

**SEGMENTASI SEMANTIK CITRA *PAP SMEAR* MENGGUNAKAN
KOMBINASI ARSITEKTUR *FULLY CONVOLUTIONAL NETWORK*,
RESIDUAL BLOCK DAN *U-NET* (FCRU-NET)**

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Sains Bidang Studi Matematika**

Oleh :

RIRIN SAGITA

NIM 08011181823106



JURUSAN MATEMATIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

TAHUN 2022

HALAMAN PENGESAHAN

**SEGMENTASI SEMANTIK CITRA *PAP SMEAR* MENGGUNAKAN KOMBINASI
ARSITEKTUR *FULLY CONVOLUTIONAL NETWORK*, *RESIDUAL BLOCK* DAN *U-
NET* (FCRU-NET)**

SKRIPSI

Sebagai Salah Satu Syarat untuk Memperoleh Gelar

Sarjana Sains Bidang Studi Matematika

Oleh :

**RIRIN SAGITA
NIM 08011181823106**

Indralaya, Agustus 2022

Pembimbing Kedua



**Anita Desiani, S.SI., M.Kom
19771211 200312 2 002**

Pembimbing Utama



**Drs. Sugandi Yahdin, M.M
19580727 198603 1 003**

**Mengetahui,
Ketua Jurusan Matematika**



**Drs. Sugandi Yahdin, M.M
19580727 198603 1 003**

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini:

Nama Mahasiswa : Ririn Sagita
NIM : 08011181823106
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain.

Semua informasi yang dimuat dalam skripsi ini yang berasal dari penulis lain baik yang dipublikasikan atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 24 Agustus 2023

Penulis



Ririn Sagita

NIM. 08011181823016

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku tersayang,

Adik-adikku tercinta,

Keluarga besarku,

Semua guru dan dosenku,

Sahabat-sahabatku,

Almamaterku

Moto

“Habis gelap terbitlah terang”

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Segala puji dan syukur kehadirat Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya yang senantiasa dilimpahkan kepada penulis, sehingga dapat menyelesaikan skripsi ini dengan judul *SEGMENTASI SEMANTIK CITRA PAP SMEAR MENGGUNAKAN KOMBINASI ARSITEKTUR FULLY CONVOLUTIONAL NETWORK, RESIDUAL BLOCK DAN U-NET (FCRU-NET)*.

Dengan segala hormat dan kerendahan hati mengucapkan terima kasih yang sedalam-dalamnya kepada Orang Tua, yaitu **Bapak Hartono** dan **Ibu Imro'atun Hartati** yang telah merawat dan mendidik penulis dengan penuh rasa cinta dan kasih sayang, doa dan perhatiannya untuk penulis selama ini. Skripsi ini dapat selesai tidak terlepas dari bantuan berbagai pihak, baik secara langsung maupun tidak langsung. Untuk itu penulis menyampaikan ucapan terima kasih dan penghargaan kepada :

1. **Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya.**
2. **Drs. Sugandi Yahdin, M.M** selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, Pembimbing Utama, serta Pembimbing Akademik yang bersedia membimbing penulis dan **Dr. Dian Cahyawati Sukanda, M.Si** selaku Sekretaris Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya yang telah

membimbing dan mengarahkan urusan akademik kepada penulis selama belajar di Jurusan Matematika FMIPA Universitas Sriwijaya.

3. Ibu **Anita Desiani, M.Kom** selaku Dosen Pembimbing yang bersedia membimbing, nasihat, saran, dan meluangkan waktu di tengah kesibukannya.

4. Bapak **Dr. Bambang Suprihatin, M.Si**, dan Ibu **Novi Rustiana Dewi, M.Si**, selaku dosen pembahas skripsi yang telah bersedia meluangkan waktu dalam memberikan tanggapan dan saran yang bermanfaat dalam perbaikan skripsi.

5. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika Dan Ilmu Pengetahuan Alam Universitas Sriwijaya**, dan seluruh pendidik yang telah memberikan ilmu yang sangat bermanfaat kepada penulis selama menempuh pendidikan.

