

Pemisahan Objek Sel Tumpang Tindih pada Citra Pap Smear dengan Metode Deep learning dan Watershed

Muh. Jamil¹, Dwiza Riana²

^{1,2}Universitas Nusa Mandiri, Jakarta, Indonesia

14002631@nusamandiri.ac.id

Abstract

The object observed in the Pap Smear image is Cervical Cancer which forms overlapping cells. This cancer must be observed early because it is a disease that causes the death of thousands of women worldwide every year. The death rate from this disease is the fourth highest among women. One way to be aware of this disease is to do an early check on the Pap Smear test image. This cell separation process uses the image segmentation method. This method is one of the important steps to be able to identify existing cell objects. This study proposes a segmentation method to separate 2 overlapping cells in the RepomedUNM dataset. The dataset is engineered in the manufacture of synthetic Pap Smear images. The segmentation method proposed is a Deep Learning-based method so that it can identify 2 overlapping cells in one area. The level of accuracy of the test with an average score of Intersection over Union (IoU) is 0.9003. And the results of segmentation with Deep Learning can be divided into all areas using the Watershed segmentation method. So that this research becomes a reference in the early identification of Cervical Cancer.

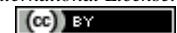
Keywords: Object Separation, Cervical Cancer, Pap Smear Image, Overlapping Cells, Segmentation.

Abstrak

Objek yang diamati pada citra Pap Smear adalah Kanker Serviks yang membentuk sel tumpang tindih (overlap). Kanker ini harus diamati secara dini karena merupakan penyakit yang menjadi penyebab kematian ribuan wanita di seluruh dunia pada setiap tahunnya. Tingkat kematian oleh penyakit ini merupakan tertinggi ke empat yang diderita oleh wanita. Salah satu cara untuk mewaspadai penyakit ini adalah dengan melakukan pemeriksaan dini pada citra Pap Smear tes. Proses pemisahan sel ini menggunakan metode segmentasi citra. Metode ini merupakan salah satu langkah penting untuk dapat mengidentifikasi objek sel yang ada. Penelitian ini mengusulkan sebuah metode segmentasi untuk dapat memisahkan 2 sel overlap pada dataset RepomedUNM. Dataset tersebut direkayasa dalam pembuatan citra Pap Smear sintetis. Metode segmentasi yang diusulkan adalah metode berbasis Deep Learning sehingga dapat mengenali 2 sel yang tumpang tindih pada satu area. Tingkat akurasi pengujian dengan skor rata-rata Intersection over Union (IoU) sebesar 0,9003. Dan hasil segmentasi dengan Deep Learning dapat dibagi terhadap seluruh area dengan menggunakan metode segmentasi Watershed. Sehingga penelitian ini menjadi rujukan dalam identifikasi awal penyakit Kanker Serviks.

Kata kunci: Pemisahan Objek, Kanker Serviks, Citra Pap Smear, Sel Tumpang Tindih, Segmentasi.

JIdT is licensed under a Creative Commons 4.0 International License.



1. Pendahuluan

Tahun 2013 telah tercatat sebanyak 98.692 kasus kanker serviks di Indonesia [1], dan 570.000 kasus pada tahun 2018 di seluruh dunia, sehingga menjadikan penyakit ini sebagai kanker tertinggi ke empat yang diderita oleh wanita [2]. Dr. Georges Papanicolaou pada tahun 1940 telah memperkenalkan metode Pap Smear tes untuk melakukan pemeriksaan dini guna untuk mewaspadai penyakit kanker serviks [3], [4]. Pemeriksaan ini dilakukan dengan mengumpulkan sampel sel dari daerah tertentu pada tubuh pasien, namun umumnya adalah di area rahim pasien [5]. Pemeriksaan tersebut menunjukkan sel serviks yang masih normal atau sudah menunjukkan gejala dini dari kanker serviks.

Segmentasi pada citra Pap Smear merupakan salah satu langkah yang paling penting untuk dapat mengidentifikasi objek sel pada citra Pap Smear [6].

