

**KLASIFIKASI LESI PRA-KANKER SERVIKS
MELALUI CITRA MEDIS IVA MENGGUNAKAN
METODE *CONVOLUTIONAL NEURAL NETWORK*
DAN *CLASS ACTIVATION MAPPING***



OLEH:
AKHIAR WISTA ARUM
09012682024006

**PROGRAM MAGISTER ILMU KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
TAHUN 2022**

**KLASIFIKASI LESI PRA-KANKER SERVIKS
MELALUI CITRA MEDIS IVA MENGGUNAKAN
METODE *CONVOLUTIONAL NEURAL NETWORK*
DAN *CLASS ACTIVATION MAPPING***

TESIS

**Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Magister**



OLEH:

AKHIAR WISTA ARUM

09012682024006

**PROGRAM MAGISTER ILMU KOMPUTER
FAKULTAS ILMU KOMPUTER
UNIVERSITAS SRIWIJAYA
TAHUN 2022**

LEMBAR PENGESAHAN

KLASIFIKASI LESI PRA-KANKER SERVIKS MELALUI CITRA MEDIS IVA MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK* DAN *CLASS ACTIVATION MAPPING*

TESIS

Diajukan Untuk Melengkapi Salah Satu Syarat
Memperoleh Gelar Magister

OLEH:
AKHIARWISTAARUM
09012682024006

Pembimbing I

Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 196908021994012001

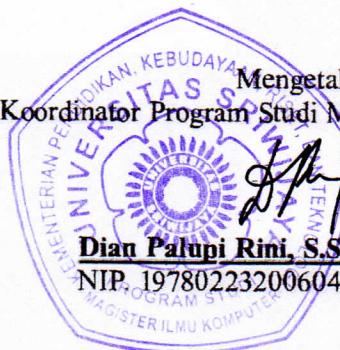
Palembang, Juli 2022

Pembimbing II

Dian Palupi Rini, S.Si, M.Kom, Ph.D
NIP. 197802232006042002

Mengetahui,
Koordinator Program Studi Magister Ilmu Komputer

Dian Palupi Rini, S.Si, M.Kom, Ph.D
NIP. 197802232006042002



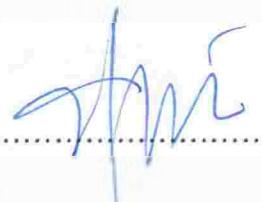
HALAMAN PERSETUJUAN

Pada hari Senin tanggal 11 Juli 2022 telah dilaksanakan ujian sidang tesis oleh Magister Ilmu Komputer Fakultas Ilmu Komputer Universitas Sriwijaya.

Nama : Akhiar Wista Arum
N I M : 09012682024006
Judul : Klasifikasi Lesi Pra-Kanker Serviks melalui Citra Medis IVA menggunakan Metode *Convolutional Neural Network* dan *Class Activation Mapping*

1. Pembimbing I

Prof. Dr. Ir. Siti Nurmaini, M.T.
NIP. 196908021994012001



2. Pembimbing II

Dian Palupi Rini, S.Si, M.Kom, Ph.D.
NIP. 197802232006042002



3. Pengaji I

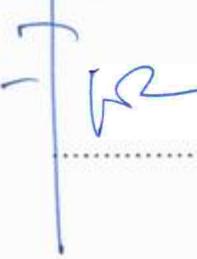
Dr. Erwin, S.Si., M.Si.
NIP. 197101291994121001



13/7/2022

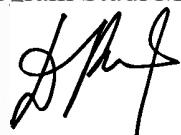
4. Pengaji II

Dr. Firdaus, S.T., M.Kom.
NIP. 197801212008121003



14/7/2022

Mengetahui,
Koordinator Program Studi Magister Ilmu Komputer



Dian Palupi Rini, S.Si, M.Kom, Ph.D
NIP.197802232006042002

LEMBAR PERNYATAAN

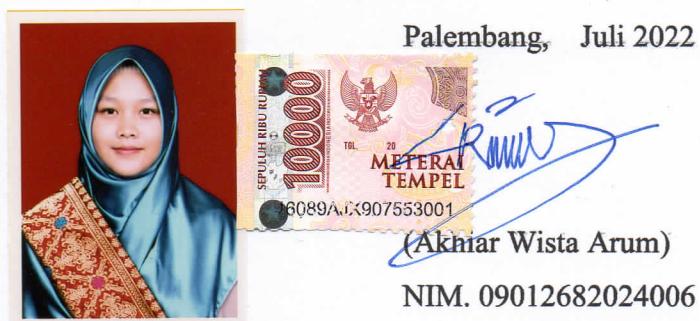
Yang bertanda tangan di bawah ini :

Nama : Akhiar Wista Arum
 NIM : 09012682024006
 Program Studi : Magister Ilmu Komputer
 Judul Tesis : Klasifikasi Lesi Pra-Kanker Serviks melalui Citra Medis
 IVA menggunakan Metode *Convolutional Neural Network*
 dan *Class Activation Mapping*

Hasil Pengecekan Software iThenticate/Turnitin : **9 %**

Menyatakan bahwa laporan tesis saya merupakan hasil karya sendiri dan bukan hasil penjiplakan/plagiat. Apabila ditemukan unsur penjiplakan/plagiat dalam laporan tesis ini, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan ketentuan yang berlaku.

Demikian, pernyataan ini saya buat dengan sebenarnya dan tidak ada paksaan oleh siapapun.



KATA PENGANTAR

Puji dan syukur penulis haturkan kehadiran Allah SWT yang telah melimpahkan rahmat, hidayah, dan kesehatan kepada penulis sehingga dapat menyelesaikan Tesis yang berjudul “**Klasifikasi Lesi Pra-Kanker Serviks melalui Citra Medis IVA menggunakan Metode Convolutional Neural Network dan Class Activation Mapping**”.

Pada kesempatan ini, penulis juga hendak mengucapkan banyak terimakasih kepada pihak-pihak yang telah banyak membantu penyelesaian Tesis ini, diantaranya:

1. Kedua orang tuaku Bapak Dartam Nur Syamsi dan Ibu Niah Wati serta Bapak Dr. Ir. M. Arief Karim, M.Sc. dan Ibu Dr.Ir. Tri Wardani Widowati, M.P yang telah memberikan motivasi, doa, dan restu.
2. Suamiku Muhammad Naufal Rachmatullah, S.Kom., M.T. yang selalu memberikan dukungan dan semangat yang tiada hentinya. Anak-anak ku Aisyah Azzahra dan Khadijah Amira Azzahra yang selalu menjadi kekuatan untuk menyelesaikan studi ini.
3. Ibu Dian Palupi Rini, S.Si, M.Kom., Ph.D selaku Koordinator Program Studi Magister Ilmu Komputer dan Dosen Pembimbing Tesis, Ibu Prof. Dr. Ir. Siti Nurmaini, M.T. selaku Dosen Pembimbing Tugas Akhir dan Bapak Samsuryadi M.Kom., Ph.D. selaku Dosen Pembimbing Akademik.
4. Semua dosen Program Studi Magister Ilmu Komputer Universitas Sriwijaya yang telah melimpahkan ilmunya kepada penulis selama proses belajar mengajar di Fakultas Ilmu Komputer Universitas Sriwijaya.