6. Ibu **Hamidah** dan Pak **Irwan** di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya, terima kasih atas bantuannya yang telah diberikan kepada penulis.

7. Adikku yang selalu mendukung, **Rayna** dan **Reza** atas kasih sayang nya.

8. Keluarga Besarku terima kasih untuk segala dukungan dan semangat yang telah diberikan kepada penulis.

9. **Seluruh Guru** yang telah memberikan ilmu yang bermanfaat hingga mengantarkan penulis pada pendidikan ini.

10. **Semua sahabat seperjuangan penulis, dalam masa perkuliahan dan perskripsian** terima kasih sudah menjadi orang-orang baik di sekeliling penulis, selalu mendukung, membantu dengan tulus, dan memberi energi positif.

11. **Keluarga Matematika 2018, BPH Himastik Tahun 2019-2020 dan BPH DPM KM FMIPA Tahun 2020-2021** atas pengalaman, dukungan serta canda dan tawa yang diberikan selama berada dalam lingkungan organisasi.

12. **Kakak-kakak tingkat angkatan 2016 dan 2017** bidang minat komputasi yang telah banyak membantu serta berbagi ilmu selama proses skripsi.

13. **Kakak-kakak tingkat angkatan 2016 dan 2017** serta adik-adik tingkat **angkatan 2019 dan 2020**, terima kasih atas segala kebaikan dan bantuan.

14. Semua pihak yang tidak dapat penulis sebutkan satu per satu. Semoga segala kebaikan yang diberikan mendapatkan balasan terbaik dari Allah.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/mahasiswi Jurusan Matematika Fakultas dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan semua pihak yang memerlukan.

Indralaya, Juli 2022

Penulis

**SEMANTIC SEGMENTATION OF PAP SMEAR IMAGE USING
COMBINATION FULLY CONVOLUTIONAL NETWORK, RESIDUAL
BLOCK DAN U-NET**

By :

Ririn Sagita

08011181823106

ABSTRACT

Deep layer of u-net architecture results in increased parameters and network complexity. Residual block has the ability to skip connection a few blocks and take an average score so that it can reduce the complexity of the network with accurate performance, but this architecture is used for image classification. Fully convolutional network architecture (FCN) is a simpler architecture and prevents overfitting due to excessive parameters. In this study there will be a combination of FCN architecture and residual block on u-net architecture to create new, more simple and accurate architecture in the segmentation pap smear image. The results of this architecture obtained 92,20% accuracy performance, sensitivity by 77,74% , 94,23% of spesificity, f1-score by 77,90% and IoU by 66,57% using herlev datassets. The result could be concluded that the architecture advanced has done pap smear image segments and predicts the background well shown with accuracy and specificity above 90%. The architecture can predict the characteristics of the nucleus, the cytoplasm and the thin cytoplasm with quite well viewed from sensitivity values above 70%, and the balance between sensitivity values and specificity is good enough to be seen from the value of F1-score above 70%, but the similarities between the image of the segmentation and the groundtruth are still quite low enough to be seen from IoU score less than 70%. Based on these results, it shows that proposed architecture is capable of pap smear image segmentation.

Keyword : Semantic Segmentation, Pap Smear, U-Net, Residual Block, FCN

**SEGMENTASI SEMANTIK CITRA *PAP SMEAR* MENGGUNAKAN
KOMBINASI ARSITEKTUR *FULLY CONVOLUTIONAL NETWORK*,
RESIDUAL BLOCK DAN *U-NET* (FCRU-NET)**

Oleh :