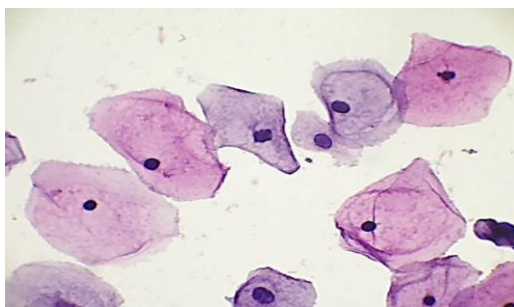
Segmentasi pada citra Pap Smear memiliki tantangan yang besar karena tidak jarang citra tersebut memiliki kualitas yang kurang baik dan bentuk sel yang saling tumpang tindih [7]. Banyak peneliti yang memperkenalkan metode untuk dapat melakukan proses segmentasi pada citra Pap Smear salah satunya adalah metode deep learning. Penelitian terdahulu seperti [8] dan [9] melakukan segmentasi citra Pap Smear yang lebih berfokus pada segmentasi bagian nukleus dan sitoplasma. Penelitian lainnya [10] yang lebih berfokus pada segmentasi bagian nukleus sel serviks pada citra Pap smear. Terdapat juga penelitian [11] yang lebih berfokus untuk melakukan segmentasi sel serviks dalam kondisi overlapping. Selain itu ketersediaan dataset yang sesuai merupakan sebuah kendala yang sering dijumpai dalam mengembangkan model berbasis Artificial Intelligence sehingga beberapa penelitian sebelumnya seperti [12], [13] menyiasati permasalahan ini dengan membuat dataset citra Pap Smear sintetis

untuk dapat mengembangkan sebuah model yang dapat melakukan proses segmentasi sel serviks dalam kondisi tumpang tindih, sehingga metode serupa akan digunakan pada penelitian ini untuk menciptakan citra Pap Smear yang terdiri dari 2 sel yang saling tumpang tindih.

U-Net merupakan model deep learning yang populer digunakan untuk melakukan segmentasi citra medis [14]. Salah satu alasan penggunaan model ini adalah karena tidak membutuhkan banyak dataset pada proses pelatihan model yang dikembangkan [15].

Beberapa penelitian terdahulu telah banyak yang melakukan kustomisasi pada bagian encoder model U-Net untuk mendapatkan hasil yang lebih baik, diantaranya adalah [16], [17], [18] menggunakan lapisan yang ada pada VGG16 sebagai encoder pada U-Net. Penelitian [19] menggunakan beberapa lapisan dari MobileNetV2 yang dijadikan lapisan encoder pada U-Net untuk kasus polyp segmentation.

Konstumasi lain seperti pada penelitian [20], [21] yang menggunakan lapisan pada model DenseNet untuk membangun lapisan encoder pada U-Net dengan tujuan untuk mendapatkan hasil segmentasi yang lebih baik dibandingkan dengan menggunakan arsitektur encoder dasar dari U-Net. Penelitian lainnya [22] menggabungkan metode segmentasi berbasis deep learning dengan metode watershed untuk memberi warna yang berbeda pada area sel yang terlihat sama dan bergerombol setelah garis tepi setiap sel berhasil dideteksi melalui proses segmentasi dengan deep learning. Sehingga penelitian kami akan menggabungkan metode deep learning dengan metode watershed guna mendeteksi dan memisahkan 2 sel yang saling tumpang tindih pada citra Pap Smear dengan menggunakan dataset yang didapatkan dari RepoMedUNM. Contoh dari dataset RepoMedUNM dapat dilihat pada Gambar 1.



Gambar 1. Sampel dataset *RepoMedUNM Citra Normal Papsmear*

2. Metodologi Penelitian

2.1 Dataset

Repository medical image processing of UNM (RepomedUNM) adalah repository citra biomedical Pap smear yang dibuat oleh Universitas Nusa Mandiri. Repository ini menyediakan 6.168 dataset digital citra Pap smear dengan tujuan untuk menyediakan dataset

publik yang dapat digunakan oleh para peneliti dalam mengembangkan metode skrining yang lebih efektif untuk deteksi dini kanker serviks secara otomatis dengan menggunakan bantuan teknologi komputer [23]. Metode pengambilan slide yang digunakan oleh ahli patologi terbagi menjadi 2 yaitu dengan metode tes ThinPrep yang menghasilkan 3 kategori citra sel yaitu normal, koilocyt serta H-Sil dan metode tes non-ThinPrep yang menghasilkan 2 kategori citra sel yaitu normal dan L-Sil [24].