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan Tesis ini. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi kemajuan karya tulis khususnya yang berkenaan dengan Tesis ini. Penulis berharap semoga Tesis ini dapat bermanfaat bagi semua pihak khususnya Magister Ilmu Komputer Universitas Sriwijaya.

Palembang, Juli 2022
Penulis

Klasifikasi Lesi Pra-Kanker Serviks Melalui Citra Medis IVA
Menggunakan Metode *Convolutional Neural Network* dan *Class Activation Mapping*

Akhiar W. Arum, Siti Nurmaini *, Dian P. Rini

ABSTRAK

Tingginya tingkat infeksi virus *Human Papilloma Virus* (HPV) mengakibatkan penyakit kanker serviks menjadi penyakit terbanyak kedua yang menyerang wanita terutama di negara berpenghasilan rendah-menengah, termasuk Indonesia. Screening awal lesi pra-kanker adalah salah satu cara untuk mengurangi penyebaran kanker serviks. Inspeksi visual dengan asam asetat (IVA) adalah salah satu metode screening awal yang direkomendasikan oleh Organisasi Kesehatan Dunia (WHO) untuk diterapkan di negara berpenghasilan rendah-menengah. Namun, diperlukan keahlian untuk dapat membaca hasil diagnosis tes IVA. Hal ini dikarenakan anatomi lesi pra-kanker serviks yang begitu kompleks. Kurangnya tenaga kesehatan yang berpengalaman menjadi masalah tersendiri dalam penerapan test IVA, terutama di Indonesia. Oleh sebab itu, teknologi kecerdasan buatan yang mampu melakukan prediksi lesi pra-kanker serviks secara otomatis dan akurat perlu dikembangkan. Penelitian ini mengembangkan model klasifikasi lesi pra-kanker serviks pada citra medis IVA dengan menggunakan metode *Convolutional Neural Network* (CNN). Tiga arsitektur CNN yang digunakan diantaranya arsitektur VGG16, VGG19 dan ResNet50. Karena jumlah data yang digunakan masih terbatas, maka dilakukan dua kasus pengujian, pertama tanpa melakukan proses augmentasi data dan yang kedua dengan melakukan augmentasi data. Hasil yang diperoleh menunjukkan kinerja model klasifikasi model arsitektur ResNet50 pre-train dengan proses augmentasi data mengungguli model klasifikasi yang lain dengan nilai kinerja dengan akurasi 91.28%, presisi 98.75%, sensitivitas 86.81 %, f1-score 92.402% dan spesitifitas 98.27%. Selain itu, untuk meningkatkan kepercayaan hasil model CNN yang selama ini dianggap sebagai *black box*, ditampilkan hasil interpretasi model CNN berupa visualisasi *heatmap* untuk menunjukkan wilayah yang dibangkitkan oleh CNN. Metode interpretasi yang digunakan adalah *Class Activation Mapping* (CAM) dan *Gradient-Weight Class Activation Mapping* (Grad-CAM). Hasil visualisasi yang diperoleh menunjukkan model dapat digunakan oleh tenaga kesehatan sebagai alternatif screening awal test IVA secara otomatis.

Kata Kunci: Klasifikasi, Lokalisasi, CNN, CAM, Grad-CAM, Inspeksi Visual dengan Asam Asetat.

Cervical Precancer Classification Using Convolutional Neural Network and Class Activation Mapping

Akhiar W. Arum, Siti Nurmaini *, Dian P. Rini

ABSTRACT

The high-level infection of Human Papilloma Virus (HPV) causes cervical cancer to become the second most common disease that affects women, especially in low-middle income countries (LMICs), including Indonesia. Early screening for pre-cancerous lesions is one way to reduce the spread of cervical cancer. Visual inspection with acetic acid (VIA) is one initial screening methods recommended by the World Health Organization (WHO) to be applied in LMICs. However, healthcare professional is needed to read the VIA test diagnosis. This is because the anatomy of cervical pre-cancerous lesions is so complex. The lack healthcare professional is a problem in implementing the VIA test, especially in Indonesia. Therefore, artificial intelligence technology that is able to predict cervical pre-cancerous lesions automatically and accurately needs to be developed. This study developed a classification model for cervical pre-cancerous lesions on VIA medical images using the Convolutional Neural Network (CNN) method. The three CNN architectures used include the VGG16, VGG19 and ResNet50 architectures. Because the amount of data used is still limited, two test cases were carried out, the first without data augmentation and the second with data augmentation. The results obtained show that the performance of model classification ResNet50 pre-train with data augmentation outperformed other classification models with a performance value 91.28% accuracy, 98.75% precision, 86.81% sensitivity, 92.402% f1-score and 98.27% specificity. In addition, to increase the confidence of the CNN model results, which have been considered a black box, the interpretation of the CNN model results in heatmap visualization to show the area generated by CNN is shown. The interpretation methods used are Class Activation Mapping (CAM) and Gradient-Weight Class Activation Mapping (Grad-CAM). The visualization results obtained show that the model can be used by healthcare professionals as an alternative to the automatic initial screening of the VIA test.

Keywords: Classification, Localization, CNN, CAM, Grad-CAM, Visual inspection with acetic acid.

DAFTAR ISI

	Halaman
Halaman Sampul	i
Halaman Judul	ii
Halaman Pengesahan	Iii
Halaman Persetujuan	iv
Halaman Pernyataan bukan Plagiat	v
Kata Pengantar	vi
Abstrak	vii
Abstract	viii
Daftar Isi	ix
Daftar Gambar	xii
Daftar Tabel	xvi
Daftar Lampiran	xvii
BAB I. PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Perumusan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan	6
1.5 Manfaat	6
1.6 Sistematika Penulisan	7
BAB II. TINJAUAN PUSTAKA	
2.1 Tinjauan Penelitian	8
2.2 Pra Kanker Serviks	11
2.3 Inspeksi Visual Asam Asetat <i>Screening Tool</i>	12
2.4 <i>Convolutional Neural Network</i>	13
2.4.1 Arsitektur VGG16	21
2.4.2 Arsitektur VGG19	22

2.4.3 Arsitektur ResNet50	24
<i>2.5 Explainable Artificial Intelligence</i>	25
2.5.1 <i>Class Activation Mapping</i>	26
2.5.2 <i>Gradient-Weighted Class Activation Mapping</i>	28
2.6 Matrix Evaluasi Kinerja	29
2.6.1 Analisa Kurva <i>Receiver Operating Characteristic</i>	31
2.6.2 Analisa Kurva Presisi- <i>Recall</i>	33
 BAB III. METODOLOGI PENELITIAN	
3.1 Kerangka Kerja	34
3.2 Akuisisi Data	36
3.3 Sebaran Data	38
3.4 Pra- Pengolahan Data	39
3.5 Augmentasi Data	41
3.6 Pengklasifikasi <i>Convolutional Neural Network</i>	43
3.6.1 Model Arsitektur VGG16	43
3.6.2 Model Arsitektur VGG19	44
3.6.3 Model Arsitektur ResNet50	45
3.6.4 Model Pre-Train	46
3.6.5 Proses Pelatihan	47
3.6.6 Proses Validasi	47
3.8 Evaluasi	48
3.9 Visualisasi Model <i>Convolutional Neural Network</i>	48
menggunakan Metode <i>Explainable Artificial Intelligence</i>	
3.9.1 Visualisasi <i>Class Activation Mapping</i>	49
3.9.2 Visualisasi <i>Gradient-Weighted Class Activation Mapping</i>	50
 BAB IV. HASIL DAN ANALISA	
4.1 Model Klasifikasi tanpa Proses Augmentasi	52
4.1.1 Hasil Klasifikasi Model Pre-Train Arsitektur VGG16	53