Ririn Sagita

08011181823106

ABSTRAK

Lapisan dalam arsitektur U-Net mengakibatkan peningkatan parameter dan kompleksitas jaringan. *Residual block* memiliki kemampuan melakukan pintasan pada beberapa blok dan mengambil nilai rata-rata sehingga dapat mengurangi kompleksitas jaringan dengan kinerja akurat, namun arsitektur ini biasa digunakan untuk klasifikasi Gambar. Arsitektur *Fully Convolutional Network* (FCN) merupakan arsitektur yang lebih sederhana dan dapat menghindari terjadinya *overfitting* akibat parameter berlebih. Dalam penelitian ini akan dilakukan kombinasi arsitektur FCN dan *residual block* pada arsitektur U-Net untuk menghasilkan arsitektur baru yang lebih sederhana dan akurat dalam segmentasi citra *pap smear*. Penelitian tersebut memperoleh kinerja akurasi sebesar 92,20%, sensitivitas sebesar 77,74%, spesifisitas sebesar 94,23%, *F1-score* sebesar 77,90% dan IoU sebesar 66,57% menggunakan dataset *Herlev*. Dari hasil tersebut dapat disimpulkan bahwa arsitektur yang diajukan telah berhasil melakukan segmentasi citra *pap smear* dan memprediksi *background* dengan sangat baik yang ditunjukkan dengan nilai akurasi dan spesifitas di atas 90%. Arsitektur ini dapat memprediksi fitur nukleus, sitoplasma dan sitoplasma tipis dengan cukup baik dilihat dari nilai sensitivitas di atas 70%, dan keseimbangan antara nilai sensitivitas dan spesifisitas sudah cukup baik dilihat dari nilai *F1-Score* di atas 70%, akan tetapi kemiripan antara citra hasil segmentasi dan *ground truth* masih cukup rendah dilihat dari nilai IoU di bawah 70%. Berdasarkan hasil kinerja tersebut, arsitektur yang diusulkan sudah cukup baik dalam segmentasi citra *pap smear*.

Kata kunci : Segmentasi Semantik, Pap Smear, *U-Net*, *Residual Block*, FCN

DAFTAR ISI

HALAMAN PENGESAHAN	i
HALAMAN PERSEMBAHAN	iii
KATA PENGANTAR.....	iv
ABSTRACT.....	vii
ABSTRAK.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xi
DAFTAR GAMBAR	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	4
1.3 Pembatasan Masalah	5
1.4 Tujuan	5
1.5 Manfaat.....	5
BAB II TINJAUAN PUSTAKA	6
2.1 Citra Digital.....	6
2.2 <i>Augmentasi Data</i>	7
2.3 <i>Preprocessing Citra : Gaussian Blur</i>	8
2.4 Segmentasi Citra	9
2.5 <i>Convolutional Neural Network (CNN)</i>	9
2.6 U-Net	15
2.7 <i>Residual Block</i>	16
2.8 <i>Fully Convolutional Network</i>	17
2.9 <i>Categorical Cross Entropy</i>	18
2.10 <i>Adam Optimizer</i>	18
2.11 <i>Confusion Matriks</i>	20
BAB III METODOLOGI PENELITIAN	23
3.1 Tempat.....	23
3.2 Waktu.....	23
3.3 Alat	23

3.4 Metode Penelitian.....	24
BAB IV HASIL DAN PEMBAHASAN.....	29
4.1 Deskripsi Data.....	29
4.2 Augmentasi data.....	30
4.3 <i>Preprocessing</i> data : <i>Gaussian Blur</i>	31
4.4 Implementasi arsitektur <i>FCN Residual Block</i> dan <i>U-Net</i>	34
4.5 Operasi Manual pada <i>Convolutional Neural Network (CNN)</i>	37
4.6 <i>Training</i>	53
4.7 <i>Testing</i>	55
4.8 Evaluasi	59
4.9 Analisis Hasil.....	62
BAB V KESIMPULAN DAN SARAN.....	64
5.1 Kesimpulan.....	64
5.2 Saran	64
DAFTAR PUSTAKA.....	65

DAFTAR TABEL

Tabel 2.1 Kategori pada kinerja model.....	21
Tabel 4.1 Sampel Citra Asli Pada Dataset Herlev.....	29
Tabel 4.2. Perbandingan Citra Asli, Hasil Segmentasi, dan <i>Ground Truth</i>	55
Tabel 4.3 <i>Confusion Matrix Multiclass</i> dari Proses <i>Testing</i>	56
Tabel 4.4 Perbandingan Hasil Kinerja Terhadap Segmentasi 4 Label.....	60
Tabel 4.5 Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lain.....	6