2.2 Citra Sintetis

Pembuatan citra sintetis yang dilakukan menggunakan dataset citra Pap smear RepomedUNM [23] dengan kondisi bergerombol ataupun tunggal. Pembuatan citra sintetis ini terinspirasi dari penelitian yang telah dilakukan [25] dengan menggunakan dataset The First Affiliated Hospital of Guangzhou University of Chinese Medicine serta penelitian [12] dengan menggunakan dataset ISBI 2014 [26]. Dataset citra yang digunakan pada penelitian ini menggunakan slide Pap smear dalam kondisi normal dan koilocyt. Dengan menggunakan software pengolah citra maka objek sel yang saling bergabung dengan sel lain pada sebuah slide Pap smear diseleksi untuk kemudian diambil dan dilakukan penggabungan dengan objek sel yang lain. Hasil dari penggabungan ini akan membentuk 2 sel yang saling tumpang tindih dalam 1 citra dengan ukuran 512 x 512 piksel. Selain pembuatan citra sintetis, maka dilakukan juga pembuatan citra label dalam bentuk tumpang tindih yang berfungsi sebagai label ketika proses training dilakukan dengan menggunakan U-Net.

2.3 U-Net.

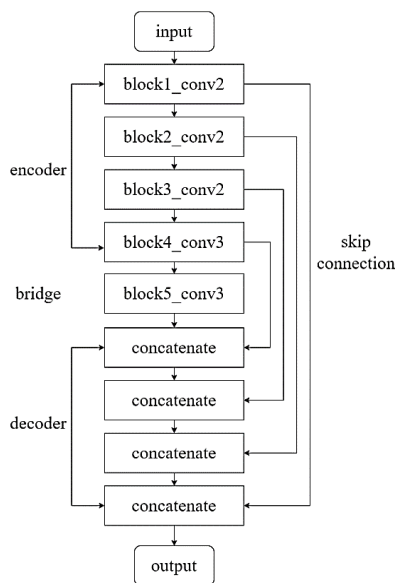
U-Net merupakan metode segmentasi semantic maka citra label yang dibuat harus memiliki warna dengan nilai piksel yang konsisten untuk mewakili setiap area pada citra. Nilai piksel yang digunakan terdiri dari 3 warna yaitu hitam $\text{rgb}(0,0,0)$ untuk mewakili area latar belakang, abu-abu $\text{rgb}(127,127,127)$ untuk mewakili area tepi pada sel, serta warna putih $\text{rgb}(255,255,255)$ untuk mewakili area sel [27][28]. Verifikasi pada hasil pemisahan sel digunakan citra label sel tunggal dengan warna hitam $\text{rgb}(0,0,0)$ untuk mewakili area latar belakang dan warna putih $\text{rgb}(255,255,255)$ untuk mewakili area sel.

Segmentasi tahap awal bertujuan untuk mendeteksi area latar belakang, area garis tepi dan area sel pada citra. Hasil keluaran dari proses ini berupa fiturmap yang selanjutnya dapat diolah lagi dengan metode Watershed untuk memberi warna yang berbeda pada setiap area yang berhasil dideteksi oleh U-Net, penggunaan model transfer learning memiliki tujuan agar model yang dikembangkan memiliki pengetahuan yang lebih baik karena terdapat proses transfer pengetahuan dari model pretrain yang digunakan [29]. Penelitian ini mengujicoba 3 model transfer learning sebagai encoder U-Net yaitu VGG16, DenseNet121 dan MobileNetV2. Meskipun pada bagian encoder yang digunakan

menggunakan model transfer learning namun secara garis besar cara kerja yang dilakukan tetap sama, yaitu pada setiap lapisan convolution di bagian encoder akan melakukan proses pooling yang kemudian dilanjutkan dengan proses up sampling pada bagian decoder hingga menghasilkan keluaran citra segmentasi pada bagian akhir lapisannya.

