

Analisis Performansi Parameter pada Arsitektur U-Net untuk Segmentasi Nukleus pada Citra Kanker Serviks

Putu Desiana Wulaning Ayu¹, Gede Angga Pradipta²

^{1,2}Institut Teknologi dan Bisnis STIKOM Bali

e-mail: ¹wulaning_ayu@stikom-bali.ac.id, ²angga_pradipta@stikom-bali.ac.id

Diajukan: 1 Januari 2024; Direvisi: 2 Februari 2024; Diterima: 6 Februari 2024

Abstrak

Pap Smear adalah salah satu metode untuk memeriksa sel-sel serviks. Sel-sel tersebut diperiksa dengan mikroskop untuk mengamati perubahan atau ketajaman sel epitel serviks sebagai tanda awal adanya keberadaan kanker. Namun, pemeriksaan Smear Pap secara manual memiliki beberapa kekurangan, yaitu membutuhkan waktu yang relatif lama dan peluang terjadinya kesalahan selama analisis besar karena bersifat subjektif. Namun, citra mikroskopis Pap Smear sulit untuk diinterpretasi, karena terdapat sel-sel yang berkelompok, tumpang tindih, adanya sel-sel inflamasi, bekas darah, kontras rendah, dan variasi dalam pencahayaan yang terjadi karena metode pewarnaan yang tidak konsisten seperti konsentrasi zat pewarna. Salah satu model dalam melakukan interpretasi citra adalah dengan segmentasi citra, maka penelitian ini berfokus pada pengembangan metode segmentasi menggunakan pendekatan model semantic segmentation U-Net dengan arsitektur dari Roenerberger. Penelitian ini menganalisis beberapa penggunaan hyperparameter untuk mengetahui performansi dari arsitektur model U-NET khususnya untuk mengsegmentasi AF. Adapun tuning hyperparameter terdapat pada optimizer, loss function, learning rate serta jumlah epoch. Performa terbaik U-Net dalam melakukan segmentasi cairan ketuban adalah dengan kombinasi parameter optimizer RMSprop, Loss function adalah Binary cross entropy, nilai learning rate 0.00001 dengan Epoch sebesar 31 dengan DSC sebesar 0.82 dan IoU sebesar 0.70, akurasi sebesar 0.8, presisi 0.78, recall 0.81.

Kata kunci: Nucleus, Citra kanker serviks, Segmentasi, U-Net.

Abstract

Pap Smear is one method for examining cervical cells. These cells are examined under a microscope to observe changes or sharpness of the cervical epithelial cells as an early sign of the presence of cancer. However, manual Pap Smear examinations have several shortcomings, including requiring a relatively long time and a high likelihood of errors during analysis due to its subjective nature. Moreover, Pap Smear microscopic images are difficult to interpret, as there are clustered cells, overlapping, presence of inflammatory cells, blood residues, low contrast, and variations in lighting due to inconsistent staining methods such as the concentration of the dye. One model for interpreting images involves image segmentation; therefore, this study focuses on developing a segmentation method using the U-Net semantic segmentation model architecture by Roenerberger. This research analyzes several uses of hyperparameters to determine the performance of the U-NET model architecture, particularly for segmenting amniotic fluid. The hyperparameter tuning involves the optimizer, loss function, learning rate, and number of epochs. The best performance of U-Net in segmenting amniotic fluid was achieved with an optimizer parameter of RMSprop, loss function of Binary cross entropy, a learning rate of 0.00001, and 31 epochs, achieving a DSC of 0.82 and IoU of 0.70, with an accuracy of 0.8, precision of 0.78, and recall of 0.81.

Keywords: Nucleus, Serviks image, Segmentation, U-Net.