DAFTAR GAMBAR

Gambar 2.1 Representasi Citra Digital.....	6
Gambar 2.2 Nukleus Pada Citra Pap Smear.....	7
<i>Gambar 2.3 Ilustrasi Convolutional Layer.....</i>	<i>10</i>
Gambar 2.4 Representasi <i>max pooling</i>	11
<i>Gambar 2.5 Ilustrasi Transposed Convolution dengan matriks kernel 2×2.....</i>	<i>14</i>
Gambar 2.6 Ilustrasi <i>concatenate layer</i>	14
Gambar 2.7 Ilustrasi Arsitektur U-Net.....	15
Gambar 2.8 Ilustrasi <i>additive skip connection layer</i>	16
Gambar 2.9 Ilustrasi Arsitektur FCN.....	17
Gambar 2.10 <i>Confusion Matrix Multiclass</i>	20
Gambar 3.1 <i>Vertical Flip</i>	25
Gambar 3.2 <i>Horizontal Flip</i>	25
Gambar 4.1 Citra <i>Pap Smear</i> , dan <i>groundtruth</i>	30
Gambar 4.2 Hasil <i>Preprocessing</i> (a) Citra Asli (b) <i>Gaussian blur</i>	32
Gambar 4.3 Kombinasi Arsitektur FCRU-Net.....	34
Gambar 4.4 Hasil <i>Training</i>	52
Gambar 4.5 Grafik Akurasi Proses Training.....	53
Gambar 4.6 Grafik <i>Loss</i> Proses Training.....	54
Gambar 4.6 Grafik <i>Loss</i> Proses Training.....	62

BAB I

PENDAHULUAN

1.1 Latar Belakang

Kanker serviks adalah salah satu jenis kanker yang terjadi karena adanya sel abnormal pada leher rahim wanita (Hussain *et al.*, 2020). Kanker serviks dapat dikendalikan dengan beberapa metode, salah satunya adalah pemeriksaan *pap smear* (Wafa & Ouadfel, 2019). *Pap smear* merupakan pemeriksaan dini pada sel tunggal yang mendeteksi kelainan nukleus dan sitoplasma (Hussain *et al.*, 2020). Pemeriksaan *pap smear* secara manual dapat dilakukan melalui pengamatan langsung (Hussain *et al.*, 2020). Pengamatan manual terkadang bersifat subjektif dan membutuhkan keahlian yang tinggi sehingga rentan terhadap kesalahan (Win & Choomchuay, 2017). Hal ini dibutuhkan sistem diagnosa otomatis pada hasil pemeriksaan *pap smear* dengan bantuan komputer untuk memudahkan para ahli dalam mendiagnosa kanker serviks. Salah satu sistem diagnosa untuk mendeteksi kelainan pada nukleus dan sitoplasma adalah dengan melakukan segmentasi pada bagian yang dibutuhkan dalam deteksi kanker serviks (L. Zhang *et al.*, 2014). Citra *pap smear* terdiri dari sitoplasma, sitoplasma tipis, nukleus dan *background* (L. Zhang *et al.*, 2014).

Salah satu metode segmentasi citra yang saat ini berkembang adalah *Deep learning* (DL). DL merupakan metode pembelajaran mesin dengan meniru kerja jaringan saraf tiruan (LeCun *et al.*, 2015). Salah satu metode *deep learning* yang sering digunakan dalam segmentasi adalah *Convolutional Neural Network* (CNN) (LeCun *et al.*, 2015). CNN merupakan metode jaringan saraf tiruan dalam

pengenalan dan pemrosesan Gambar untuk memproses data piksel (Kayalibay *et al.*, 2017). Salah satu arsitektur CNN yang banyak digunakan untuk segmentasi yaitu *U-Net*. Keuntungan penggunaan arsitektur *U-Net* adalah kemampuan dalam prediksi piksel yang akurat dan banyak digunakan dalam segmentasi semantik (Khryashchev *et al.*, 2019).