4.1.2 Hasil Klasifikasi Model Arsitektur VGG16 tanpa Pre-Train	57
4.1.3 Hasil Klasifikasi Model Pre-Train Arsitektur VGG19	61
4.1.4 Hasil Klasifikasi Model Arsitektur VGG19 tanpa Pre-Train	65
4.1.5 Hasil Klasifikasi Model Pre-Train Arsitektur ResNet50	70
4.1.6 Hasil Klasifikasi Model Arsitektur ResNet50 tanpa Pre-Train	75
4.2 Model Klasifikasi dengan Proses Augmentasi	79
4.2.1 Hasil Klasifikasi Model Pre-Train Arsitektur VGG16	80
4.2.2 Hasil Klasifikasi Model Arsitektur VGG16 tanpa Pre-Train	84
4.2.3 Hasil Klasifikasi Model Pre-Train Arsitektur VGG19	89
4.2.4 Hasil Klasifikasi Model Arsitektur VGG19 tanpa Pre-Train	93
4.2.5 Hasil Klasifikasi Model Pre-Train Arsitektur ResNet50	97
4.2.6 Hasil Klasifikasi Model Arsitektur ResNet50 tanpa Pre-Train	101
4.3 Perbandingan Kinerja Model Klasifikasi	105
4.4 Diskusi	109
 BAB V. KESIMPULAN	
5.1 Kesimpulan	119
5.2 Saran	120
Daftar Pustaka	121
Lampiran	

DAFTAR GAMBAR

	Halaman
Gambar 2. 1 Anatomi Wilayah penyebaran sel kanker pada serviks	12
Gambar 2. 2 Contoh Serviks yang Mengalami Perubahan Warna setelah di olesi Asam Asetat	13
Gambar 2. 3 Contoh Arsitektur CNN (Hwang dkk., 2021)	14
Gambar 2. 4 Ilustrasi Operasi Konvolusi. Piksel biru adalah citra masukan, piksel tengah adalah filter/kernel, dan piksel hijau feature map	15
Gambar 2. 5 Stride pada CNN	16
Gambar 2. 6 Penambahan zero-padding pada citra masukan	16
Gambar 2. 7 Operasi Max Pooling, Average Pooling.	17
Gambar 2. 8 Arsitektur VGG-16 (Hacifendioğlu dkk., 2021)	22
Gambar 2. 9 Arsitektur VGG 19 (Panwar dkk., 2020).	24
Gambar 2. 10 (a) Arsitektur ResNet50, (b) Metode pembelajaran CNN (kiri) dan ResNet (kanan). Dengan menambahkan pintasan yang menambahkan nilai input ke nilai output setiap dua lapisan, error akan berkurang lebih cepat dibandingkan dengan CNN biasa (Park dkk., 2021)	25
Gambar 2. 11 Class Activation Mapping (Yildiz, Zan, dan Said 2021).	27
Gambar 2. 12 Arsitektur Grad-CAM (Zhang dkk., 2021)	29
Gambar 2. 13 Confusion Matrix Untuk Klasifikasi Biner	29
Gambar 2. 14 Confussion Matrix Klasifikasi Multi Kelas	31
Gambar 2. 15 Kurva ROC	32
Gambar 2. 16 Contoh Kurva Presisi- <i>Recall</i>	33
Gambar 3. 1 Kerangka Kerja Metodologi Penelitian	35
Gambar 3. 2 Arsitektur yang Digunakan	36
Gambar 3. 3 Contoh citra medis IVA yang digunakan dalam Penelitian (a) citra medis IVA Normal, (b) dan (c) citra medis IVA Abnormal	37
Gambar 3. 4 Sebaran Data Training.	38
Gambar 3. 5 Sebaran Data Validasi	38

Gambar 3. 6 (a) Gambar Asli Sebelum Penghapusan Latar Belakang, (b) Setelah Proses Penghapusan Latar Belakang.	39
Gambar 3. 7 (a) Gambar Asli sebelum di resize, (b) Gambar setelah di resize	40
Gambar 3. 8 Tahapan Proses Pra-Pengolahan Data yang dilakukan	40
Gambar 3. 9 Metode Augmentasi yang Digunakan	41
Gambar 3. 10 Sebaran Dataset Training setelah Proses Augmentasi Data	42
Gambar 3. 11 Sebaran Dataset Validasi	42
Gambar 3. 12 Arsitektur VGG16 yang Digunakan.	44
Gambar 3. 13 Arsitektur VGG19 yang Digunakan	45
Gambar 3. 14 Arsitektur ResNet50 yang Diusulkan.	46
Gambar 3. 15 Model Pre-Trained yang digunakan dalam Penelitian ini.	47
Gambar 3. 17 Arsitektur CAM yang digunakan	49
Gambar 3. 18 Contoh Visualisasi CAM pada citra medis IVA	50
Gambar 3. 19 Arsitektur Grad-CAM yang digunakan.	51
Gambar 3. 20 Contoh hasil Visualisasi Grad-CAM (Hwang dkk., 2021).	51
Gambar 4. 1 Confusion Matrix Model Pre-Train Arsitektur VGG16 Tanpa Proses Augmentasi Data	54
Gambar 4. 2 Grafik Fungsi Loss dari Model Pre-Train VGG16 tanpa Proses Augmentasi Data.	55
Gambar 4. 3 Grafik Akurasi dari Model Pre-Train VGG16 tanpa Proses Augmentasi Data	56
Gambar 4. 4 Confusion Matrix Model VGG16 tanpa Pre-Train tanpa proses Augmentasi Data	58
Gambar 4. 5 Grafik Fungsi Loss dari Model VGG16 tanpa Pre-Train dan tanpa Augmentasi Data	59
Gambar 4. 6 Grafik Akurasi dari Model VGG16 tanpa Pre-Train dan tanpa Augmentasi Data	60
Gambar 4. 7 Confusion Matrix Model Pre-Train Arsitektur VGG19 tanpa Proses Augmentasi Data	62
Gambar 4. 8 Grafik Fungsi Loss dari Model Pre-Train VGG19 tanpa Augmentasi Data.	64
Gambar 4. 9 Grafik Akurasi dari Model Pre-Train VGG19 tanpa Augmentasi Data.	64
Gambar 4. 10 Confusion Matrix Model VGG19 tanpa Pre-Train tanpa proses Augmentasi Data.	67
Gambar 4. 11 Grafik Fungsi Loss dari Model VGG19 tanpa Pre-Train dan tanpa Augmentasi Data.	68