1. Pendahuluan

Kanker serviks merupakan salah satu penyakit yang menjadi fokus penanganan yang signifikan terutama dinegara-negara berkembang, di mana akses terhadap skrining dan deteksi dini mungkin terbatas[1]. Mengidentifikasi kelainan serviks pada tahap awal melalui metode skrining seperti Pap Smear dan tes HPV sangat krusial untuk meningkatkan efektivitas pengobatan dan memperbaiki prognosis pasien[2]. Pap Smear adalah salah satu metode untuk memeriksa sel-sel serviks. Sel-sel tersebut diperiksa

dengan mikroskop untuk mengamati perubahan atau ketajaman sel epitel serviks sebagai tanda awal adanya keberadaan kanker[2]. Namun, pemeriksaan Smear Pap secara manual memiliki beberapa kekurangan, yaitu membutuhkan waktu yang relatif lama dan peluang terjadinya kesalahan selama analisis besar karena bersifat subjektif[3]. Namun, citra mikroskopis Pap Smear sulit untuk diinterpretasi, karena terdapat sel-sel yang berkelompok, tumpang tindih, adanya sel-sel inflamasi, bekas darah, kontras rendah, dan variasi dalam pencahayaan yang terjadi karena metode pewarnaan yang tidak konsisten seperti konsentrasi zat pewarna[4]. Oleh karena itu, dalam beberapa tahun terakhir, penelitian difokuskan pada model yang dapat menginterpretasi citra Pap Smear secara otomatis. Salah satu model dalam melakukan interpretasi citra adalah dengan segmentasi citra. Segmentasi citra adalah proses pemrosesan citra yang bertujuan untuk memisahkan area objek dari area latar belakang sehingga objek dapat dengan mudah dianalisis untuk mengenali objek yang melibatkan banyak visual[5]. Citra mikroskopis pap smear terdiri dari 3 bagian, yaitu *background*, *citoplasma*, dan *nucleus*. Segmentasi dari ketiga bagian tersebut dapat dilakukan dengan pendekatan *deep learning*.

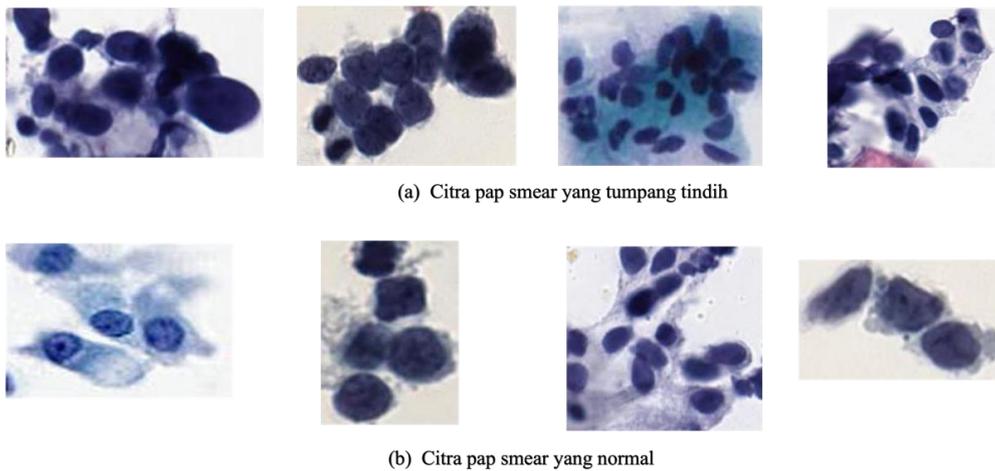
Deep learning merupakan bagian dari kecerdasan buatan, telah menjadi alat yang menjanjikan untuk meningkatkan kemampuan mendeteksi dan mendiagnosis kanker serviks. Teknik *deep learning*, terutama jaringan saraf konvulsional (CNN), telah menunjukkan kemampuan luar biasa dalam segmentasi citra medis. Berbeda dengan metode tradisional yang mengandalkan ekstraksi fitur, model *deep learning* dapat secara otomatis mempelajari fitur-fitur yang relevan dari data, memungkinkan mempelajari pola dan variasi kompleks dalam citra mikroskopis pap smear[1]. Dengan melatih pada dataset besar gambar serviks yang dianotasi, model *deep learning* dapat mencapai akurasi dan efisiensi tinggi dalam mengsegmentasi struktur serviks. Salah satu model arsitektur *deep learning* dengan performansi yang baik dalam bidang citra medis yaitu dengan arsitektur U-Net [6], [7], [8], [9], [10]. Arsitektur U-Net mengadaptasi struktur enkoder-dekoder, proses enkoder dimulai dengan lapisan konvolusi yang bertujuan untuk menangkap fitur-fitur penting dari citra input, proses decoder merekonstruksi hasil segmentasi dari representasi fitur yang telah diekstraksi oleh encoder [11].