Beberapa penelitian telah menunjukkan hasil yang baik pada segmentasi *pap smear* menggunakan arsitektur *U-Net* diantaranya adalah Huang *et al.*, (2019) melakukan segmentasi citra *pap smear* menggunakan *U-Net* menghasilkan akurasi 91,5% dan sensitivitas diatas 90%. Zhang *et al.*, (2020) menggunakan *Attention U-Net* pada segmentasi citra *pap smear* menghasilkan akurasi 91,7% dan sensitifitas 93%. Long, (2020) melakukan segmentasi citra *pap smear* dengan modifikasi *U-Net* menghasilkan akurasi 90,5% dan F1-score lebih dari 75%. Sayangnya ketiga penelitian ini hanya melakukan segmentasi 3 label yaitu pada fitur nukleus, sitoplasma dan *background*. Kelainan pada sel tunggal lebih akurat dengan melakukan segmentasi pada 4 label yaitu sitoplasma, sitoplasma tipis, nukleus dan *background* (L. Zhang *et al.*, 2014)..

Arsitektur *U-Net* terdiri dari 3 bagian yaitu *encoder* yang terdiri dari *downsampling layer*, *bridge* yang terdiri dari *Dense Block* dan *decoder* yang terdiri dari *upsampling layer* (Huang *et al.*, 2019). *U-Net* merupakan arsitektur yang cukup dalam sehingga penambahan *layer* secara langsung pada arsitekturnya dapat memperbanyak parameter. Parameter yang banyak dapat mengakibatkan kompleksitas jaringan (Ronneberger *et al.*, 2015). Selain itu, parameter yang banyak juga dapat menyebabkan *overfitting* dan hilangnya gradien (Mwamsojo *et*

al., 2022). Salah satu arsitektur CNN yang memiliki jaringan yang lebih sederhana adalah *Fully Convolutional Network* (FCN). FCN hanya terdiri dari dua bagian yaitu *encoder* dan *decoder*. FCN tidak memiliki *Dense Block* pada bagian *encoder* dan hanya melakukan *deconvolution*. Sayangnya, tidak adanya *Dense Block* pada arsitektur FCN dapat menyebabkan beberapa fitur kecil yang terlewat (B. Chen *et al.*, 2018). Beberapa penelitian yang dilakukan menggunakan arsitektur FCN mendapatkan hasil kinerja yang baik seperti pada segmentasi pap smear oleh Bogacsovics *et al.*, (2021) menghasilkan akurasi 93% dan F1-score diatas 69%. L. Zhang *et al.*, (2017) menggunakan modifikasi FCN pada segmentasi citra *pap smear* menghasilkan akurasi diatas 90% dan F1-score lebih dari 80%. Penelitian lainnya dilakukan oleh Ma *et al.*, (2020) pada segmentasi citra *pap smear* menggunakan FCN menghasilkan akurasi 90,1% dan F1-score 80,3%. Sayangnya ketiga penelitian ini hanya melakukan segmentasi pada 2 label yaitu nukleus dan *background*.

Permasalahan *overfitting* pada *U-Net* juga disebabkan oleh penambahan secara langsung *layer* yang menyebabkan penambahan *concatenate layer* (Mwamsojo *et al.*, 2022). Operasi *concatenate* menyebabkan bertambahnya jumlah parameter karena terjadinya proses penggabungan fitur yang lama dengan fitur yang baru (H. Zhang *et al.*, 2020). *Residual Block* merupakan salah satu arsitektur CNN yang menggunakan *skip connection* yang dapat melakukan pintasan koneksi pada beberapa *layer* sehingga dapat meminimalkan waktu eksekusi (D. Li *et al.*, 2019). Namun, arsitektur *Residual Block* banyak digunakan dalam klasifikasi citra bukan segmentasi (Hussain *et al.*, 2020). Beberapa penelitian telah menunjukkan

hasil kinerja yang sangat baik pada klasifikasi citra menggunakan arsitektur *Residual Block* diantaranya Sellamuthu Palanisamy *et al.*, (2022) menggunakan *Ensemble Residual Dense Block* pada klasifikasi citra *pap smear* dengan hasil kinerja akurasi 99% dan *F1-score* 88%. Huong *et al.*, (2021) menggunakan *Ensemble Residual* dan *AlexNet* pada klasifikasi citra *pap smear* mendapatkan hasil kinerja yang sangat baik dengan akurasi 98%, sensitivitas sebesar 90% dan spesifisitas 99%.

