

Periode : Semester Genap
Tahun : 2020
Skema Penelitian : Penelitian Terapan
Tema RIP : Teknologi Informasi & Komunikasi

**LAPORAN
PROGRAM PENELITIAN**

**PENGEMBANGAN *FRAMEWORK* KANKERNET
BERDASARKAN *CONVOLUTIONAL NEURAL NETWORKS*
DAN MODEL PSO UNTUK PENYAKIT KANKER SERVIKS**



Oleh:

**Habibullah Akbar, S.Si., M.Sc., Ph.D
Sandfreni, S.SI, M.T**


**Fakultas Ilmu Komputer
Program Studi Magister Ilmu Komputer
Universitas Esa Unggul
2021**

**Halaman Pengesahan Laporan
Program Penelitian
Universitas Esa Unggul**


1. Judul Kegiatan Penelitian : Pengembangan Framework KankerNet Berdasarkan *Convolutional Neural Networks* dan Model PSO untuk Penyakit Kanker Serviks
2. Ketua Tim
 - a. Nama : Habibullah Akbar, S.Si.,M.Sc., Ph.D
 - b. NIDN : 0315108201
 - c. Jabatan Fungsional : Lektor
 - d. Fakultas/Prodi : Fakultas Ilmu Komputer / Magister Ilmu Komputer
 - e. Bidang Keahlian : Kecerdasan Buatan
 - f. Telepon : 081319110259
 - g. E-mail : habibullah.akbar@esaunggul.ac.id
3. Jumlah Anggota Dosen : 1 orang
4. Lokasi Penelitian : Universitas Esa Unggul
5. Periode/waktu kegiatan : April – Maret 2020
6. Luaran yang dihasilkan : Publikasi pada Jurnal Informatika dan Komputer
7. Anggaran
 - a. Dana Internal UEU : Rp. 22.000.000

Jakarta, 29 Juli 2021

Mengetahui,
Wakil Rektor Bidang Akademik dan Pendidikan


(Endah Murtiana Sari, ST, MM)
NIK. 219050796

Ketua Peneliti


(Habibullah Akbar, S.Si, M.Sc, PhD)
NIK. 218030726

Mengetahui,
Ketua LPPM Universitas Esa Unggul

Dr. Erry Yudhya Mulyani, M.Sc
NIP/NIK. 209100388

DAFTAR ISI


Bab 1. Pendahuluan.....	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah.....	2
1.3 Tujuan Penelitian.....	3
1.4 Manfaat Penelitian.....	3
1.5 Hasil yang diharapkan.....	4
Bab 2. Renstra dan Peta Jalan Penelitian Perguruan Tinggi.....	5
Bab 3. Tinjauan Pustaka dan Landasan Teori.....	9
3.1 Tinjauan Pustaka.....	9
3.2 Landasan Teori.....	10
3.2.1 Arsitektur <i>Convolutional Neural Network</i> (CNN).....	10
3.2.2 Optimisasi <i>Particle Swarm Optimization</i> (PSO).....	13
Bab 4. Metode Penelitian.....	15
4.1 Metode Eksperimental.....	15
4.2 Tahapan Penelitian.....	15
Bab 5. Hasil dan Pembahasan.....	21
5.1 Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter epoch	21
5.2 Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter	25
<i>minibatch</i> dan <i>learning rate</i>	
5.3 Hasil Eksperimen Sensitifitas terhadap Rasio Data <i>Training</i>	
dan <i>Testing</i>	26
5.4 Hasil Eksperimen Sensitifitas terhadap Jumlah Lapisan Konvolusi	27
5.5 Hasil Eksperimen Pengaruh metode optimisasi <i>Particle Swarm</i>	
<i>Optimization</i> (PSO) dan Parameter <i>Dropout</i> terhadap Arsitektur	
AlexNet.....	29
5.6. Rangkuman Hasil Eksperimen.....	30
Bab 6. Kesimpulan dan Saran.....	32
6.1 Kesimpulan.....	32
6.2. Saran.....	32
Daftar Pustaka.....	33
Lampiran.....	35

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Kanker serviks termasuk kanker jenis yang paling umum setelah kanker payudara. Setiap tahun, sekitar setengah juta perempuan diseluruh dunia yang terdiagnosis positif kanker serviks dengan angka kematian lebih dari 300.000 (Cohen, Jhingran, Oaknin, & Denny, 2019). Di Indonesia sendiri kanker serviks berada di urutan keempat yang meningkat dari 1,4 per 1000 penduduk pada tahun 2013 menjadi 1,8 per 1000 penduduk pada tahun 2018 (Khatimah & Sofiana, 2019). Tingkat prevalensi angka kejadian yang cukup tinggi tersebut tentunya memerlukan perhatian baik pihak pemerintah, swasta, dan masyarakat dalam upaya pencegahan, pengobatan dan pengendalian penyakit kanker serviks. Angka kematian mencapai 18.279 per tahun kasus kanker serviks di Indonesia.

