposcopy data," Accessed International Conference on Artificial Intelligence in Information and Communication (ICAIC), 2020.
- [3] A. Roihan, P. A. Sunarya, A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang : Review paper," 2020, hal. 75–82.
- [4] J. A. Nichols, H. W. H. Chan, M. A. B. Baker, "Machine learning : applications of artificial intelligence to imaging and diagnosis," hal. 111–118, 2019.
- [5] A. Kumar, S. Srivastava, "Object Detection System Based on Convolution Using Single Shot Multi-Box Detector," *Procedia Comput. Sci.*, vol. 171, hal. 2610–2617, 2020, doi: 10.1016/j.procs.2020.04.283.
- [6] J. Ker, L. Wang, J. Rao, dan T. Lim, "Deep Learning Applications in Medical Image Analysis," *IEEE Access*, vol. 6, hal. 9375–9379, 2017. doi: 10.1109/ACCESS.2017.2788044.
- [7] Li Y, Chen J, Xue P, Tang C, Chang J, Chu C, et al.. "Computer-aided cervical cancer diagnosis using time-lapsed colposcopic images," *IEEE Trans Med Imaging*, 2020, doi: 10.1109/TMI.2020.2994778 .
- [8] Sato M, Horie K, Hara A, Miyamoto Y, Kurihara K, Tomio K, et al.. "Application of deep learning to the classification of images from colposcopy," *Oncol Lett* , 2018, doi: 10.3892/ol.2018.7762.
- [9] S. K. Gautam et al., "Considerations for a PAP Smear Image Analysis System with CNN Features," arXiv:1806.0902, 2018
- [10] J. V. Burness, P. Oregon, F. Medicine, dan P. M. Hospital, "Cervical Colposcopy : Indications and Risk Assessment," 2020.
- [11] B. Bai et al., "Detection of cervical lesion region from colposcopic images based on feature reselection," *Biomed. Signal Process. Control*, vol. 57, hal. 101785, 2020. doi: 10.1016/j.bspc.2019.101785.
- [12] P. Guo et al., "Anatomical landmark segmentation in uterine cervix images using deep learning," *Proc. SPIE*, vol. 11318, hal. 32, 2020. doi: 10.1117/12.2549267.
- [13] M. Coskun et al., "An Overview of Popular Deep Learning Methods," *Eur. J. Tech.*, vol. 7, no. 2, hal. 165–176, 2017. doi: 10.23884/ejt.2017.7.2.11.
- [14] P. Wang et al., "Automatic cell nuclei segmentation and classification of cervical Pap smear images," *Biomed. Signal Process. Control*, vol. 48, hal. 93–103, 2019. doi: 10.1016/j.bspc.2018.09.008.
- [15] V. Kudva, K. Prasad, dan S. Guruvare, "Automation of Detection of Cervical Cancer Using Convolutional Neural Networks," hal. 135–145, 2018.
- [16] S. Kiptoo, L. Nderu, dan L. Mutanu, "Automated Detection of Cervical Pre-Cancerous Lesions Using Regional-Based Convolutional Neural Network," 2020.
- [17] A. U. Rehman et al., "An Automatic Mass Screening System for Cervical Cancer Detection Based on Convolutional Neural Network," *Math. Probl. Eng.*, 2020. doi: 10.1155/2020/4864835.
- [18] Y. Li et al., "Computer-aided Cervical Cancer Diagnosis using Time-lapsed Colposcopic Images," *IEEE Trans. Med. Imaging*, 2020. doi: 10.1109/TMI.2020.2994778.
- [19] Mueller JL, Lam CT, Dahl D, Asiedu MN, Krieger MS, Bellido-Fuentes Y, et al.. "Portable pocket colposcopy performs comparably to standard-of-care clinical colposcopy using acetic acid and lugol's iodine as contrast mediators: an investigational study in peru". *BJOG . Int J Obstetric Gynaecol* (2018) 125:1321–9. doi: 10.1111/1471-0528.15326
- [20] Q. Aini et al., "DETEKSI DAN PENGENALAN OBJEK DENGAN MODEL MACHINE LEARNING : MODEL YOLO," vol. 6, no. 2, hal. 192–199, 2021.