Berdasarkan kelemahan *U-Net* maka tugas akhir ini mengusulkan modifikasi arsitektur *U-Net* pada bagian *encoder* dengan arsitektur FCN dan bagian *bridge* menggunakan *Residual Block* untuk memperoleh arsitektur yang lebih ringan dengan hasil kinerja yang lebih akurat pada segmentasi citra *pap smear* dengan 4 label yaitu sitoplasma, sitoplasma tipis, nukleus dan background. Untuk melihat kinerja yang dihasilkan oleh modifikasi FCN, *Residual Block* dan *U-Net* akan digunakan akurasi, sensitivitas, spesifisitas, *F1-score* dan IoU.

1.2 Perumusan Masalah

Bagaimana penerapan arsitektur baru melalui modifikasi arsitektur *U-Net* pada bagian *encoder* dengan arsitektur FCN dan bagian *bridge* menggunakan *Residual Block* dalam segmentasi citra *pap smear* dengan 4 label yaitu sitoplasma, sitoplasma tipis, nukleus dan background serta mengukur hasil kinerja arsitektur berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan IoU.

1.3 Pembatasan Masalah

Pembatasan masalah pada penelitian ini adalah :

1. Pembatasan masalah dalam penelitian ini adalah parameter keberhasilan yang digunakan adalah nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan IoU dari segmentasi semantik data sekunder citra *pap smear*.
2. Segmentasi dilakukan pada 4 label yaitu sitoplasma, sitoplasma tipis, nukleus dan background.

1.4 Tujuan

Menerapkan alternatif arsitektur baru dengan modifikasi arsitektur *U-Net* pada bagian *encoder* dengan arsitektur FCN dan bagian *bridge* menggunakan *Residual Block* dalam segmentasi citra *pap smear* dengan 4 label yaitu sitoplasma, sitoplasma tipis, nukleus dan background serta mengukur hasil kinerja berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-score* dan IoU.

1.5 Manfaat

Manfaat dari penelitian ini adalah :

1. Dapat diperoleh hasil segmentasi citra *pap smear* yang lebih akurat dengan kombinasi arsitektur FCN, *Residual Block* dan *U-Net*.
2. Dapat dijadikan sebagai referensi bagi pihak yang membutuhkan dalam penelitian terkait segmentasi citra *pap smear* dalam deteksi kanker serviks.