Artinya setiap hari sekitar 50 perempuan Indonesia meninggal dunia. Gambar 1.1 memberikan ilustrasi secara visual tentang penampakan sel kanker serviks nampak tidak lebih sulit untuk diklasifikasi dibandingkan dengan sel kanker payudara. Berikut ini adalah perbandingan gambar kanker payudara dan gambar kanker serviks. Namun demikian bagaimana performa model CNN lainnya seperti AlexNet terhadap gambar kanker serviks masih belum diketahui.



Gambar 1.1 Perbandingan gambar (a) sel kanker payudara (Żejmo, Kowal, Korbicz, & Monczak, 2017) dan (b) sel kanker serviks (Payette, Rachleff, & de Graaf, 2017).

Penyakit kanker serviks adalah bermula dari pertumbuhan sel yang tidak teratur dan sel-sel ini dapat menyerang organ biologis lainnya baik dengan pertumbuhan langsung di jaringan yang bersebelahan atau dengan migrasi ke sel lainnya (metastasis). Pertumbuhan yang tidak teratur dapat menyebabkan kerusakan DNA, yang mengakibatkan mutasi di gen vital yang mengontrol pembagian sel, dan fungsi lainnya. Jika sudah parah, pertumbuhan sel akan menjadi tumor ganas yang menyerang jaringan di mulut rahim. Penyebab utama dari kanker serviks adalah infeksi Human Papiloma Virus, meskipun terdapat beberapa faktor lain yang juga dapat mempengaruhi progresifitas kanker.

Umumnya, tes kanker serviks dapat dilakukan dengan *pap smear*, pemeriksaan HPV, dan pemeriksaan IVA yang didukung dengan tes pencitraan/gambar medis seperti CT scan, mikroskopis dan MRI. Perkembangan teknologi kecerdasan buatan seperti *deep learning* yaitu model *Convolutional neural network* (CNN) dapat dilatih untuk melakukan segmentasi otomatis terhadap sel kanker ataupun mendeteksi potensi kanker berdasarkan citra medis yang diambil dari pasien (Liu et al., 2020; Wang, Wang, Li, Li, & Zhang, 2020). Namun teknologi CNN ini masih memerlukan penelitian agar benar-benar dapat dikembangkan menjadi alat bantu dokter spesialis patologi dalam melakukan diagnosis kanker serviks berdasarkan gambar medis pasien.

1.2 Identifikasi Masalah

Convolutional neural network (CNN) sudah mulai digunakan untuk dalam mendeteksi potensi kanker dari gambar medis. (Ciresan, Giusti, Gambardella, & Schmidhuber, 2013) membangun model *Convolutional neural network* (CNN) untuk mendeteksi mitosis pada sel kanker pada gambar histologi. Penelitian yang lebih mendalam mengenai klasifikasi kanker telah dilakukan oleh (Araújo et al., 2017). Selain itu, (Sornapudi et al., 2018) telah berhasil menggunakan model LeNet yang sudah dimodifikasi dengan variasi lapisan dan parameter untuk mengurangi beban memori dan komputasi.

CNN juga dapat digunakan untuk segmentasi kanker serviks tanpa harus melakukan klasifikasi (Song et al., 2014). Yang lebih menarik lagi, penelitian yang dilakukan oleh (Rasti, Teshnehlab, & Phung, 2017) mampu menggabungkan metode segmentasi dan klasifikasi pada kanker dalam satu *framework* diagnosis. Selain itu, varian CNN seperti GoogLeNet dan AlexNet juga telah diterapkan untuk klasifikasi langsung kanker pada gambar hispatologi yang diambil dari sampel biopsi tanpa melibatkan proses segmentasi (Žejmo et al., 2017).

Dari penelitian-penelitian yang telah dilakukan sebelumnya, model CNN yang digunakan tidak dijamin optimal. Hal ini disebabkan, para peneliti masih secara manual ataupun dengan proses *trial-and-error* dalam menentukan konfigurasi gabungan dari parameter-parameter yang paling tepat untuk memberikan performa yang baik. Padahal optimisasi parameter-parameter dari model CNN harusnya dapat dilakukan belum menggunakan pendekatan otomatis seperti *metaheuristics* (Hamidinekoo, Denton, Rampun, Honnor, & Zwigelaar, 2018). Sayangnya, belum banyak penelitian yang telah memadukan CNN dengan optimisasi *metaheuristics* yang mampu mencari konfigurasi parameter yang tepat untuk menghasilkan performa akurasi dan efisiensi terbaik.

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk

1. Mengembangkan *framework* AlexNet berdasarkan arsitekturnya yang terdiri jumlah lapisan *convolutional*, *rectified linear unit (ReLU)*, *pooling*, *fully connected*, dan *softmax*.
2. Menguji parameter *epoch*, *minibatch*, *learning rate*, resolusi gambar input, rasio data *training* dan *testing*, ukuran dataset, dan *dropout*. Kemudian melakukan optimisasi parameter yang paling berpengaruh terhadap akurasi AlexNet berdasarkan metode *particle swarm optimization*.
3. Mengevaluasi performa dari *framework* CNN yang dikembangkan menggunakan *dataset* standar untuk gambar kanker serviks.