2.3.1 VGG-UNet

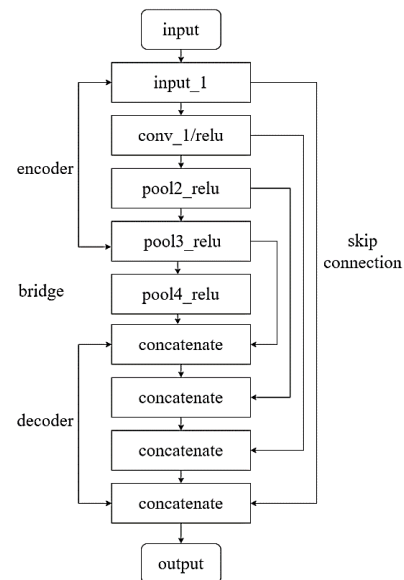
Desain model U-Net dengan menggunakan 4 lapisan pada VGG16 sebagai encoder yaitu block1_conv2, block2_conv2, block3_conv2 dan block4_conv3 serta block5_conv3 untuk digunakan pada bagian bridge sehingga jumlah lapisan yang digunakan adalah 5. Salah satu karakteristik dari VGG16 adalah penggunaan maxpooling pada setiap block yang dimiliki [30]. Struktur model ini secara ringkas ditunjukkan pada Gambar 2.



Gambar 2. Desain VGG-UNet

2.3.2 Dense-UNet

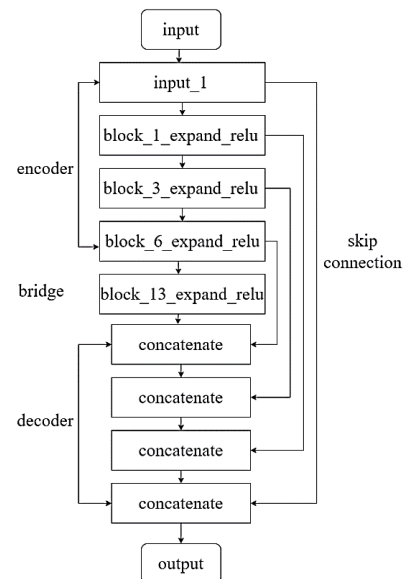
Desain U-Net dengan DenseNet121 menggunakan 4 lapisan DenseNet yaitu input_1, conv_1/relu, pool2_relu dan pool3_relu dan 1 block yaitu pool4_relu untuk mengisi bagian bridge. Salah satu karakteristik dari DenseNet121 adalah penggunaan average pooling pada setiap dense block yang dimiliki, ketika proses penggabungan setiap lapisan menerima feature map dari semua lapisan sebelumnya hingga jaringannya menjadi lebih kecil dan tipis [18]. Setelah beberapa block dense yang ada digunakan sebagai encoder U-Net maka struktur model ini secara ringkas dapat dilihat pada Gambar 3.



Gambar 3. Desain Dense-UNet

2.3.3 Mobile-UNet

Desain U-Net dengan menggunakan 4 lapisan MobileNetV2 sebagai encoder yaitu input_1, block_1_expand_relu, block_3_expand_relu dan block_6_expand_relu dan 1 block block_13_expand_relu sebagai bridge pada struktur U-Net yang dibangun. Sehingga struktur model ini secara ringkas dapat dilihat pada Gambar 4.



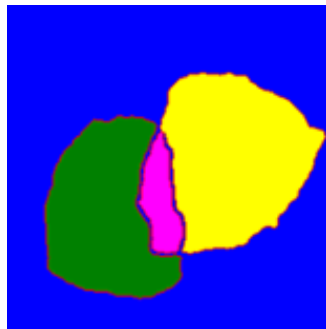
Gambar 4. Desain Mobile-UNet

2.4 Segmentasi Watershed

Setelah segmentasi tahap pertama berhasil dilakukan dengan menggunakan U-Net maka tahap selanjutnya adalah segmentasi dengan menggunakan watershed. Hal ini dilakukan untuk memberikan warna yang berbeda pada setiap area yang berhasil dideteksi pada segmentasi tahap pertama. Konsep ini merepresentasikan sebuah objek sebagai sebuah

punggung bukit dan lembah, nilai elevasi lankap biasanya ditentukan oleh nilai abu-abu dari masing-masing piksel atau besaran gradiennya. Nilai intensitas tinggi menunjukkan sebuah bukit sedangkan intensitas yang rendah menunjukkan sebuah lembah sehingga Metode ini akan membagi wilayah-wilayah berdasarkan minima wilayahnya [31]. Penggabungan metode watershed dengan metode segmentasi berbasis deep learning pada penelitian ini terinspirasi dari penelitian yang dilakukan oleh W. Wang [22] yang menggunakan metode ini untuk memberi warna yang berbeda pada setiap sel setelah proses fitur map didapatkan dari segmentasi menggunakan Metode Deep Learning.