DAFTAR PUSTAKA

- Alom, M. Z., Yakopcic, C., Hasan, M., Taha, T. M., & Asari, V. K. (2019). Recurrent residual U-Net for medical image segmentation. *Journal of Medical Imaging*, 6(1), 014006. <https://doi.org/10.1117/1.JMI.6.1.014006>
- Bahadure, N. B., Ray, A. K., & Thethi, H. P. (2018). Comparative Approach of MRI-Based Brain Tumor Segmentation and Classification Using Genetic Algorithm. *Journal of Digital Imaging*, 31(4), 477–489. <https://doi.org/10.1007/s10278-018-0050-6>
- Bogacsovics, G., Hajdu, A., & Harangi, B. (2021). Cell Segmentation in Digitized Pap Smear Images Using an Ensemble of Fully Convolutional Networks. *2021 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*, 1–6. <https://doi.org/10.1109/SPMB52430.2021.9672284>
- Chankong, T., Theera-Umpon, N., & Auephanwiriyakul, S. (2014). Automatic cervical cell segmentation and classification in Pap smears. *Computer Methods and Programs in Biomedicine*, 113(2), 539–556. <https://doi.org/10.1016/j.cmpb.2013.12.012>
- Chen, B., Qi, X., Wang, Y., Zheng, Y., Shim, H. J., & Shi, Y.-Q. (2018). An Improved Splicing Localization Method by Fully Convolutional Networks. *IEEE Access*, 6, 69472–69480. <https://doi.org/10.1109/ACCESS.2018.2880433>
- Chen, Y., Chen, J., Wei, D., Li, Y., & Zheng, Y. (2020). Multiscale Multimodal Medical Imaging. In *arXiv* (Vol. 11977). <https://doi.org/10.1007/978-3-030-37969-8>
- Du, C., Wang, Y., Wang, C., Shi, C., & Xiao, B. (2020). Selective feature connection mechanism: Concatenating multi-layer CNN features with a feature selector. *Pattern Recognition Letters*, 129, 108–114. <https://doi.org/10.1016/j.patrec.2019.11.015>
- Ghosh, A., Sultana, F., Sufian, A., & Chakrabarti, A. (2020). *Fundamental Concepts of Convolutional Neural Network*. https://doi.org/10.1007/978-3-030-32644-9_36
- Huang, Y., Zhu, H., Wang, P., & Dong, D. (2019). Segmentation of Overlapping Cervical Smear Cells Based on U-Net and Improved Level Set. *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 3031–3035. <https://doi.org/10.1109/SMC.2019.8914625>
- Huong, A. K. C., Tay, K. G., & Ngu, X. T. I. (2021). Five-Class Classification of Cervical Pap Smear Images: A Study of CNN-Error-Correcting SVM Models. *Healthcare Informatics Research*, 27(4), 298–306. <https://doi.org/10.4258/hir.2021.27.4.298>
- Hussain, E., Mahanta, L. B., Das, C. R., & Talukdar, R. K. (2020). A comprehensive study on the multi-class cervical cancer diagnostic prediction on pap smear images using a fusion-based decision from ensemble deep convolutional neural network. *Tissue and Cell*, 65, 101347. <https://doi.org/10.1016/j.tice.2020.101347>

- Jafari, M. H., Karimi, N., Nasr-Esfahani, E., Samavi, S., Soroushmehr, S. M. R., Ward, K., & Najarian, K. (2016). Skin lesion segmentation in clinical images using deep learning. *Proceedings - International Conference on Pattern Recognition, 0*, 337–342. <https://doi.org/10.1109/ICPR.2016.7899656>
- Jr, E., & L, R. (2010). *Digital Image Processing I*. September 2010.
- Kayalibay, B., Jensen, G., & van der Smagt, P. (2017). *CNN-based Segmentation of Medical Imaging Data*. <https://doi.org/10.48550/ARXIV.1701.03056>
- Khryashchev, V., Lebedev, A., Stepanova, O., & Srednyakova, A. (2019). Using Convolutional Neural Networks in the Problem of Cell Nuclei Segmentation on Histological Images. *Springer Nature Switzerland AG 2019*, 149–161. <https://doi.org/10.1007/978-3-030-12072-6>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, D., Dharmawan, D. A., Ng, B. P., & Rahardja, S. (2019). Residual U-Net for Retinal Vessel Segmentation. *2019 IEEE International Conference on Image Processing (ICIP)*, 1425–1429. <https://doi.org/10.1109/ICIP.2019.8803101>
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical image classification with convolutional neural network. *2014 13th International Conference on Control Automation Robotics Vision (ICARCV)*, 844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>
- Liong, S.-T., Gan, Y. S., Huang, Y.-C., Yuan, C.-A., & Chang, H.-C. (2019). *Automatic Defect Segmentation on Leather with Deep Learning*.
- Long, F. (2020). Microscopy cell nuclei segmentation with enhanced U-Net. *BMC Bioinformatics*, *21*(1), 8. <https://doi.org/10.1186/s12859-019-3332-1>
- Ma, D., Liu, J., Li, J., & Zhou, Y. (2020). Cervical cancer detection in cervical smear images using deep pyramid inference with refinement and spatial-aware booster. *IET Image Processing*, *14*(17), 4717–4725.
- Meng, Z., Zhao, Z., Su, F., & Guo, L. (2021). Hierarchical Spatial Pyramid Network For Cervical Precancerous Segmentation By Reconstructing Deep Segmentation Networks. *IEEE Access*.
- Mwamsojo, N., Lehmann, F., El–Yacoubi, M. A., Merghem, K., Frignac, Y., Benkelfat, B.-E., & Rigaud, A.-S. (2022). Reservoir Computing for Early Stage Alzheimer’s Disease Detection. *IEEE Access*, *1*. <https://doi.org/10.1109/ACCESS.2022.3180045>
- N, S., Ngamvirojcharoen, J., Mopan, J., P, P., W, H., & K, S. (2019). Automated Pap Smear Cervical Cancer Screening Using Deep Learning. *IEEE Engineering in Medicine and Biology Society (EMBC)*. <https://doi.org/https://doi.org/10.1109/EMBC.2019.8856369>
- Oriola, O. (2020). *A Stacked Generalization Ensemble Approach for Improved Intrusion Detection*. *18*(5), 62–67.
- Riana, D., Hadianti, S., Rahayu, S., Friyadie, Hasan, M., Karimah, I. N., & Pratama, R. (2021). RepoMedUNM: A New Dataset for Feature Extraction and Training of Deep Learning Network for Classification of Pap Smear Images. In T. Mantoro, M. Lee, M. A. Ayu, K. W. Wong, & A. N. Hidayanto