1.4 Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Mengembangkan teknologi *deep learning* (kecerdasan buatan) seiring dengan tren perkembangan revolusi industri 4.0 untuk penerapan di bidang kesehatan. *Framework* usulan akan diberi nama KankerNet, menggunakan istilah yang berasal dari Bahasa Indonesia agar arsitektur *convolutional neural networks* ini dapat diperkenalkan dan dipromosikan ke dunia luar.
2. Mengembangkan metodologi deteksi dini untuk penyakit kanker berdasarkan kecerdasan buatan yang sudah dioptimisasi menggunakan pendekatan *Particle Swarm Optimization (PSO)*. Penggunaan metode *metaheuristics* ini dapat menarik para peneliti lain untuk

menerapkan algoritma optimisasi lainnya seperti *artificial immune system*, *gravitational search*, dan *ant colony optimisation*.

3. Menyediakan *framework* teknologi untuk membantu para dokter dan pihak layanan kesehatan dengan sistem deteksi dini namun bukan untuk menggantikan dokter. Sehingga, upaya pencegahan dan penanganan kanker serviks di Indonesia diharapkan dapat dilakukan dengan lebih baik untuk kedepannya.

1.5 Hasil yang diharapkan

Hasil yang diharapkan dari penelitian ini adalah didapatkannya kerangka kerja klasifikasi yang dapat dioptimisasi agar memudahkan pencarian hyperparameter dari arsitektur *convolutional neural network* AlexNet yang digunakan untuk melakukan klasifikasi tipe kanker serviks berdasarkan input gambar.

BAB 2. RENSTRA DAN PETA JALAN PENELITIAN PERGURUAN TINGGI

Berdasarkan skema strategi nasional, Universitas Esa Unggul telah menetapkan Rencana Induk Penelitian (RIP) 2017-2021 yang mencakup 7 bidang unggulan penelitian, yaitu:

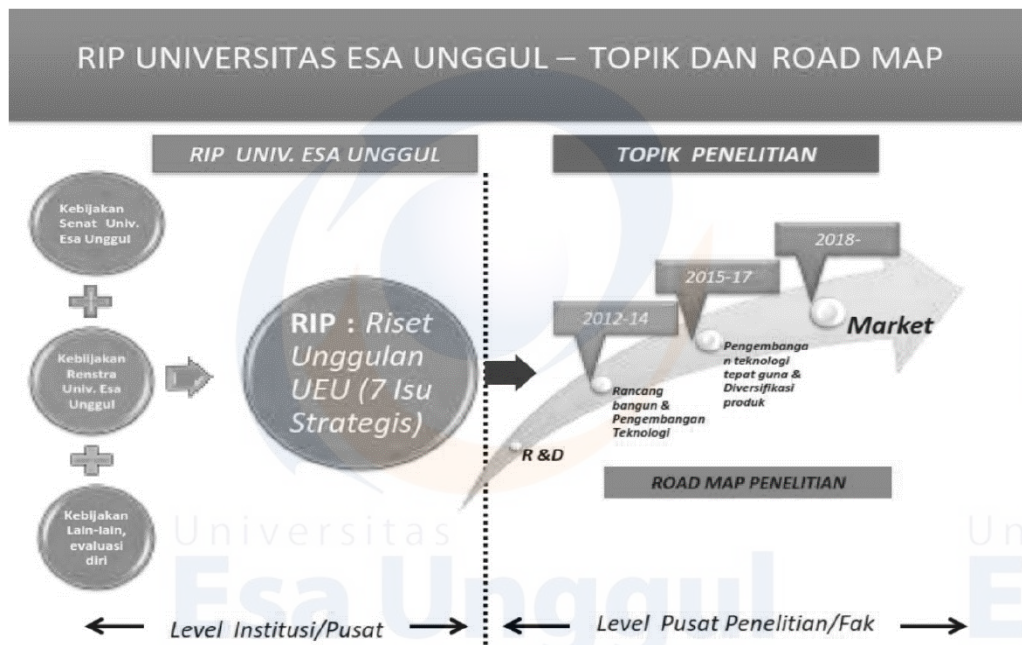
1. Pengentasan Kemiskinan (*Poverty Alleviation*) dan Ketahanan & Keamanan Pangan (*Food Safety & Security*)
2. Pemanfaatan Energi Baru dan Terbarukan (*New And Renewable Energy*)
3. Kualitas Kesehatan, Penyakit Tropis, Gizi & Obat-Obatan (*Health, Tropical Diseases, Nutrition & Medicine*)
4. Penerapan Pengelolaan Bencana (*Disaster Management*) dan Integrasi Nasional & Harmoni Sosial (*Nation Integration & Social Harmony*)
5. Implementasi Otonomi Daerah & Desentralisasi (*Regional Autonomy & Decentralization*)
6. Pengembangan Seni & Budaya/Industri Kreatif (*Arts & Culture/ Creative Industry*) dan Teknologi Informasi & Komunikasi (*Information & Communication Technology*)
7. Pembangunan Manusia & Daya Saing Bangsa (*Human Development & Competitiveness*)

Perencanaan penelitian dan pengambilan keputusan dalam pengelolaan penelitian institusi diarahkan untuk Mewujudkan Hasil Penelitian Berkualitas dan Sustainable. Dari topik-topik tersebut, telah ditetapkan basis roadmap penelitian Universitas Esa Unggul seperti yang ditunjukkan pada Gambar 2.1.