Gambar 4. 12 Grafik Akurasi dari Model VGG19 tanpa Pre-Train dan tanpa Augmentasi Data.	69
Gambar 4. 13 Confussion Matrix Model Pre-Train Arsitektur ResNet50 Tanpa Proses Augmentasi Data	72
Gambar 4. 14 Grafik Fungsi Loss dari Model Pre-Train ResNet50 tanpa Augmentasi Data	73
Gambar 4. 15 Grafik Akurasi dari Model Pre-Train ResNet50 tanpa Augmentasi Data	73
Gambar 4. 16 Confussion Matrix Model ResNet50 tanpa Pre-Train tanpa proses Augmentasi Data	76
Gambar 4. 17 Grafik Fungsi Loss dari Model ResNet50 tanpa Pre-Train dan tanpa Augmentasi Data	77
Gambar 4. 18 Grafik Akurasi dari Model ResNet50 tanpa Pre-Train dan tanpa Augmentasi Data	78
Gambar 4. 19 Confussion Matrix Model Pre-Train Arsitektur VGG16 dengan Proses Augmentasi Data	81
Gambar 4. 20 Grafik Fungsi Loss dari Model Pre-Train VGG16 dengan proses Augmentasi Data	82
Gambar 4. 21 Grafik Akurasi dari Model Pre-Train VGG16 dengan proses Augmentasi Data	82
Gambar 4. 22 Confussion Matrix Model Augmentasi VGG16 Tanpa Pre-Train	86
Gambar 4. 23 Grafik Loss dari Model VGG16 tanpa Pre-Train dengan Proses Augmentasi Data	87
Gambar 4. 24 Grafik Akurasi dari Model VGG16 tanpa Pre-Train dengan Proses Augmentasi Data	87
Gambar 4. 25 Confussion Matrix Model Pre-Train Arsitektur VGG19 dengan Proses Augmentasi Data.	90
Gambar 4. 26 Grafik Fungsi Loss dari Model Pre-Train VGG19 dengan proses Augmentasi Data.	91
Gambar 4. 27 Grafik Akurasi dari Model Pre-Train VGG19 dengan proses Augmentasi Data.	92
Gambar 4. 28 Confussion Matrix Model VGG19 Tanpa Pre-Train dengan Proses Augmentasi.	94
Gambar 4. 29 Grafik Loss dari Model VGG19 tanpa Pre-Train dengan Proses Augmentasi Data	95
Gambar 4. 30 Grafik Akurasi dari Model VGG19 tanpa Pre-Train dengan Proses Augmentasi Data	96
Gambar 4. 31 Confussion Matrix Model Pre-Train Arsitektur ResNet50 dengan Proses Augmentasi Data	98
Gambar 4. 32 Grafik Fungsi Loss dari Model Pre-Train ResNet50 dengan Proses Augmentasi Data.	99
Gambar 4. 33 Grafik Akurasi dari Model Pre-Train ResNet50 dengan Proses Augmentasi Data	100
Gambar 4. 34 Confussion Matrix Model Arsitektur ResNet50 tanpa Pre-Train dengan Proses Augmentasi Data	102

Gambar 4. 35 Grafik Fungsi Loss dari Model ResNet50 tanpa Pre-Train dengan Proses Augmentasi Data	103
Gambar 4. 36 Grafik Akurasi dari Model ResNet50 tanpa Pre-Train dengan Proses Augmentasi Data	104
Gambar 4. 37 Grafik Perbandingan Hasil Kinerja Model	108
Gambar 4. 38 Grafik ROC ResNet50 Pre-Train dengan Proses Augmentasi Data.	111
Gambar 4. 39 Grafik PR ResNet50 Pre-Train dengan Proses Augmentasi Data	112
Gambar 4. 40 Hasil Visualisasi CAM dan Grad-CAM pada Citra IVA Normal yang diprediksi sebagai Normal. (a) Raw Data, (b) CAM, (c) Grad-CAM.	114
Gambar 4. 41 Hasil Visualisasi CAM dan Grad-CAM pada Citra IVA Abnormal yang diprediksi sebagai Abnormal. (a) Raw Data, (b) CAM, (c) Grad-CAM	116
Gambar 4. 42 Hasil Visualisasi CAM dan Grad-CAM pada Citra IVA Abnormal yang diprediksi sebagai Normal. (a) Raw Data, (b) CAM, (c) Grad-CAM.	117
Gambar Lampiran 1. Contoh Gambar yang diolah dengan Nilai Piksel Berukuran 7x7	
Gambar Lampiran 2. Hasil Penskalaan nilai piksel pada gambar berukuran 7x7	
Gambar Lampiran 3. Perhitungan dasar lapisan konvolusi pada matriks gambar 7x7 dan matriks filter 3x3. Hasil yang diperoleh adalah matriks fitur 5x5	
Gambar Lampiran 4. Fungsi Aktivasi ReLU.	
Gambar Lampiran 5. Hasil perhitungan fungsi aktivasi ReLU.	
Gambar Lampiran 6. Operasi Max-Pooling dari matriks 5x5 dan filter 2x2 menghasilkan keluaran berupa matriks 3x3.	
Gambar Lampiran 7. Arsitektur Fully Connected yang akan dilakukan perhitungan	

DAFTAR TABEL

	Halaman
Tabel 1. Penelitian Terkait Teknik Klasifikasi Pra-Kanker Serviks yang Pernah Dilakukan	10
Tabel 2. Struktur VGG16	21
Tabel 3. Tabel Perbedaan VGG16 dan VGG19	23
Tabel 4. Kriteria Nilai Akurasi AUC	32
Tabel 5. Matriks Evaluasi kinerja Model	48
Tabel 6. Hasil Kinerja seluruh Model Klasifikasi	106
Tabel 6. Benchmarking Usulan Arsitektur dengan Model Machine Learning lainnya.	118

DAFTAR LAMPIRAN

Lampiran 1. Simulasi Perhitungan CNN

Lampiran 2. Source Code Program Python

BAB I. PENDAHULUAN

Bab I berisi tentang latar belakang dilakukannya penelitian, yang memuat permasalahan-permasalahan dan solusi yang pernah dilakukan. Selanjutnya dilakukan analisa rumusan masalah untuk mengetahui permasalahan mana yang belum terselesaikan dan dapat dijadikan sebagai permasalahan dengan batasan-batasan yang jelas dalam penelitian ini. Tujuan, dan metodologi yang digunakan dalam penelitian ini juga dijabarkan sehingga hasil yang diperoleh lebih terperinci dan terarah serta menghasilkan kinerja yang baik.

1.1 Latar Belakang

Kanker serviks adalah jenis kanker yang terdapat di leher rahim tepatnya di daerah sambungan skuamo kolumnar (SSK) (Lange, 2005). Kanker jenis ini banyak disebabkan oleh infeksi *Human Papilloma Virus* (HPV) (Asiedu dkk., 2019; Kudva, dkk., 2017; Liu dkk., 2017). Menurut (Globocan, 2021) kanker serviks adalah penyakit nomer 2 terbanyak yang menyerang wanita terutama di negara berkembang. Lebih lanjut pada tahun 2020 dilaporkan sebanyak 17,2% atau 3.633 kasus kanker yang dialami oleh Wanita di Indonesia merupakan kanker serviks (Globocan, 2021). Kematian akibat kanker serviks dilaporkan sebanyak 2.003 kasus atau 57,3 %. Jumlah ini merupakan jumlah tertinggi ke dua setelah kanker payudara. Tingginya tingkat infeksi kanker serviks di Indonesia dikarenakan masih rendahnya kesadaran wanita untuk melakukan *screening* awal pendekslan kanker serviks.

Screening awal penting dilakukan untuk mengurangi risiko bahaya kanker serviks. Pemeriksaan ini dapat meningkatkan efektivitas penyintas hingga 100% (Cubie dan Campbell, 2020). Hal ini dikarenakan ketika seseorang terinfeksi HPV butuh waktu beberapa tahun bagi jaringan *epithelia* untuk berubah dari lesi pra-kanker menjadi kanker yang berbahaya (Zhao dkk., 2016). Oleh karena itu ada waktu yang memadai untuk melakukan *screening* dan deteksi awal lesi pra-kanker.