Beberapa penelitian yang mengadaptasi arsitektur U-Net antara lain adalah Ayu dkk, melakukan penelitian untuk mensegmentasi area cairan ketuban pada citra rongga ketuban dengan menggunakan arsitektur U-net, dengan menganalisis penggunaan parameter seperti *optimizer*, *lost function*, *learning rate* dan *epoch*, dengan hasil DSC sebesar 88% dan IoU 79% [12]. Penelitian yang dilakukan oleh Kurniawan dkk, melakukan segmentasi pada inti dan sitoplasma dataset Herlev menggunakan arsitektur U-Net yang dipadukan dengan augmentasi data dan peningkatan citra. Dalam proses pembelajarannya, penelitian ini menghasilkan nilai IoU yang cukup tinggi yaitu 78%[3]. Yao Liu dkk menggunakan arsitektur U-Net untuk mensegmentasi citra serviks, dengan menggunakan arsitektur U-Net dari *Rooneyberger* [11] dengan settingan pada parameter *momentum*, *learning rate* dan koefisien pada *learning rate* serta iterasi. Pada penelitian yang dilakukan oleh Yaou Liu dkk, menghasilkan *Average Pixel Accuracy* sebesar 0.8736 dan *average intersection* sebesar 0.7786[6]. Dari penelitian yang telah disampaikan sebelumnya, *average accuracy pixel* paling tinggi adalah pada penelitian yang dilakukan oleh You Liu, sebesar 0.8736, sehingga pada penelitian ini mengadopsi arsitektur U-Net dari [11] dengan penggunaan *tuning hyperparameter* [12]. seperti *optimizer* seperti *Stochastic Gradient Descent* (SDG), *Adam*, *Nadam*, *RMSprop*, *AdaDelta*, dan *AdaMa,x di mana harapannya dapat meningkatkan DSC dan IoU* dari penelitian-penelitian.

2. Metode Penelitian

2.1 Akuisisi Data

Dataset citra pada penelitian ini bersumber dari *Kaggle Public Dataset* (<https://www.kaggle.com/datasets/zhaojing0522/cervical-nucleus-segmentation>). Repositori ini terdiri dari total 1030 gambar untuk data *training*, dan 477 citra untuk data *testing*. Dataset citra memiliki ukuran resolusi piksel sebesar 512 x 512 piksel. Gambar 1 menunjukkan contoh Publik Dataset.

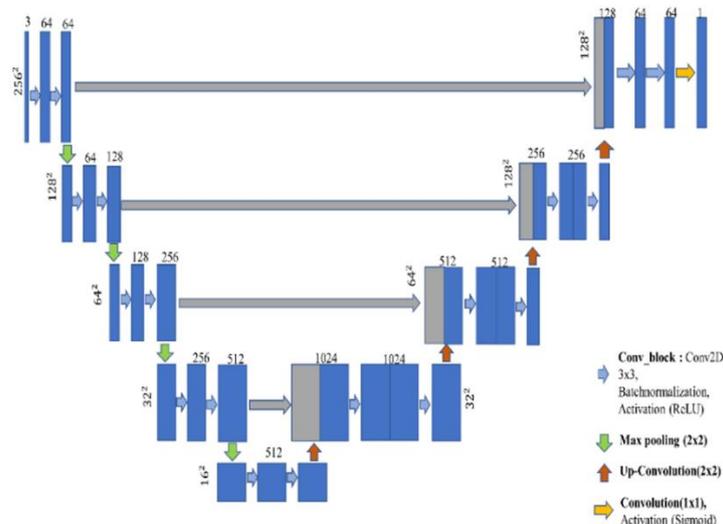


Gambar 1. Contoh dataset citra pap smear (a) citra pap smear yang terlihat tumpang tindih (b) citra pap smear normal.

2.2 Arsitektur U-Net

Citra lesi kanker serviks merupakan citra RGB, sehingga jumlah lapis konvolusional pertama untuk masukan menjadi 3. Citra masukan adalah 512×512 , dan penerapan konvolusional menambah kedalaman citra. Kami menggunakan blok konvolusional untuk setiap filter dalam arsitektur ini dengan ukuran 64, 128, 256, dan 512. Blok konvolusional terdiri dari dua proses konvolusional dengan ukuran kernel 3×3 diikuti dengan satu proses *batch normalization*. Fungsi aktivasi *ReLU* digunakan di setiap lapisan konvolusional. Panah hijau pada Gambar 2 menunjukkan proses penggabungan maksimal menggunakan kernel 2×2 . Panah abu-abu menunjukkan proses digunakan untuk menyimpan *feature map* dari *encoder* ke *decoder*.