Dari roadmap universitas, fakultas menetapkan kebijakan pengembangan bidang penelitian dengan memberikan prioritas penelitian sebagai berikut:

1. Mengintegrasikan Lab-lab yang ada berbasis pada kompetensi keilmuan, dan terwujudnya jalinan pengembangan iptek dengan sasaran menjadi pusat penelitian unggulan di tingkat fakultas.
2. Meningkatkan peran Laboratorium dalam kegiatan penelitian dan pengabdian kepada masyarakat.
3. Menentukan Road map unggulan Fasilkom-UEU.
4. Memfasilitasi Doktor untuk memotori penelitian yang mengarah pada penelitian kompetitif tingkat nasional dan internasional

5. Mendorong Dosen Fasilkom untuk melakukan kerjasama penelitian dengan pihak stakeholder.
6. Program pembinaan penelitian dosen muda oleh Doktor.
7. Mengidentifikasi potensi sumberdaya dan permasalahan lokal yang bisa diangkat menjadi penelitian untuk kepentingan masyarakat.
8. Membangun inkubator penelitian ditingkat program studi bersinergi dengan Fakultas dan Universitas.
9. Membangun sistem data base produk penelitian dan sumber daya.

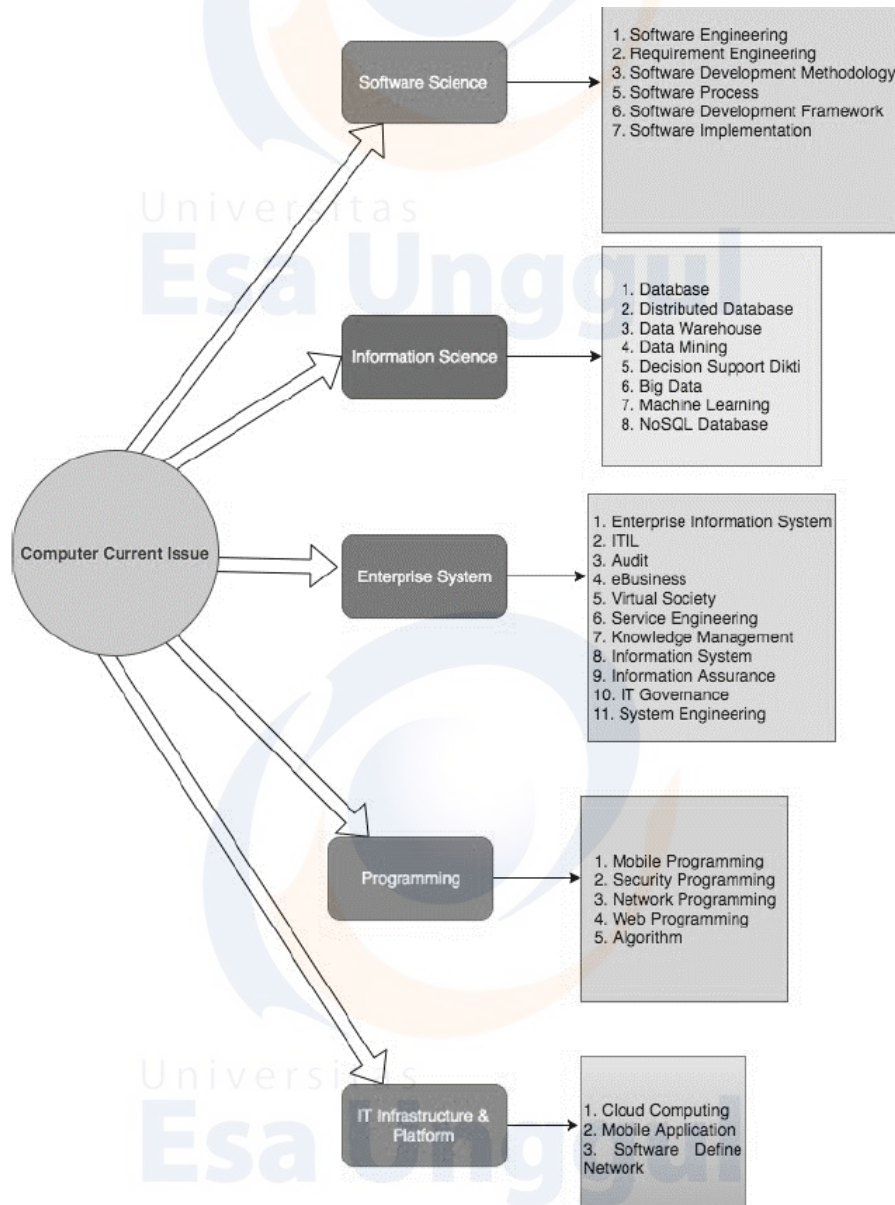


Gambar 2.1 Basis *Roadmap* Penelitian Universitas Esa Unggul
(Sumber Pedoman Penyusunan RIP – RISTEKDIKTI)