Proses dengan metode Watershed melakukan setiap area yang ada pada sel dapat diberi warna yang berbeda sehingga dapat lebih mudah untuk dipisahkan. Hasil segmentasi dengan menggunakan metode watershed ditampilkan pada Gambar 5. Setelah area pada citra berhasil dipisahkan maka hasil segmentasi citra tunggal bisa didapatkan dengan melakukan penyeleksian nilai piksel citra dan kemudian dihitung keberhasilan pemisahannya dengan menggunakan IoU.



Gambar 5. Hasil Pemberian dengan 3 Warna

2.5 Evaluasi Hasil

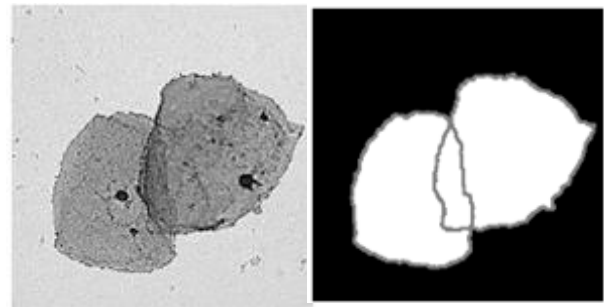
Untuk mengevaluasi hasil segmentasi dengan menggunakan U-Net digunakan 2 metrik yaitu Intersection over Union (IoU) pada Persamaan (1). IoU digunakan untuk membandingkan kesamaan antara 2 bentuk data. IoU mengkodekan properti bentuk dari objek yang dibandingkan seperti lebar, tinggi dan posisi kedalam sebuah properti wilayah [32], [33].

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

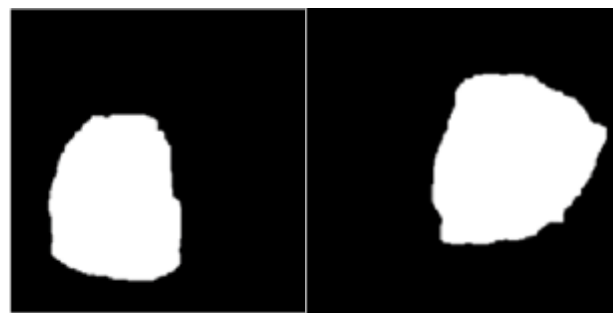
3. Hasil dan Pembahasan

Penelitian ini telah menghasilkan sebanyak 420 dataset citra sintetis dalam bentuk 2 sel tumpang tindih beserta dengan citra label dalam bentuk tumpang tindih, dataset yang ada kemudian diaugmentasi dengan membalikkan citra ke arah kanan dan bawah untuk menambah variasi citra yang dapat dipelajari oleh model segmentasi yang dibangun [34] sehingga dataset yang dimiliki bertambah

jumlahnya menjadi 1.260 citra. Dataset citra input dan label dalam bentuk tumpang tindih diubah resolusinya menjadi 256 x 256 untuk mengurangi beban komputasi ketika proses training dilakukan. Skenario yang digunakan pada setiap desain U-Net yang telah dibangun adalah penggunaan epoch sebanyak 50, dengan hyperparameter optimizer Adam, learning_rate 0.0005, beta_1 0.9, beta_2 0.999, epsilon 1e-07 dan ukuran batchsize 8 dengan komposisi 80% (1008 citra) data training dan 20% (252 citra) data testing. Salah satu citra uji disajikan pada Gambar 6 dan Gambar 7.