Proses pertama adalah melakukan inisialisasi sebuah variabel bernama *skip_connection_x* untuk melakukan proses *bridging* antara *encoder* dan *decoder* ini. *Output* dari *conv_block* kemudian ditambahkan kedalam variabel *skip_connection_x*, yang mana digunakan nantinya pada tahapan *decoder*. Proses *decoder* ini memiliki fungsi utama yaitu untuk menghasilkan *semantic segmentation map* yang diinginkan. *Decoder* melakukan perulangan pada seluruh ukuran filter yang digunakan, di mana pada proses perulangan tersebut terdapat layer *upsampling* dengan window 2×2 . Setelah itu *output* dari proses *upsampling* ini kemudian digabungkan atau disambungkan dengan nilai pada *skip connection* yang tersimpan pada variabel *skip_connection_x*. Pada akhir dari proses *decoder* ini, proses konvolusi dilakukan dengan menggunakan ukuran *window* 1×1 dengan menggunakan fungsi aktivasi sigmoid. Proses ini menghasilkan *final output* berupa hasil segmentasi dalam bentuk *binary mask* dari citra nucleus kanker serviks.



Gambar 2. Arsitektur U-Net [11], [12].

2.3 Optimizer

Optimizer adalah algoritma atau metode yang digunakan untuk meminimalkan fungsi kesalahan (*loss function*) atau untuk memaksimalkan efisiensi produksi. *Optimizer* merupakan fungsi matematika yang berkaitan dengan pengembangan parameter seperti *weight* dan bias. *Optimizer* dapat membantu dalam mengubah nilai dari *weight* dan *learning rate* pada *neural network* untuk mengurangi *losses*. Adapun beberapa *optimizer* yang digunakan pada *deep learning* seperti: *Optimizer* dapat membantu dalam mengubah nilai dari *weight* dan *learning rate* pada *neural network* untuk mengurangi *losses*. Adapun beberapa *optimizer* yang digunakan pada *deep learning* seperti:

A. Gradient Descent

Gradient descent (GD) merupakan algoritma optimasi yang didasarkan pada *convex function* dan menyesuaikan parameter-parameternya secara iteratif untuk meminimalkan fungsi kerugian dengan bergerak ke arah yang berlawanan dengan arah naik [13]. Kelebihan dari *gradient descent* adalah mudah diimplementasikan, sedangkan kekurangannya adalah komputasi atau perhitungan yang sangat lambat yang disebabkan oleh perhitungan gradien untuk seluruh kumpulan data dalam satu *update*, dan membutuhkan *memory* yang besar serta komputasi yang tinggi. Pengembangan dari algoritma GD salah satunya adalah *Stochastic Gradient Descent* (SGD), di mana SGD ini melakukan *update* parameter satu per satu atau melakukan *update* parameter untuk setiap *training* $x^{(i)}$ dan label $y^{(i)}$, di mana persamaannya ada pada (1).

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \tag{1}$$

Where θ is weight, η is *learning rate*, J is jumlah *training* sampel.

Keuntungan dari pengoptimal SGD adalah *update* parameter model yang secara berkala, membutuhkan memori yang lebih sedikit, dan memungkinkan penggunaan kumpulan data besar karena hanya perlu memperbarui satu contoh pada satu waktu.

B. Adadelta

Adadelta adalah pengembangan dari *Adagrad* yang bertujuan untuk mengurangi laju pembelajaran yang agresif dan secara monotonik menurun [14]. Berbeda dengan mengakumulasi semua gradien kuadrat sebelumnya, *Adadelta* membatasi jendela gradien sebelumnya yang terakumulasi ke ukuran tetap w . Pada *adadelta* tidak diperlukan untuk mengatur default *learning rate*, karena telah dihilangkan dari *update rule*. Kelebihan dari *Adadelta* adalah tidak membutuhkan *learning rate*. Di mana persamaannya ada pada (2) [14].

$$\theta_{t+1} = \theta_t + \Delta_{\theta_t} \tag{2}$$

C. RMSprop

RMSprop adalah metode adaptif *learning* oleh Geoff Hinton. RMS-Prop adalah versi khusus *Adagrad* di mana tingkat pembelajaran adalah rata-rata eksponensial dari gradien, bukan jumlah kumulatif gradien kuadrat[13]. RMS-Prop pada dasarnya menggabungkan momentum dengan AdaGrad. In RMS-Prop *learning rate* RMS-Prop disesuaikan secara otomatis dan memilih *learning rate* yang berbeda untuk setiap parameter. Di mana persamaannya ada pada (4).