Strategi pengembangan RIP Fakultas Ilmu Komputer adalah menghasilkan penelitian serta penerapan dan inovasi teknologi informasi tepat guna dalam rangka terciptanya kemampuan individu, organisasi, dan masyarakat berbasis pengetahuan dan teknologi. Teknologi merupakan suatu industri yang berkembang pesat di dunia dan sangat membutuhkan inovasi-inovasi terbaru didalamnya. Fasilkom-UEU memiliki potensi menjawab tantangan tersebut. Adapun tantangan tersebut, agar dapat berjalan dan terwujud maka penyusunan Rencana Induk Penelitian (RIP) merupakan hal yang penting untuk dilakukan. RIP yang dirancang tersusun

dari Roadmap-Roadmap yang mempertimbangkan faktor lingkungan eksternal (peluang dan tantangan) dan lingkungan internal (kekuatan dan kelemahan) Fasilkom-UEU.

Selain itu, RIP juga didasarkan pada ketersediaan sumberdaya, serta dinamika akademis yang berkembang baik di tingkat nasional maupu internasional. Adapun Garis besar RIP bidang penelitian dan PkM dari Fasilkom-UEU dirancang berdasarkan pada beberapa strategi yang tercakup didalam Roadmap penelitian Fasilkom UEU dapat dilihat pada gambar 2.2. Adapun topik penelitian pada penelitian ini berada dalam cakupan bidang ilmu *information science* dengan sub bidang ilmu *machine learning*. Berdasarkan *roadmap* penelitian universitas dan *roadmap* fakultas, maka penelitian dan pengembangan tidak boleh dibatasi pada kajian teoretis dan laboratorial belaka. Namun, penelitian yang kami usulkan memiliki arah mulai dari R&D, rancang bangun, pengembangan teknologi tepat guna, hingga komersialiasi pasar sehingga luaran penelitian dapat berguna bagi masyarakat.



Gambar 2.2 *Roadmap* Penelitian Fakultas Ilmu Komputer. Terdapat 5 bidang ilmu utama yaitu *Software Science*, *Information Science*, *Enterprise System*, *Programming*, dan *IT Infrastructure & Platform*.

BAB 3. TINJAUAN PUSTAKA DAN LANDASAN TEORI

3.1 Tinjauan Pustaka

Perkembangan *deep learning* yaitu jaringan saraf tiruan yang dapat melakukan ekstraksi fitur langsung dari data mentah telah menarik minat penelitian di bidang analisis gambar medis untuk deteksi kanker. Berbagai macam convolutional neural networks (CNN) telah dikembangkan untuk mengklasifikasi penyakit kanker. GoogLeNet dan AlexNet telah diterapkan untuk klasifikasi kanker pada gambar hispatologi yang diambil dari sampel biopsi (Żejmo et al., 2017). Adapun (Ciresan et al., 2013) menggunakan CNN untuk mendeteksi mitosis yang merupakan indikator penting dari kanker pada gambar histologi. Sayangnya kedua penelitian tersebut masih kesulitan dalam mencari parameter terbaik dalam model CNN yang dikembangkan.

Pengklasifikasian kanker yang lebih detail dilakukan oleh penelitian (Araújo et al., 2017). Mereka menggunakan CNN untuk menentukan apakah gambar histologi mengindikasikan salah satu dari 4 kondisi penyakit yaitu: i) jaringan normal, ii) lesi jinak, iii) karsinoma in situ dan iv) karsinoma invasif. Mereka membandingkan performa prediksi CNN dengan SVM. Anehnya, akurasi keseluruhan SVM masih lebih baik dari CNN sebesar 2%. Hal ini nampaknya disebabkan model CNN yang digunakan belum mencapai performa yang optimal.

Selain untuk klasifikasi kanker, (Sornapudi et al., 2018) justru menggunakan model LeNet yang sudah dicoba dengan variasi lapisan dan parameter dengan tujuan mensegmentasi gambar histologi. Mereka menggunakan LeNet untuk mengurangi beban memori dan komputasi. LeNet digunakan untuk membedakan apakah sebuah piksel mengandung nuclei (indikator kanker serviks) atau tidak. Penelitian (Rasti et al., 2017) menggabungkan metode segmentasi dan klasifikasi pada kanker. Kandidat tumor disegmentasi dengan menggunakan metode Otsu dan klasifikasi tumor menggunakan CNN.