Gambar 6. Hasil Pembuatan Citra Tumpang Tindih, (a) Sintetis, (b) Citra Label



Gambar 7. Hasil Citra Label Tunggal, (a) Sel 1, (b). Sel 2

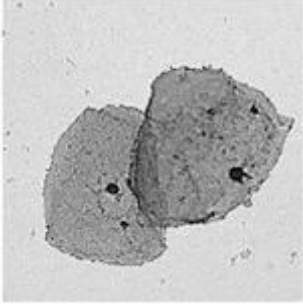

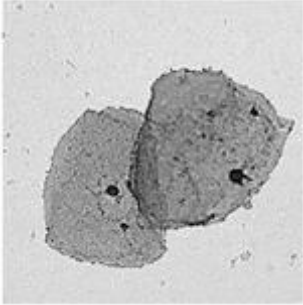

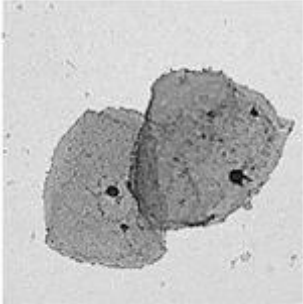
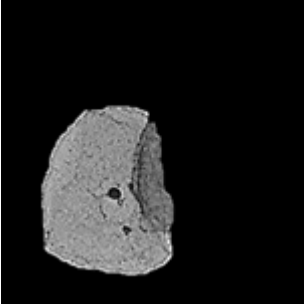
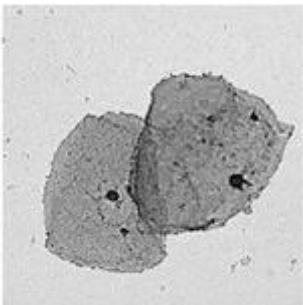
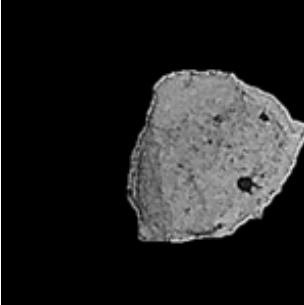
Akurasi terhadap ketiga model U-Net yang digunakan disajikan pada Tabel 1.

Tabel 1. Hasil Akurasi Pengujian

Model	IoU
VGG-UNet	0.9061
Dense-UNet	0.9014
Mobile-UNet	0.8934
Rata-rata	0.9003

Dengan akurasi yang didapatkan dari ketiga model arsitektur U-Net maka dipilih segmentasi VGG-UNet dengan 252 citra testing yang digunakan pada proses segmentasi selanjutnya oleh Metode Watershed untuk mendapatkan sel hasil pemisahan. Citra hasil pemisahan yang disajikan pada artikel disajikan secara lengkap hingga hasil overlay dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pemisahan dan Overlay Citra Sel Papsmear

Kondisi Awal	Hasil Proses
	
Citra asli	Pemisahan 1
	
Citra asli	Pemisahan 2
	
Citra asli	Overlay1
	
Citra asli	Overlay2

4. Kesimpulan

Penelitian ini berhasil mengusulkan sebuah metode yang dapat memisahkan 2 objek sel tumpang tindih pada citra Pap Smear. Hasil eksperimen yang dilakukan menunjukkan bahwa VGG-UNet mampu mengungguli Dense-UNet dan juga Mobile-UNet untuk kasus multiclass segmentation sel serviks pada citra Pap Smear dengan skor rata-rata IoU sebesar 0,9061. Metode Watershed yang dipadukan dengan metode U-Net terbukti mampu memisahkan setiap area yang ada

pada citra dengan memberi penanda berupa warna yang berbeda untuk bagian latar belakang, sel dan juga area tumpang tindih sel serviks. Sehingga penelitian ini dapat dijadikan rujukan dalam pemisahan objek sel umpang tindih Kanker Serviks.

Daftar Rujukan

- [1] Rio, S., & Suci, E. S. T. (2017). Persepsi tentang kanker serviks dan upaya prevensinya pada perempuan yang memiliki keluarga dengan riwayat kanker. *Jurnal Kesehatan Reproduksi*, 4(3), 159-169. doi: 10.22146/jkr.36511