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \tag{3}$$

$$\sqrt{E[g^2]_t} = 0.9 E[g^2]_{t-1} \tag{4}$$

RMSprop juga membagi *learning rate* dengan rata-rata gradien kuadrat yang menurun secara eksponensial. Hinton menyarankan agar γ diatur ke nilai 0,9, sementara nilai *default* yang baik untuk laju pembelajaran η adalah 0,001.

D. Adam

Adaptive Moment Astimation (Adam) merupakan metode yang menghitung adaptive *learning rate* untuk setiap parameter. Selain menyimpan *exponentially decaying average of past squared gradient* v_t seperti Adadelta dan RMSprop, Adam juga menyimpan rata-rata penurunan eksponensial dari past gradient

m_t [15]. Adam mengamati nilai bias menuju zero, terutama selama langkah waktu awal, dan terutama ketika *decay rate* kecil (i.e 1 and are close to 1). Persamaan untuk Adam dapat dilihat pada persamaan (7)[15].

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{5}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{6}$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \tag{7}$$

Di mana m_t dan v_t estimasi dari *first moment* (the mean) dan *the second moment* (the uncentered variance) dari *gradient* [16]. *Default values* 0.9 untuk β_1 , 0.999 untuk β_2 , dan 10^{-8} for ϵ .

2.4 Loss Function

Loss function digunakan untuk mengukur kesalahan antara keluaran prediksi dan nilai target yang diberikan. Tujuannya adalah hampir selalu untuk meminimalkan *minimize loss function*/fungsi kerugian. Di mana semakin rendah kerugian, semakin baik modelnya. Sebuah *loss function* memberitahu kita seberapa jauh model algoritma dari mewujudkan hasil yang diharapkan. Kata “loss” berarti penalti atau hukuman yang didapatkan oleh model karena gagal memberikan hasil yang diinginkan. Penggunaan *loss function* berdasarkan pada tujuan model yang dikembangkan. Pada klasifikasi model, *loss function* yang bisa digunakan antara lain seperti *Binary Cross-Entropy* (BCE), *Hinge Loss* (HL) dan *Squared Hinge Loss* (SHL). *BCE Loss* terutama digunakan untuk model klasifikasi biner, yang mana model hanya memiliki 2 kelas, dengan persamaan (9).

$$loss(x, y) = - \sum x \cdot \log(y) \tag{8}$$

2.5 Learning Rate dan Epoch

Learning rate, merupakan salah satu parameter *training* untuk menghitung nilai koreksi bobot pada waktu proses *training*. Nilai *learning rate* ini berada pada *range* nol (0) sampai (1). Semakin besar nilai *learning rate*, maka proses *training* berjalan semakin cepat. Semakin besar *learning rate*, maka ketelitian jaringan akan semakin berkurang, tetapi berlaku sebaliknya, apabila *learning rate*-nya semakin kecil, maka ketelitian jaringan akan semakin besar atau bertambah dengan konsekuensi proses *training* akan memakan waktu yang semakin lama. Sedangkan *epoch*, untuk mewakili jumlah iterasi yang harus dilakukan pada set data. *Epoch* menandakan satu siklus algoritma *deep learning* belajar dari keseluruhan *training dataset*. Satu *epoch* berarti menandakan sebuah algoritma *deep learning* telah belajar dari *training dataset* secara keseluruhan.

2.6 Evaluasi Performansi

Evaluasi performansi untuk segmentasi kami menggunakan *Dice Similarity Coefficient* (DSC) and *Intersection of Union* (IoU). Sedangkan untuk mengetahui performansi dari *Optimizer* terhadap *loss function*, *learning rate* dan *epoch* kami menggunakan *confusion matrix*.