Namun demikian, penelitian-penelitian tersebut lebih menitik-beratkan pada percobaan manual dalam menentukan parameter lapisan maupun tambahan fungsionalitas segmentasi dan mengabaikan pentingnya efek nilai dari parameter yang digunakan. Baru-baru ini, (Arefan et al., 2020) mengkombinasikan CNN dengan *Linear Discriminant Analysis* klasifikator. Namun demikian mereka mengakui model yang diusulkan belum optimal karena masih membutuhkan proses trial-and-error dalam menentukan nilai dari konfigurasi parameter yang digunakan.

Dari keseluruhan penelitian-penelitian tersebut, optimasi model klasifikasi masih digunakan secara manual dengan menentukan konfigurasi gabungan dari parameter-parameter dengan proses *trial-and-error*. Hal ini diperkuat dengan paper review yang diterbitkan oleh Elsevier *Medical Image Analysis* (Hamidinekoo et al., 2018) yang menunjukkan bahwasanya optimisasi parameter menggunakan pendekatan *metaheuristics* masih menjadi *open question* dalam bidang penelitian CNN untuk bidang *medical imaging*. Hal ini menunjukkan peluang penelitian yang cukup penting karena kebutuhan optimisasi model machine learning merupakan hal yang sangat penting agar hasil penelitian dapat diterapkan secara nyata untuk perbaikan layanan kesehatan deteksi penyakit kanker.

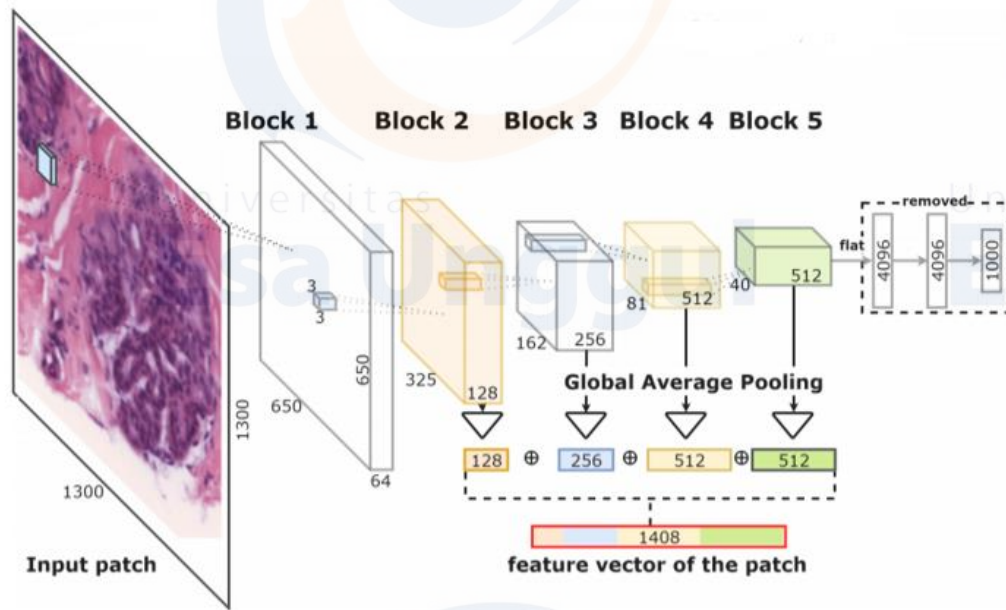
Adapun penelitian yang kami usulkan bertujuan untuk mengoptimisasi proses *training* dari model CNN menggunakan pendekatan optimisasi *metaheuristics* sehingga penentuan nilai parameter dari model klasifikator yang terbaik dapat dilakukan secara otomatis. Pendekatan *metaheuristics* yang akan diambil berasal dari metode *Particle Swarm Optimization* (PSO) yang secara acak mampu secara iteratif mencari kandidat parameter terbaik secara otomatis untuk mencapai performa akurasi dan efisiensi yang terbaik tanpa harus melalui proses *tuning* parameter secara *trial-and-error*.

3.2 Landasan Teori

Dua konsep utama yang akan menjadi basis penelitian ini adalah *convolutional neural network* dan *particle swarm optimization*. *Convolutional neural network* akan digunakan untuk mentransformasikan input gambar menjadi label penyakit. Adapun *particle swarm optimization* akan digunakan untuk mencari model *convolutional neural network* yang dapat memberikan nilai akurasi dan efisiensi yang terbaik.

3.2.1 Arsitektur Convolutional Neural Network (CNN) AlexNet


Convolutional Neural Network (CNN) adalah sebuah representasi dari fungsi atau matematis yang dapat mendeteksi konten visual dari sebuah gambar medis. Ilustrasi model CNN AlexNet yang digunakan untuk melakukan prediksi kanker serviks otomatis dari input gambar diberikan pada gambar 3.1.



Gambar 3.1 Arsitektur *convolutional neural networks* untuk prediksi penyakit kanker (Rakhlin, Shvets, Iglovikov, & Kalinin, 2018).