- [2] Wantini, N. A., & Indrayani, N. (2019). Deteksi dini kanker serviks dengan inspeksi visual asam asetat (IVA). *Jurnal Ners dan Kebidanan (Journal of Ners and Midwifery)*, 6(1), 027-034. doi: 10.26699/jnk.v6i1.ART.p027
- [3] Riana, D., & Hidayanto, A. N. (2017, August). Integration of Bagging and greedy forward selection on image Pap Smear classification using Naïve Bayes. In 2017 5th *International Conference on Cyber and IT Service Management (CITSM)* (pp. 1-7). IEEE. doi: 10.1109/CITSM.2017.8089320
- [4] Hidayatulloh, T., Herliana, A., & Arifin, T. (2016). Klasifikasi sel tunggal Pap Smear berdasarkan analisis fitur berbasis naive bayes classifier dan particle swarm optimization. *Swabumi*, 4(2), 186-193.
- [5] Pasrun, Y. P., Fatchah, C., & Suciati, N. (2016). Penggabungan Fitur Bentuk dan Fitur Tekstur yang Invariant terhadap Rotasi untuk Klasifikasi Citra Pap Smear. *Jurnal Buana Informatika*, 7(1). doi: 10.24002/jbi.v7i1.479
- [6] Husain, N. P., & Fatchah, C. (2017). Segmentasi Citra Sel Tunggal Smear Serviks Menggunakan Radiating Component Normalized Generalized GVFS. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 6(1), 107-114.
- [7] Zhao, M., Wang, H., Han, Y., Wang, X., Dai, H. N., Sun, X., ... & Pedersen, M. (2021). Seens: Nuclei segmentation in Pap Smear images with selective edge enhancement. *Future Generation Computer Systems*, 114, 185-194. doi: 10.1016/j.future.2020.07.045
- [8] Braz, E. F., & Lotufo, R. D. A. (2017). Nuclei detection using deep learning. In *Proc. Simpósio Brasileiro Telecomunicações Processamento Sinais* (pp. 1059-1063). doi: 10.14209/sbrt.2017.48
- [9] Gautam, S., Bhavsar, A., Sao, A. K., & Harinarayan, K. K. (2018, March). CNN based segmentation of nuclei in PAP-smear images with selective pre-processing. In *Medical Imaging 2018: Digital Pathology* (Vol. 10581, pp. 246-254). SPIE. doi: 10.1117/12.2293526
- [10] Harangi, B., Toth, J., Bogacsovics, G., Kupas, D., Kovacs, L., & Hajdu, A. (2019, September). Cell detection on digitized Pap Smear images using ensemble of conventional image processing and deep learning techniques. In 2019 *11th International Symposium on Image and Signal Processing and Analysis (ISPA)* (pp. 38-42). IEEE. doi: 10.1109/ISPA.2019.8868683
- [11] Araújo, F. H., Silva, R. R., Ushizima, D. M., Rezende, M. T., Carneiro, C. M., Bianchi, A. G. C., & Medeiros, F. N. (2019). Deep learning for cell image segmentation and ranking. *Computerized Medical Imaging and Graphics*, 72, 13-21. doi: 10.1016/j.compmedimag.2019.01.003
- [12] Mahyari, T. L., & Dansereau, R. M. (2021, January). Deep Learning Methods for Image Decomposition of Cervical Cells. In 2020 28th *European Signal Processing Conference (EUSIPCO)* (pp. 1110-1114). IEEE. doi: 10.23919/Eusipco47968.2020.9287435
- [13] Kupas, D., & Harangi, B. (2021, November). Solving the problem of imbalanced dataset with synthetic image generation for cell classification using deep learning. In 2021 43rd *Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 2981-2984). IEEE. doi: 10.1109/EMBC46164.2021.9631065
- [14] Ibtehaz, N., & Rahman, M. S. (2020). MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural networks*, 121, 74-87. doi: 10.1016/j.neunet.2019.08.025
- [15] Iglovikov, V., & Shvets, A. (2018). Terausnet: U-net with vgg11 encoder pre-trained on imagenet for image segmentation. *arXiv preprint arXiv:1801.05746*. [Online]. Available: <http://arxiv.org/abs/1801.05746>
- [16] Cheng, D., & Lam, E. Y. (2021). Transfer learning U-Net deep learning for lung ultrasound segmentation. *arXiv preprint arXiv:2110.02196*. [Online]. Available: <http://arxiv.org/abs/2110.02196>
- [17] Pravitasari, A. A., Iriawan, N., Almuhyar, M., Azmi, T., Irfamah, I., Fithriasari, K., ... & Ferriastuti, W. (2020). UNet-VGG16 with transfer learning for MRI-based brain tumor segmentation. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 18(3), 1310-1318. doi: 10.12928/TELKOMNIKA.v18i3.14753