Oleh karena itu, DSC memiliki rentang nilai antara [0, 1]. Selain itu, DSC didefinisikan dalam Persamaan (10) [8]. Lebih lanjut, koefisien *Jaccard* / IoU adalah jumlah irisan piksel A dan B dibagi oleh gabungan A dan B seperti yang ditunjukkan dalam persamaan. (10-11)[12].

$$DSC = \frac{2|A \cap B|}{|A| + |B|} \tag{9}$$

$$Jaccard/IoU = \frac{|A \cap B|}{|A \cup B|} \tag{10}$$

Di mana: *A* adalah piksel yang tersegmentasi, dan *B* adalah *pixel* dari label/*groundtruth*.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \tag{11}$$

$$\text{Precision} = \frac{TP}{TP + FP} \tag{12}$$

$$\text{Recall} = \frac{TP}{TP + FN} \tag{13}$$

TP adalah *True Positive* (label positif yang diprediksi sebagai label aktual), FP adalah *False Positive* (label negatif tetapi diprediksi sebagai label positif), TN adalah *True Negative* (data negatif yang diprediksi dengan benar), dan FN adalah *False Negative* (label positif tetapi diprediksi sebagai label negatif).

3. Hasil dan Pembahasan

Skenario eksperimen yang dilakukan pertama kali adalah menguji *penggunaan / pergantiaan parameter* (Tuning hyperparameter) seperti *epoch*, *learning rate*, *loss function*, dan *optimizer*. *Tuning hyperparameter* ini dilakukan untuk mengetahui parameter terbaik yang bisa digunakan untuk segmentasi nucleus pada citra microscopis kanker serviks. Langkah pertama, pengecekan dilakukan dengan menguji beberapa metode *optimizer* seperti *Stochastic Gradient Descent* (SDG), *Adam*, *Nadam*, *RMSprop*, *AdaDelta*, dan *AdaMax* dengan *learning rate* bernilai 0,00001, jumlah *batch* adalah 2, dan *epoch* sebesar 40. Tabel 1 menunjukkan hasil ujicoba terhadap 6 metode *optimizer* di atas.

Tabel 1. Perbandingan performa metode optimizer pada model U-Net untuk segmentasi nucleus pada citra kanker serviks.

Optimizer	Metrik Performansi					
	loss	acc	recall	precision	IoU	DSC
<i>Stochastic Gradient Descent</i> (SGD)	0,40	0,77	0,80	0,81	0,52	0,70
<i>RMSprop</i>	0,41	0,83	0,82	0,92	0,74	0,82
<i>AdaDelta</i>	0,62	0,53	0,68	0,60	0,4	0,52
<i>AdaMax</i>	0,29	0,81	0,84	0,91	0,72	0,81
<i>Nadam</i>	0,32	0,83	0,82	0,88	0,80	0,81
<i>Adam</i>	0,31	0,81	0,83	0,91	0,77	0,80

Dari Tabel 1 di atas dapat diketahui bahwa metode *RMSprop* mampu mencapai performa terbaik dengan nilai DSC dan IoU pada data uji sebesar 0,82 dan 0,74, dari hasil ini kemudian dilakukan kembali *tuning hyperparameter* pada model dengan *optimizer RMSprop* dengan melakukan eksperimen pada metode *Loss Function* yang digunakan yaitu *Binary Crossentropy*, *Hinge*, dan *Squared Hinge*. Tujuan dari eksperimen kedua ini untuk mengetahui metode *Loss Function* terbaik yang bisa dihasilkan oleh model *U-net* menggunakan *optimizer RMSprop*. Tabel 2 menunjukkan performa model terhadap beberapa metode *loss function* yang telah diujicobakan.

Tabel 2. Perbandingan hasil terhadap metode *loss function* yang digunakan pada metode U-Net.

Loss Function	Metrik Performansi					
	loss	acc	recall	precision	IoU	DSC
<i>Binary cross entropy</i>	0,38	0,81	0,80	0,8	0,71	0,80
<i>Hinge</i>	0,40	0,67	0,6	0,62	0,65	0,77
<i>Squared Hinge</i>	0,32	0,50	0,86	0,60	0,55	0,70