Terdapat beberapa metode *screening* yang direkomendasikan oleh WHO di antaranya, *cancer cytology* (*pap smear test*), HPV test, *visual inspection test* dan

kolposkopi (V. Kudva dkk., 2017; Liu dkk., 2017). Metode *screening* yang dianggap sebagai *gold standart* pada beberapa negara maju di antaranya tes pap smear , tes HPV dan kolposkopi (Asiedu dkk., 2019; Ferndanes dkk., 2018) .Hal ini disebabkan tingkat akurasi dan spesifisitas yang relatif tinggi. Namun, ketiga jenis metode *screening* ini membutuhkan biaya dan infrastruktur yang tidak murah, sehingga cukup sulit untuk diterapkan pada negara berkembang (V. Kudva dkk., 2018) seperti Indonesia.

Alternatif yang dapat digunakan sebagai *screening* awal di negara berkembang adalah *visual inspection test* menggunakan larutan asam asetat atau yang lebih dikenal dengan metode inspeksi visual dengan asam asetat (IVA) (Vidya Kudva dkk., 2018). Saat ini, IVA menjadi *screening tool* yang popular untuk pendekslsian awal kanker serviks di negara berkembang karena tingkat keefektifan, kenyamanan serta biaya yang murah (Bae dkk., 2020). Pemeriksaan IVA yaitu dengan mengaplikasikan 3-5% asam asetat secara inspekulo dengan mata telanjang (Zhao dkk., 2016).Oleh karena itu, untuk mendapatkan hasil IVA yang akurat diperlukan operator yang berpengalaman, untuk membaca hasil tes sehingga tidak terjadi kesalahan diagnosis (Srivastava dkk. 2020).

Minimnya dokter berpengalaman di negara berkembang menjadi permasalahan tersendiri dalam penerapan tes IVA. Untuk mengatasinya perlu dikembangkan teknologi kecerdasan buatan yang dapat membantu melakukan analisis pra-kanker serviks pada citra medis IVA secara otomatis (V. Kudva dkk., 2017). Penelitian mengenai otomatisasi deteksi dan klasifikasi pra-kanker serviks sudah banyak dilakukan. Namun lebih banyak berfokus pada metode pap smear (Sharma dkk., 2016; Su dkk., 2016; William dkk., 2018), metode HPV (Chauhan dkk., 2020), serta metode kolposkopi (Bai dkk., 2020; Centre, 2018).

Penelitian yang berfokus pada klasifikasi lesi pra-kanker serviks menggunakan tes IVA masih sangat minim. Beberapa penelitian pada kasus klasifikasi berfokus pada wilayah kanker serviks, di antaranya Tao Xu, dkk., (2015) melakukan penelitian mengenai klasifikasi derajat keparahan kanker serviks menggunakan pengklasifikasi AdaBoost. Selain itu Tao Xu, dkk, menggunakan *Local Binary Pattern (LBP) map*, L*A*B kanal warna dan gambar *gradient maps* sebagai metode ekstraksi fitur. Sehingga hasil terbaik dari model yang diusulkan

diperoleh nilai sensitivitas: 42%, spesifisitas 90%. Namun, hasil sensitivitas yang masih jelek dan spesifisitas masih lebih rendah jika dibanding dengan diagnosis ahli mengindikasikan bahwa model masih belum dapat dipercaya dalam menyelesaikan kasus klasifikasi (Xu, Kim, dan Huang, 2015).

Penelitian lain (Sukumar dan Gnanamurthy, 2016), Sukumar dkk., (2016) melakukan klasifikasi normal dan abnormal pada 280 data gambar kanker serviks. Menggunakan arsitektur pembelajaran mesin *random forest*. Beberapa metode ekstrasi fitur yang digunakan di antaranya *Local Binary Pattern* (LBP), *Local Ternary Pattern* (LTP), dan *Local Derivative Pattern* (LDP). Akurasi yang diperoleh dalam penelitian ini mencapai nilai 95.4%. Namun sayangnya, dalam penelitian ini hanya ditampilkan metrik kinerja akurasi. Padahal dalam dunia medis hasil kinerja tidak hanya dilihat dari akurasi saja. Perlu parameter lain yang dilihat untuk menilai suatu model dapat digunakan atau tidak.

Penelitian terbaru (Kudva dkk., 2020; Liu dkk., 2019) dilakukan dengan menerapkan metode *Convolutional Neuron Network* (CNN) untuk melakukan tugas klasifikasi normal dan abnormal pada kanker serviks. Rata-rata nilai kinerja yang dihasilkan juga melebihi 85%, model sudah dianggap cukup baik dalam melakukan klasifikasi. Namun masing-masing penelitian masih terdapat kekurangan seperti pada penelitian (Kudva dkk., 2020) yaitu fitur untuk filter di lapisan konvolusi yang menyoroti margin wilayah *acetowhite* dan tekstur di dalam wilayah *acetowhite* perlu ditambah untuk meningkatkan akurasi kinerja model.

Penelitian sebelumnya belum banyak menyentuh wilayah pra-kanker serviks, dan lebih berfokus pada klasifikasi tingkat keparahan kanker serviks. Oleh karena itu, pada penelitian ini diusulkan suatu arsitektur CNN untuk melakukan tugas klasifikasi pra-kanker serviks pada citra medis IVA. Klasifikasi yang dilakukan yaitu klasifikasi biner normal dan abnormal. Arsitektur CNN yang digunakan dalam penelitian ini terdiri dari arsitektur VGG16, arsitektur VGG19 dan arsitektur ResNet50.

Pemilihan ketiga arsitektur tersebut didasarkan pada kinerja yang dihasilkan masing-masing arsitektur dalam melakukan klasifikasi pada penelitian dibidang citra medis. Arsitektur VGG16, VGG19 dan ResNet50 menghasilkan nilai akurasi dan sensitivitas yang sangat baik (Adweb dkk., 2021; Zhang dkk., 2021). Bahkan

beberapa penelitian mengklaim arsitektur VGG menghasilkan model terbaik dengan nilai akurasi, sensitivitas dan spesifisitas di atas 95% (Zhang dkk., 2021).

Terbatasnya jumlah data citra medis IVA menjadi permasalahan tersendiri dalam melakukan klasifikasi lesi pra-kanker serviks. Klasifikasi dengan menggunakan arsitektur CNN memerlukan jumlah data yang banyak untuk menghasilkan model yang *robust*. Oleh sebab itu, dalam penelitian ini akan dilakukan dua kasus pengujian. Pertama pembangunan model dengan jumlah data asli (tanpa proses augmentasi data) dan kedua pembangunan model dengan proses augmentasi data. Tujuan penerapan proses augmentasi data untuk melihat pengaruh jumlah data yang digunakan dalam pembangunan model klasifikasi lesi pra-kanker menggunakan arsitektur CNN.