- [18] Cui, B., Chen, X., & Lu, Y. (2020). Semantic segmentation of remote sensing images using transfer learning and deep convolutional neural network with dense connection. *IEEE Access*, 8, 116744-116755. doi: 10.1109/ACCESS.2020.3003914
- [19] Branch, M. V., & Carvalho, A. S. (2021). Polyp Segmentation in Colonoscopy Images using U-Net-MobileNetV2. *arXiv preprint arXiv:2103.15715*.
- [20] Li, X., Chen, H., Qi, X., Dou, Q., Fu, C. W., & Heng, P. A. (2018). H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes. *IEEE transactions on medical imaging*, 37(12), 2663-2674. doi: 10.1109/TMI.2018.2845918
- [21] Wei, Z., Song, H., Chen, L., Li, Q., & Han, G. (2019). Attention-based DenseUnet network with adversarial training for skin lesion segmentation. *IEEE Access*, 7, 136616-136629. doi: 10.1109/ACCESS.2019.2940794
- [22] Wang, W., Taft, D. A., Chen, Y. J., Zhang, J., Wallace, C. T., Xu, M., ... & Xing, J. (2019). Learn to segment single cells with deep distance estimator and deep cell detector. *Computers in biology and medicine*, 108, 133-141. doi: 10.1016/j.compbiomed.2019.04.006
- [23] Riana, D., Rahayu, S., Hadianiti, S., Friyadie, F., Hasan, M., Karimah, I. N., & Pratama, R. (2022). Identifikasi Citra Pap Smear RepoMedUNM dengan Menggunakan K-Means Clustering dan GLCM. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(1), 1-8. doi: 10.29207/resti.v6i1.3495
- [24] Riana, D., Hadianiti, S., Rahayu, S., Hasan, M., Karimah, I. N., & Pratama, R. (2021, December). RepoMedUNM: A New Dataset for Feature Extraction and Training of Deep Learning Network for Classification of Pap Smear Images. In *International Conference on Neural Information Processing* (pp. 317-325). Springer, Cham. doi: 10.1007/978-3-030-92307-5_37
- [25] Zhang, J., Hu, Z., Han, G., & He, X. (2016). Segmentation of overlapping cells in cervical smears based on spatial relationship and overlapping translucency light transmission model. *Pattern recognition*, 60, 286-295. doi: 10.1016/j.patcog.2016.04.021
- [26] Lu, Z., Carneiro, G., Bradley, A. P., Ushizima, D., Nosrati, M. S., Bianchi, A. G., ... & Hamarneh, G. (2016). Evaluation of three algorithms for the segmentation of overlapping cervical cells. *IEEE journal of biomedical and health informatics*, 21(2), 441-450. doi: 10.1109/JBHI.2016.2519686
- [27] Siddique, N., Paheding, S., Elkin, C. P., & Devabhaktuni, V. (2021). U-net and its variants for medical image segmentation: A review of theory and applications. *IEEE Access*, 9, 82031-82057. doi: 10.1109/ACCESS.2021.3086020
- [28] Du, G., Cao, X., Liang, J., Chen, X., & Zhan, Y. (2020). Medical image segmentation based on u-net: A review. *Journal of Imaging Science and Technology*, 64, 1-12. doi: 10.2352/J.ImagingSci.Technol.2020.64.2.020508
- [29] Adiba, A., Hajji, H., & Maatouk, M. (2019, March). Transfer learning and U-Net for buildings segmentation. In *Proceedings of the New Challenges in Data Sciences: Acts of the Second Conference of the Moroccan Classification Society* (pp. 1-6). doi: 10.1145/3314074.3314088

- [30] Karthick, R. (2018). Deep Learning For Age Group Classification System. *International Journal Of Advances In Signal And Image Sciences*, 4(2), 16-22. doi: 10.29284/ijasis.4.2.2018.16-22
- [31] McAuliffe, M. J., Lalonde, F. M., McGarry, D., Gandler, W., Csaky, K., & Trus, B. L. (2001, July). Medical image processing, analysis and visualization in clinical research. In *Proceedings 14th IEEE Symposium on Computer-Based Medical Systems. CBMS 2001* (pp. 381-386). IEEE. doi: 10.1109/CBMS.2001.941749
- [32] Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 658-666). doi: 10.1109/CVPR.2019.00075
- [33] Arora, R., Saini, I., & Sood, N. (2021). Multi-label segmentation and detection of COVID-19 abnormalities from chest radiographs using deep learning. *Optik*, 246, 167780. doi: 10.1016/j.ijleo.2021.167780
- [34] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48. doi: 10.1186/s40537-019-0197-0