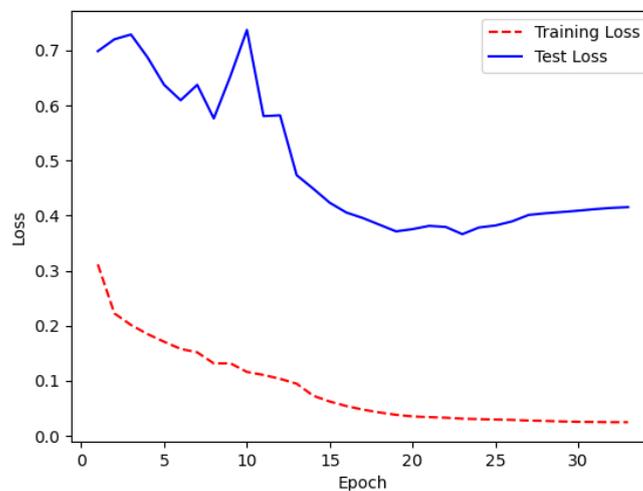
Dari hasil yang ditunjukkan pada tabel di atas, diketahui bahwa metode *Loss Function* yaitu *Binary Cross Entropy* mampu memberikan hasil terbaik dengan mencapai nilai DSC sebesar 0,80 (80%) dan IoU sebesar 0,71 (71%). Dari kedua hasil eksperimen ini telah didapatkan kombinasi terbaik antara metode *optimizer* dan metode *Loss Function* yaitu *RMSprop* dan juga *Binary Cross Entropy*. *Tuning*

Hyperparameter berikutnya adalah dilakukan untuk mengetahui nilai *Learning Rate* dan jumlah *epoch* terbaik dari kedua kombinasi metode di atas terhadap model U-Net. *Learning Rate* diobservasi pada nilai 0.00001, 0.0001, 0.001, dan 0.1 Tabel 3 Menunjukkan hasil performa model U-Net pada tuning parameter *Learning Rate*.

Tabel 3. Perbandingan hasil terhadap metode *nilai learning rate* yang digunakan pada metode U-Net.

Performance Metric	RMSprop + Binary_crossentropy			
	Learning Rate			
	0,00001	0,0001	0,001	0,01
Val_IoU	0,70	0,68	0,67	0,66
Val_DSC	0,82	0,81	0,83	0,81
Val_acc	0,8	0,81	0,82	0,81
Val_precision	0,78	0,77	0,8	0,8
Val_recall	0,81	0,83	0,81	0,83
Val_loss	0,40	0,3	0,31	0,22

Nilai *Learning Rate* 0.00001 mampu memberikan hasil yang terbaik pada model U-Net yaitu dengan nilai DSC sebesar 0.82 dan IoU sebesar 0.70. Dari ketiga hasil *Tuning Hyperparameter* ini didapatkan bahwa hasil kombinasi *optimizer RMSprop*, Metode *Loss Function Binary Cross Entropy*, dan *Learning Rate* 0.00001 menjadi parameter terbaik yang bisa di *tuning* pada model U-Net untuk melakukan segmentasi pada cairan ketuban. Terakhir untuk mengetahui nilai *Epoch* yang dibutuhkan hingga model ini konvergen dilakukan dengan pengecekan jumlah *Epoch* dengan batas hingga 100 dan juga menggunakan metode *Early Stopping* untuk melakukan monitoring saat sudah tidak ada lagi perbaikan performa. Gambar 3 menunjukkan plot antara jumlah *epoch* dan *validation loss* pada model U-Net dari hasil *Tuning Hyperparameter* ini.



Gambar 3. Plot antara nilai *epoch* dan nilai loss pada model U-net.

Dari Gambar 3 di atas pada nilai *epoch* 31 ke atas, tidak terjadi perubahan nilai *validation loss* sehingga metode *early stopping* mengakhiri proses pelatihan pada *epoch* ke 31 diperoleh U-Net pada salah satu validasi data citra.

4. Kesimpulan

Kesimpulan pada paper ini berdasarkan hasil eksperimen terhadap *tuning* parameter dari model U-Net ini dapat diketahui bahwa performa terbaik U-Net dalam melakukan segmentasi cairan ketuban adalah dengan kombinasi parameter *optimizer RMSprop*, *Loss function* adalah *Binary cross entropy*, nilai *learning rate* 0.00001 dengan *Epoch* sebesar 31 dengan DSC sebesar 0.82 dan IoU sebesar 0.70, akurasi sebesar 0.8,

presisi 0.78, *recall* 0.81. Peluang riset selanjutnya dapat meningkatkan lagi performansi dari U-Net dengan melakukan *hyper-parameter tuning* atau dengan pengembangan arsitektur *deep learning* yang lainnya.