Selain menerapkan arsitektur CNN, dalam penelitian ini juga menerapkan metode *Explainable AI* (XAI) untuk membantu menginterpretasikan hasil keluaran CNN. Hal ini penting karena dalam dunia medis, selain model yang *robust* diperlukan juga model yang *trust* (Linardatos dkk., 2021). Maksudnya, bagaimana model dapat melakukan tugas klasifikasi dengan baik, bagaimana model dapat mengenali penyakit dengan tepat dan bagaimana model dapat melakukan lokalisasi wilayah dengan akurat harus bisa dijelaskan dan dipahami oleh manusia. Selama ini manusia hanya percaya dengan model yang dihasilkan oleh komputer tanpa tahu proses sebenarnya yang terjadi (*blackbox*) (Ding, 2018; Linardatos dkk., 2021).

Oleh karena itu, dengan menggunakan metode XAI, dapat menjelaskan bagaimana suatu model melakukan pembelajaran dan menyelesaikan tugas yang diberikan. Sehingga hasil yang diperoleh dapat lebih dipahami dan dipercaya oleh manusia (Selvaraju dkk., 2020). Dalam kasus citra, metode XAI melakukan visualisasi dengan menampilkan *heatmap* pada hasil keluaran model CNN. *Heatmap* adalah salah satu cara untuk merepresentasikan data dengan bentuk map atau diagram. Value dari map atau diagram tersebut digambarkan dengan intensitas warna (Zhang dkk., 2021).

Dalam penelitian ini, arsitektur CNN digunakan untuk proses klasifikasi seperti arsitektur VGG16, arsitektur VGG19 dan arsitektur ResNet50 kemudian dilakukan interpretasi dengan menerapkan metode XAI. Metode XAI yang digunakan diantaranya *Class Activation Map* (CAM) (Zhou dkk., 2016), *Gradient-*

Weight Class Activation Map (Grad-CAM) (Hwang dkk., 2021; Selvaraju dkk., 2017). Klasifikasi dan interpretasi dengan menggunakan arsitektur CNN dan XAI pada bidang citra medis terutama untuk kasus klasifikasi pra-kanker serviks merupakan penelitian pertama yang dilakukan khususnya di Indonesia.

1.2 Perumusan Masalah

Perumusan masalah di tinjau berdasarkan latar belakang yang telah dipaparkan yaitu “Menginterpretasikan hasil klasifikasi lesi pra-kanker serviks citra medis IVA sehingga dapat dipahami oleh manusia”. Merujuk perumusan masalah tersebut, maka dapat diuraikan menjadi beberapa poin perumusan masalah, di antaranya:

1. Menentukan tahapan pra-pengolahan data pada citra medis IVA yang dapat memperbaiki kualitas gambar sehingga hasil klasifikasi lesi pra-kanker serviks dapat optimal.
2. Merancang arsitektur CNN yang *robust* untuk melakukan tugas klasifikasi lesi pra-kanker serviks pada citra medis IVA.
3. Melihat pengaruh penerapan proses augmentasi data dalam membangun model klasifikasi lesi pra-kanker serviks pada citra medis IVA.
4. Merancang arsitektur *explainable AI* sehingga dapat menginterpretasikan hasil pengklasifikasian arsitektur CNN dalam tampilan *heatmap*.
5. Melakukan evaluasi kinerja pengklasifikasian pada arsitektur dengan menggunakan parameter: akurasi, sensitivitas, spesifisitas, presisi, F1 score, kurva ROC, dan kurva presisi-*recall*.

1.3 Batasan Masalah

Batasan masalah pada model klasifikasi lesi pra-kanker serviks citra medis IVA pada tesis ini adalah:

1. Model yang di rancang adalah model untuk melakukan klasifikasi lesi pra-kanker serviks citra medis IVA dan model interpretasi hasil dari klasifikasi tersebut.
2. Dataset yang digunakan merupakan data primer yang diperoleh dari salah satu rumah sakit di kota Palembang.

1.4 Tujuan

Tujuan dari penelitian ini secara umum adalah untuk menghasilkan model yang dapat menginterpretasikan hasil klasifikasi sehingga dapat lebih mudah dipahami dan dipercaya oleh manusia. Tujuan tersebut dapat dirincikan menjadi:

1. Membuat proses pra-pengolahan data pada citra medis IVA sehingga dapat memperbaiki kualitas gambar dan dapat diklasifikasikan menjadi lesi pra-kanker serviks ke dalam kelas normal dan abnormal secara tepat.
2. Merancang arsitektur CNN yang *robust* untuk melakukan tugas klasifikasi lesi pra-kanker serviks pada citra medis IVA.
3. Membandingkan model klasifikasi sebelum dan setelah proses augmentasi data.
4. Merancang arsitektur XAI sehingga dapat menginterpretasikan hasil pengklasifikasian arsitektur CNN dengan bentuk keluaran *heatmap*.
5. Mengukur kinerja pengklasifikasian pada arsitektur CNN dengan optimal, dalam hal ini akurasi, sensitivitas, spesifisitas, presisi, F1 score, kurva ROC, dan kurva presisi-*recall*.

1.5 Manfaat

Berdasarkan tujuan penelitian yang hendak dicapai, maka penelitian ini diharapkan memiliki manfaat menjadi sarana alternatif pendekstrian dini lesi pra kanker serviks secara otomatis dan akurat di negara yang memiliki kekurangan sumber daya ahli dan berpenghasilan rendah-menengah, termasuk Indonesia. Manfaat penelitian dapat dirincikan menjadi:

1. Mempermudah proses pemeriksaan dini lesi pra-kanker serviks pada wilayah yang sulit dijangkau oleh tenaga medis.
2. Mempermudah proses analisa lesi pra-kanker serviks pada wilayah yang sulit dijangkau oleh tenaga medis.
3. Mempersingkat waktu dan menghemat biaya pemeriksaan lesi pra-kanker serviks.
4. Menurunkan angka kematian wanita akibat kanker serviks karena apabila lesi pra-kanker serviks dapat di deteksi sedini mungkin, maka

pasien dapat mendapat perawatan yang dibutuhkan sehingga virus HPV tidak berkembang menjadi kanker.

1.6 Sistematika Penulisan

Sistematika penulisan merupakan rangkuman dari setiap bab yang ada pada penelitian. Tujuannya untuk mempermudah penyusunan dan untuk memperjelas isi masing-masing bab. Sistematika penulisan pada penelitian ini terdiri dari:

1. BAB I Pendahuluan

Bab ini berisi tentang latar belakang, rumusan masalah, batasan masalah, tujuan, manfaat, metodologi penelitian, dan sistematika penulisan.

2. BAB II Tinjauan Pustaka

Bab ini berisi tentang seluruh penjelasan mengenai landasan teori yang berhubungan dengan permasalahan yang dibahas pada penulisan tesis ini.

3. BAB III Metodologi Penelitian

Bab ini berisi penjelasan secara bertahap dan terperinci tentang langkah-langkah (metodologi) yang digunakan untuk membuat kerangka berpikir dan kerangka kerja dalam menyelesaikan tesis serta *timeline* penggerjaan penelitian.

4. BAB IV Hasil dan Analisa

Bab ini berisi tentang hasil sementara yang telah diperoleh dalam penelitian ini. Hasil sementara dianalisis untuk di evaluasi sehingga dapat dilakukan perbaikan pada tesis dua.

5. BAB IV Kesimpulan

Bab ini berisi kesimpulan dari hasil sementara yang telah diperoleh serta uraian tahapan tesis dua yang akan dilakukan.