Arsitektur CNN diatas dari beberapa struktur yaitu:

1. **Input patch.** Data masukan yang dapat diterima CNN adalah *input* gambar atau *patch* gambar. Contoh gambar untuk 4 kategori kanker serviks yaitu normal, tumor jinak, *carcinoma in situ*, dan *invasive carcinoma* dapat dilihat pada gambar 3.2. Jika gambar normal diabaikan maka jumlah kategori kanker serviks hanya berjumlah 3 seperti pada dataset yang akan digunakan (Intel, 2017).



Gambar 3.2 Contoh gambar mikroskopik dari prosedur biopsi: (A) normal; (B) tumor jinak; (C) *carcinoma in situ*; (D) *invasive carcinoma* (Rakhlin et al., 2018)

2. **Blocks.** Setiap blok CNN terdiri atas 3 lapisan yaitu lapisan konvolusi, ReLU, dan *pooling*.
 - a. **Lapisan konvolusi** menerima *input patch* yang terdiri dari piksel-piksel. Lapisan ini terdiri dari kumpulan filter yang diinisialisasi secara acak untuk mencari representasi fitur dari suatu gambar berdasarkan kategori label penyakit. Setiap filter mengandung matrik saraf sebagai *receptive field* yang dimana nilai setiap sel saraf

akan dilatih untuk mendeteksi fitur dari yang paling sederhana seperti *edge*, *curve* hingga *cell parts*.

- b. **Lapisan ReLU** akan menentukan apakah sinyal dari lapisan konvolusi dapat diteruskan pada lapisan berikutnya atau tidak. Bentuk fungsi ReLU dapat dinyatakan dengan $f(x)=\max(0,x)$ yang artinya akan memotong sinyal input yang memiliki nilai kurang dari 0.
- c. **Lapisan pooling** akan mengurangi beban komputasi dengan cara menurunkan ukuran gambar yang diteruskan dari lapisan ReLU dengan melakukan *down sampling*.

3. Lapisan *fully-connected*

Lapisan koneksi penuh merupakan lapisan *perceptron* yang menghimpun seluruh sinyal lapisan sebelumnya lalu memproses jumlah sinyal tersebut menggunakan fungsi *softmax*. Fungsi *softmax* diberikan pada persamaan berikut ini:

$$y_r(x) = \frac{\exp(y_r(x))}{\sum_{j=1}^k \exp(a_r(x))}$$

Setiap output dari perceptron didalam lapisan *fully-connected* akan menjadi input bagi fungsi *softmax* tersebut yang kemudian digunakan untuk menghitung probabilitas dari tipe kanker serviks. Jumlah *perceptron* yang digunakan biasanya 4096 dan kemudian akan dikurangi jumlahnya pada lapisan berikutnya hingga tersisa *neuron* sesuai dengan jumlah label yang ada (3 label). Label berisi kategori penyakit yang diberikan pada dataset.

Jumlah *block* yang diperlukan agar CNN dapat memberikan performa prediksi yang baik tidak diketahui pada awalnya. Pada gambar 3.1, blok yang digunakan berjumlah 5. Namun pada penelitian ini, jumlah blok maksimal yang digunakan hanya berjumlah 3. Hal ini disebabkan waktu komputasi yang dibutuhkan akan semakin besar jika jumlah blok semakin besar. Selain blok, terdapat parameter arsitektur lain yang harus ditentukan yaitu ukuran filter konvolusi, ukuran *sliding* pada lapisan pooling, jumlah *perceptron* dan jumlah lapisan *fully-connected*. Adapun untuk proses *training*, parameter yang perlu di-*tuning* adalah parameter *epoch*, *minibatch*, *learning rate*, resolusi gambar input, rasio data *training* dan *testing*, ukuran dataset, dan *dropout*.

Kombinasi dari parameter-parameter pada proses *training* CNN AlexNet ini disebut sebagai *hyperparameter*. Pada penelitian-penelitian sebelumnya, pemilihan nilai *hyperparameter* ini ditentukan secara manual dengan proses *trial-dan-error*. Proses ini memakan waktu eksperimen yang lama dan menyulitkan. Oleh karena itu, kami mengusulkan agar proses pencarian nilai optimal dari parameter dapat dilakukan secara otomatis menggunakan metode PSO.

3.2.2 Optimisasi *Particle Swarm Optimization* (PSO)

Untuk mengatasi proses *trial-dan-error* yang sulit dilakukan secara eksperimental, pendekatan optimisasi PSO cukup menjanjikan. Model PSO terinspirasi dari perilaku kolektif burung yang menunjukkan bentuk kecerdasan koloni sosial (komunitas). Penyederhanaan bagaimana burung dapat menyesuaikan gerakan fisik secara bersama-sama untuk mencari makanan, pasangan, dan menghindari pemangsa, telah dijadikan model optimisasi. Pada model *Particle Swarm Optimization* (PSO), setiap anggota dari kelompok hewan ini disebut sebagai partikel. Di ruang pencarian parameter D -dimensional, posisi partikel dapat dilambangkan sebagai $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$. Setiap partikel melakukan perubahan posisi menuju solusi optimal, melalui ruang pencarian, diarahkan oleh posisi partikel terbaik.