Daftar Pustaka

- [1] N. Youneszade, M. Marjani, and C. P. Pei, “Deep Learning in Cervical Cancer Diagnosis: Architecture, Opportunities, and Open Research Challenges,” *IEEE Access*, vol. 11, no. January, pp. 6133–6149, 2023, doi: 10.1109/ACCESS.2023.3235833.
- [2] A. A. Esmailzadeh and F. Nasirzadeh, “Original Article: Uterus Cancer,” *Eurasian Journal of Chemical, Medicinal and Petroleum Research*, vol. 2, no. 5, pp. 63–83, 2023.
- [3] A. Rozy, “JITE (Journal of Informatics and Telecommunication Engineering) Diagnosing Achalasia,” vol. 7, no. July, pp. 308–316, 2023.
- [4] R. Kurniawan, I. Muhimmah, A. Kurniawardhani, and I. Indrayanti, “Segmentation of Overlapping Cervical Cells in Normal Pap Smear Images Using Distance-Metric and Morphological Operation,” *CommIT (Communication and Information Technology) Journal*, vol. 11, no. 1, p. 25, 2017, doi: 10.21512/commitv11i1.1957.
- [5] C. Yang, L. hui Qin, Y. en Xie, and J. yuan Liao, “Deep learning in CT image segmentation of cervical cancer: a systematic review and meta-analysis,” *Radiation Oncology*, vol. 17, no. 1, pp. 1–14, 2022, doi: 10.1186/s13014-022-02148-6.
- [6] Y. Liu, B. Bai, H. C. Chen, P. Liu, and H. M. Feng, “Cervical Image Segmentation using U-Net Model,” *Proceedings - 2019 International Symposium on Intelligent Signal Processing and Communication Systems, ISPACS 2019*, pp. 4–5, 2019, doi: 10.1109/ISPACS48206.2019.8986384.
- [7] J. Liu, Q. Chen, J. Fan, and Y. Wu, “HSIL Colposcopy Image Segmentation Using Improved U-Net,” *Proceedings - 2021 36th Youth Academic Annual Conference of Chinese Association of Automation, YAC 2021*, pp. 891–897, 2021, doi: 10.1109/YAC53711.2021.9486581.
- [8] M. Han *et al.*, “Automatic segmentation of human placenta images with u-net,” *Journal EEE Access*, vol. 7, pp. 180083–180092, 2019, doi: 10.1109/ACCESS.2019.2958133.
- [9] C. Chu, J. Zheng, and Y. Zhou, “Ultrasonic thyroid nodule detection method based on U-Net network,” *Comput Methods Programs Biomed*, vol. 199, p. 105906, Feb. 2021, doi: 10.1016/J.CMPB.2020.105906.
- [10] H. Shin, R. Agyeman, M. Rafiq, M. C. Chang, and G. S. Choi, “Automated segmentation of chronic stroke lesion using efficient U-Net architecture,” *Biocybern Biomed Eng*, vol. 42, no. 1, pp. 285–294, Jan. 2022, doi: 10.1016/J.BBE.2022.01.002.
- [11] O. Ronneberger, P. Fischer, and T. Brox, “U-net: convolutional networks for biomedical image segmentation,” *Lecture Notes in Computer Science*, vol. 9351, pp. 234–241, 2015, doi: 10.1007/978-3-319-24574-4_28.
- [12] P. D. Wulaning Ayu and G. A. Pradipta, “U-Net Tuning Hyperparameter for Segmentation in Amniotic Fluid Ultrasonography Image,” *2022 4th International Conference on Cybernetics and Intelligent System, ICORIS 2022*, 2022, doi: 10.1109/ICORIS56080.2022.10031294.
- [13] S. Ruder, “An overview of gradient descent optimization algorithms,” pp. 1–14, 2016, [Online]. Available: <http://arxiv.org/abs/1609.04747>
- [14] M. D. Zeiler, “ADADELTA: An Adaptive Learning Rate Method,” 2012, [Online]. Available: <http://arxiv.org/abs/1212.5701>
- [15] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15, 2015.
- [16] S. Ruder, “An overview of gradient descent optimization algorithms,” pp. 1–14, 2016.