DAFTAR PUSTAKA

- Adweb, K. M. A., Cavus, N., & Sekeroglu, B. (2021). Cervical Cancer Diagnosis Using Very Deep Networks over Different Activation Functions. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2021.3067195>
- Agrawal, H., Mathialagan, C. S., Goyal, Y., Chavali, N., Banik, P., Mohapatra, A., ... Batra, D. (2016). CloudCV: Large scale distributed computer vision as a cloud service. In Mobile cloud visual media computing. *Springer*, (pp. 265–290).
- Antol, S., Agrawal, A., Lu, J., Mitchell, M., Batra, D., Lawrence Zitnick, C., & Parikh, D. (2015). VQA: Visual question answering. *ICCV*.
- Asiedu, M. N., Simhal, A., Chaudhary, U., Mueller, J. L., Lam, C. T., Schmitt, J. W., Ramanujam, N. (2019). Development of algorithms for automated detection of cervical pre-cancers with a low-cost, point-of-care, Pocket Colposcope HHS Public Access. *IEEE Trans Biomed Eng*, 66(8), 2306–2318. <https://doi.org/10.1109/TBME.2018.2887208>
- Bae, J. K., Roh, H.-J., S, J. Y., Kim, K., Ahn, Y., Askaruly, S., ... Jung, W. (2020). Quantitative Screening of Cervical Cancers for Low-Resource Settings: Pilot Study of Smartphone-Based Endoscopic Visual Inspection After Acetic Acid Using Machine Learning Techniques. *JMIR Mhealth Uhealth*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7097827/>
- Bai, B., Du, Y., Liu, P., Sun, P., Li, P., & Lv, Y. (2020). Detection of cervical lesion region from colposcopic images based on feature reselection. *Biomedical Signal Processing and Control*, 57, 101785. <https://doi.org/10.1016/j.bspc.2019.101785>
- Benedetti, J. (2019). Description of Skin Lesions. In *Merck and the Merck Manuals*. Merck & Co., Inc.,.
- Chauhan, A. S., Prinja, S., Srinivasan, R., Rai, B., Malliga, J. S., Jyani, G., Ghoshal, S. (2020). Cost effectiveness of strategies for cervical cancer prevention in India. *PLoS ONE*, 15(9 September). <https://doi.org/10.1371/journal.pone.0238291>

- Cubie, H. A., & Campbell, C. (2020). Cervical cancer screening – The challenges of complete pathways of care in low-income countries: Focus on Malawi. *Women's Health*, 16. <https://doi.org/10.1177/1745506520914804>
- Diez, P. (2018). Chapter 1 - Introduction. In *Chiral Analysis* (Second Edi). <https://doi.org/10.1016/B978-0-12-812892-3/00001-7>
- Ding, L. (2018). Human Knowledge in Constructing AI Systems - Neural Logic Networks Approach towards an Explainable AI. *Procedia Computer Science*, 126, 1561–1570. <https://doi.org/10.1016/j.procs.2018.08.129>
- Fernandes, K., Cardoso, J. S., & Fernandes, J. (2018). Automated Methods for the Decision Support of Cervical Cancer Screening Using Digital Colposcopies. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2018.2839338>
- Globocan. (2021). Data Cancer in Indonesia 2020. *International Agency for Research o Cancer*, 858, 2020–2021.
- Guo, P., Xue, Z., Mtema, Z., Yeates, K., Ginsburg, O., Demarco, Ma., ... Antani, S. (2020). Ensemble Deep Learning for Cervix Image Selection toward Improving Reliability in Automated Cervical Precancer Screening. *MDPI*.
- Gutiérrez-fragoso, K., Acosta-mesa, H. G., Cruz-ramírez, N., & Hernández-jiménez, R. (2017). Optimization of Classification Strategies of Acetowhite Temporal Patterns towards Improving Diagnostic Performance of Colposcopy. *Hindawi*, 2017.
- Hacıefendioğlu, K., Başağa, H. B., Yavuz, Z., & Karimi, M. T. (2021). Intelligent ice detection on wind turbine blades using semantic segmentation and class activation map approaches based on deep learning method. *Renewable Energy*. <https://doi.org/10.1016/j.renene.2021.10.025>
- Hilal, Z., Tempfer, C. B., Burgard, L., Rehman, S., & Reznicek, G. A. (2020). How long is too long? Application of acetic acid during colposcopy: a prospective study. *The American Journal of Obstetrics & Gynecology*, 223(1), 101.e1-101.e8. <https://doi.org/10.1016/j.ajog.2020.01.038>
- Hoiem, D., Chodpathumwan, Y., & Dai, Q. (2012). Diagnosing error in object detectors. *ECCV*.
- Hwang, Y., Lee, H. H., Park, C., Tama, B. A., Kim, J. S., Cheung, D. Y., ... Lee, B. I. (2021). Improved classification and localization approach to small bowel

- capsule endoscopy using convolutional neural network. *Digestive Endoscopy*, 33(4), 598–607. <https://doi.org/10.1111/den.13787>
- Jackson, P. (1998). Introduction to expert systems (3rd ed.). *Boston, MA: Addison-Wesley Longman Publishing Co., Inc.*.
- Ji, Q., Huang, J., He, W., & Sun, Y. (2019). Optimized deep convolutional neural networks for identification of macular diseases from optical coherence tomography images. *Algorithms*, 12(3), 1–12. <https://doi.org/10.3390/a12030051>
- Johns, E., Mac Aodha, O., & Brostow, G. J. (2015). Becoming the expert—interactive multi-class machine teaching. *CVPR*.
- Karabağ, C., Jones, M. L., Peddie, C. J., Weston, A. E., Collinson, L. M., & Reyes-Aldasoro, C. C. (2020). Semantic segmentation of HeLa cells: An objective comparison between one traditional algorithm and four deep-learning architectures. *PLoS ONE*. <https://doi.org/10.1371/journal.pone.0230605>
- Karpathy, A. (2014). What I learned from competing against a ConvNet on ImageNet. Retrieved from <http://karpathy.github.io/2014/09/02/what-i-learned-from-competing-against-a-convnet-on-imagenet/>.
- Kiptoo, S., Nderu, L., & Mutanu, L. (2020). *Automated Detection of Cervical Precancerous Lesions Using Regional-Based Convolutional Neural Network*.
- Kudva, V., Prasad, K., & Guruvare, S. (2017). Detection of Specular Reflection and Segmentation of Cervix Region in Uterine Cervix Images for Cervical Cancer Screening. *Irbm*, 38(5), 281–291. <https://doi.org/10.1016/j.irbm.2017.08.003>
- Kudva, V., Prasad, K., & Guruvare, S. (2018). Andriod Device-Based Cervical Cancer Screening for Resource-Poor Settings. *Journal of Digital Imaging*, 31(5), 646–654. Retrieved from <http://www.embase.com/search/results?subaction=viewrecord&from=export&id=L628820036%0Ahttp://dx.doi.org/10.1007/s10278-018-0083-x>
- Kudva, Vidya, Prasad, K., & Guruvare, S. (2018). Automation of detection of cervical cancer using convolutional neural networks. *Critical Reviews in Biomedical Engineering*, 46(2), 135–145. <https://doi.org/10.1615/CritRevBiomedEng.2018026019>
- Kudva, Vidya, Prasad, K., & Guruvare, S. (2020). Hybrid Transfer Learning for