- (Eds.), *Neural Information Processing* (pp. 317–325). Springer International Publishing.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9351, 234–241. <https://doi.org/10.1007/978-3-319-24574-4>
- Sellamuthu Palanisamy, V., Athiappan, R. K., & Nagalingam, T. (2022). Papsmear based cervical cancer detection using residual neural networks deep learning architecture. *Concurrency and Computation: Practice and Experience*, 34(4), e6608. <https://doi.org/https://doi.org/10.1002/cpe.6608>
- Wafa, M., & Ouadfel, S. (2019). Deep Feature Extraction for Pap-Smear Image Classification: A Comparative Study. In *ICCTA 2019: Proceedings of the 2019 5th International Conference on Computer and Technology Applications*. <https://doi.org/10.1145/3323933.3324060>
- Wijaya, R. S. D., Adiwijaya, Suksmono, A. B., & Mengko, T. L. (2021). Segmentasi Citra Kanker Serviks Menggunakan Markov Random Field dan Algoritma K-Means. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 139–147. <https://doi.org/10.29207/resti.v5i1.2816>
- Win, K. Y., & Choomchuay, S. (2017). Automated segmentation of cell nuclei in cytology pleural fluid images using OTSU thresholding. *2017 International Conference on Digital Arts, Media and Technology (ICDAMT)*, 14–18. <https://doi.org/10.1109/ICDAMT.2017.7904925>
- Wu, J. (2017). Introduction to convolutional neural networks. *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23), 495.
- Zhang, H., Zhu, H., & Ling, X. (2020). Polar coordinate sampling-based segmentation of overlapping cervical cells using attention U-Net and random walk. *Neurocomputing*, 383, 212–223. <https://doi.org/10.1016/j.neucom.2019.12.036>
- Zhang, L., Kong, H., Chin, C. T., Liu, S., Chen, Z., Wang, T., & Chen, S. (2014). Segmentation of cytoplasm and nuclei of abnormal cells in cervical cytology using global and local graph cuts. *Computerized Medical Imaging and Graphics*, 38(5), 369–380. <https://doi.org/10.1016/j.compmedimag.2014.02.001>
- Zhang, L., Sonka, M., Lu, L., Summers, R. M., & Yao, J. (2017). Combining fully convolutional networks and graph-based approach for automated segmentation of cervical cell nuclei. *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*, 406–409. <https://doi.org/10.1109/ISBI.2017.7950548>
- Zhang, X., & Zhao, S.-G. (2019). Cervical image classification based on image segmentation preprocessing and a CapsNet network model. *International Journal of Imaging Systems and Technology*, 29(1), 19–28. <https://doi.org/10.1002/ima.22291>
- Zhao, M., Wang, H., Han, Y., Wang, X., Dai, H. N., Sun, X., Zhang, J., & Pedersen, M. (2021). SEENS: Nuclei segmentation in Pap smear images with selective

edge enhancement. *Future Generation Computer Systems*, 114, 185–194.
<https://doi.org/10.1016/j.future.2020.07.045>