- Classification of Uterine Cervix Images for Cervical Cancer Screening. *Journal of Digital Imaging*, 33(3), 619–631. <https://doi.org/10.1007/s10278-019-00269-1>
- Lange, H. (2005). Automatic detection of multi-level acetowhite regions in RGB color images of the uterine cervix. *Medical Imaging*, 5747, 1004–1017. <https://doi.org/10.1117/12.596064>
- Lashgari, E., Liang, D., & Maoz, U. (2020). Data augmentation for deep-learning-based electroencephalography. *Journal of Neuroscience Methods*, 346(February), 108885. <https://doi.org/10.1016/j.jneumeth.2020.108885>
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2021). Explainable ai: A review of machine learning interpretability methods. *Entropy*, 23(1), 1–45. <https://doi.org/10.3390/e23010018>
- Liu, J., Li, L., & Wang, L. (2017). *Acetowhite region segmentation in uterine cervix images using a registered ratio image*. <https://doi.org/10.1016/j.combiomed.2017.12.009>
- Liu, J., Yun, P., & Yingchun, Z. (2019). A Fuzzy Reasoning Model for Cervical Intraepithelial Neoplasia Classification Using Temporal Grayscale Change and Textures of Cervical Images During Acetic Acid Tests. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2019.2893357>
- Masakazu Sato, Horie, K., Hara, A., Miyamoto, Y., Kurihara, K., Tomio, K., & Yokota, H. (2018). *Application of deep learning to the classification of images from colposcopy*. 3518–3523. <https://doi.org/10.3892/ol.2018.7762>
- Miyagi, Y., Takehara, K., Nagayasu, Y., & Miyake, T. (2020). Application of deep learning to the classification of uterine cervical squamous epithelial lesion from colposcopy images combined with HPV types. *ONCOLOGY LETTERS*, 19, 1602–1610. <https://doi.org/10.3892/ol.2019.11214>
- Özdemir, Ö., & Sönmez, E. B. (2021). Attention mechanism and mixup data augmentation for classification of COVID-19 Computed Tomography images. *Journal of King Saud University - Computer and Information Sciences*, (xxxx). <https://doi.org/10.1016/j.jksuci.2021.07.005>
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., Bhardwaj, P., & Singh, V. (2020). A deep learning and grad-CAM based color visualization

- approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons and Fractals*, 140, 110190. <https://doi.org/10.1016/j.chaos.2020.110190>
- Park, Y. R., Kim, Y. J., Ju, W., Nam, K., Kim, S., & Kim, K. G. (2021). Comparison of machine and deep learning for the classification of cervical cancer based on cervicography images. *Scientific Reports*, 1–11. <https://doi.org/10.1038/s41598-021-95748-3>
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLoS ONE*, 10(3). <https://doi.org/10.1371/journal.pone.0118432>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Proceedings of the IEEE International Conference on Computer Vision, 2017-Octob*, 618–626. <https://doi.org/10.1109/ICCV.2017.74>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2020). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *International Journal of Computer Vision*, 128(2), 336–359. <https://doi.org/10.1007/s11263-019-01228-7>
- Setiawan, W., & Damayanti, F. (2019). Layers Modification of Convolutional Neural Network for Pneumonia Detection Layers Modification of Convolutional Neural Network for Pneumonia Detection. *ICComSET*. <https://doi.org/10.1088/1742-6596/1477/5/052055>
- Sharma, M., Kumar Singh, S., Agrawal, P., & Madaan, V. (2016). Classification of Clinical Dataset of Cervical Cancer using KNN. *Indian Journal of Science and Technology*, 9(28). <https://doi.org/10.17485/ijst/2016/v9i28/98380>
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*.
- Srivastava, A., Sinha, P., Vatsal, P., Khatoon, F., & Lal, N. (2020). Visual Inspection with Acetic Acid Versus Papanicolaou Test in Cervical Cancer Screening. *Indian Journal of Gynecologic Oncology*. <https://doi.org/10.1007/s40944-020-00438-z>

- Su, J., Xu, X., He, Y., & Song, J. (2016). Automatic Detection of Cervical Cancer Cells by a Two-Level Cascade Classification System. *Analytical Cellular Pathology*, 2016, 10–13. <https://doi.org/10.1155/2016/9535027>
- Sukumar, P., & Gnanamurthy, R. K. (2016). Computer aided screening of cervical cancer using random forest classifier. *Research Journal of Pharmaceutical, Biological and Chemical Sciences*, 7(1), 1521–1529.
- Sze, V., Chen, Y.-H., Yang, T.-J., & Emer, J. (2017). *Efficient Processing of Deep Neural Networks: A Tutorial and Survey*. 1–32.
- Tammina, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), p9420. <https://doi.org/10.29322/ijrsp.9.10.2019.p9420>
- Wang, P., Wang, L., Li, Y., Song, Q., Lv, S., & Hu, X. (2019). Automatic cell nuclei segmentation and classification of cervical Pap smear images. *Biomedical Signal Processing and Control*, 48, 93–103. <https://doi.org/10.1016/j.bspc.2018.09.008>
- William, W., Ware, A., Basaza-Ejiri, A. H., & Obungoloch, J. (2018). A review of image analysis and machine learning techniques for automated cervical cancer screening from pap-smear images. *Computer Methods and Programs in Biomedicine*, 164, 15–22. <https://doi.org/10.1016/j.cmpb.2018.05.034>
- Wu, S., Zhong, S., & Liu, Y. (2015). Deep residual learning for image Recognition. *Multimedia Tools and Applications*, 1–17. <https://doi.org/10.1007/s11042-017-4440-4>
- Xu, T., Kim, E., & Huang, X. (2015). *Adjustable Adaboost Classifier And Features for Image-Based Cervical Cancer Diagnosis*. 281–285.
- Yan, L., Song, H., Guo, Y., Ren, P., Zhou, W., Li, S., ... Shen, X. (2022). HLDnet: Novel deep learning based Artificial Intelligence tool fuses acetic acid and Lugol's iodine cervicograms for accurate pre-cancer screening. *Biomedical Signal Processing and Control*, 71, 103163. <https://doi.org/10.1016/j.bspc.2021.103163>
- Yildiz, A., Zan, H., & Said, S. (2021). Classification and analysis of epileptic EEG recordings using convolutional neural network and class activation mapping.

- Biomedical Signal Processing and Control*, 68(January), 102720.
<https://doi.org/10.1016/j.bspc.2021.102720>
- Zhang, T., Luo, Y., Li, P., Liu, P., Du, Y., & Sun, P. (2020). Cervical precancerous lesions classification using pre-trained densely connected convolutional networks with colposcopy images. *Biomedical Signal Processing and Control*, 55, 101566. <https://doi.org/10.1016/j.bspc.2019.101566>
- Zhang, Y., Hong, D., McClement, D., Oladosu, O., Pridham, G., & Slaney, G. (2021). Grad-CAM helps interpret the deep learning models trained to classify multiple sclerosis types using clinical brain magnetic resonance imaging. *Journal of Neuroscience Methods*, 353(February), 109098. <https://doi.org/10.1016/j.jneumeth.2021.109098>
- Zhao, M., Wu, A., Song, J., Sun, X., & Dong, N. (2016). Automatic screening of cervical cells using block image processing. *BioMedical Engineering Online*. <https://doi.org/10.1186/s12938-016-0131-z>
- Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning Deep Features for Discriminative Localization. *Academy of Management Proceedings*, 2016(1), M1–M6. <https://doi.org/10.5465/ambpp.2004.13862426>