Setiap partikel dimodelkan dengan tiga komponen yaitu momentum, komponen kognitif dan sosial (Kennedy & Eberhart, 1995). Komponen momentum didasarkan pada kecepatan sebelumnya. Komponen kognitif didasarkan pada masing-masing pengalaman partikel, diwakili oleh posisi anggota terbaik p_i . Komponen sosial didasarkan pada seluruh pengalaman segerombolan, diwakili oleh p_{best} posisi terbaik dari anggota sebelumnya. Adapun kecepatan dan posisi terbaik yang telah dikunjungi partikel dapat direpresentasikan sebagai $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ dan $p_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ masing-masing.

Kemudian, posisi partikel selanjutnya dapat diperbarui secara heuristik berdasarkan aturan pergerakan berikut

$$x_{i+1} = x_i + v_{i+1}$$

Kecepatan partikel berikutnya v_{i+1} adalah kombinasi dari komponen momentum, kognitif dan sosial seperti yang ditunjukkan dalam persamaan di bawah ini.

$$v_{i+1} = 0.5 \cdot v_i + a_1 \cdot \text{rand}_1() \cdot (p_i - x_i) + a_2 \cdot \text{rand}_2() \cdot (p_{best} - x_i)$$

Variabel a_1 dan a_2 adalah laju pembelajaran akselerasi kognitif dan sosial masing-masing, umumnya kedua nilai tersebut ditetapkan dengan angka 1.4 untuk memungkinkan partikel untuk mencapai target dengan waktu yang lebih cepat (Shi & Eberhart, 1998). Variabel $rand_1$, $rand_2$ adalah angka acak antara 0 dan 1 dengan distribusi seragam. Kecepatan variabel v_i juga dapat dibatasi menjadi batas antara $[-v_{max}, v_{max}]$ sedangkan nilai v_{max} dapat ditetapkan dengan angka 2 (Shi & Eberhart, 1998). Kode PSO diberikan sebagai berikut (Clerc & Kennedy, 2002)

Inisialisasi populasi partikel

Lakukan

Untuk anggota partikel $i = 1$ sampai anggota ke-
N

jika $f(x_i) > f(p_i)$ maka $p_i = x_i$

jika $f(p_i) > f(p_{best})$ maka $p_{best} = p_i$

Untuk $d = 1$ hingga dimensi ke- D

$$v_{id} = v_{id} + a_1 \cdot rand() \cdot (p_{id} - x_{id}) + a_2 \cdot rand() \cdot (p_{best} - x_{id})$$
$$v_i = \text{maks}(v_{min}, \min(v_{max}, v_{id}))$$
$$x_{id} = x_{id} + v_{id}$$

d berikutnya

i berikutnya

Sampai kriteria terminasi terpenuhi

Berhenti.

BAB 4. METODE PENELITIAN

4.1 Metode Eksperimental

Untuk mengatasi proses *trial-dan-error* yang sulit dilakukan secara eksperimental, pendekatan Metode penelitian yang digunakan pada penelitian ini adalah metode eksperimental yang banyak digunakan dalam rangka mengevaluasi prototipe atau *framework* pada bidang ilmu analisis gambar medis (Zhou, Greenspan, & Shen, 2017). Metode eksperimental dipilih karena *framework* dari kerangka konseptual model CNN yang akan diusulkan juga perlu diuji terhadap data riil berupa gambar medis pasien kanker serviks yang didapatkan dari rumah sakit.

Secara umum, metode eksperimental dibagi menjadi dua fase yaitu fase eksplorasi dan fase evaluasi. Fase eksplorasi digunakan untuk mengidentifikasi masalah dan alternatif-alternatif teori, konsep dan metode yang dapat digunakan untuk menyelesaikan masalah tersebut. Dari alternatif-alternatif yang ditemukan akan dirancang sebuah *framework* yang akan diusulkan sebagai solusi dari masalah yang diangkat. Fase evaluasi digunakan untuk membuat desain eksperimental yang baik untuk menentukan apakah solusi yang diusulkan dapat menyelesaikan masalah. Desain eksperimental akan mencakup *hardware* dan *software* yang akan digunakan beserta metrik-metrik performa yang dijadikan dasar evaluasi *framework*.

4.2 Tahapan Penelitian

Pada penelitian ini kami tahapan yang digunakan pada penelitian ini dijelaskan sebagai berikut:

Tahap 1: Kajian kondisi prevalensi kanker


Tahap 1 adalah kajian literatur terhadap masalah kanker serviks dan relevansi penelitian dengan bidang ilmu komputer. Kajian terhadap literatur mencakup bidang kesehatan yang berkaitan dengan penyakit kanker dan solusi yang dapat diberikan dari sisi ilmu komputer yaitu *deep learning* atau CNN. Hasil temuan adalah terdapat kebutuhan akan model *artificial intelligence* untuk melakukan prediksi kanker serviks secara otomatis seperti yang telah dijelaskan pada latar belakang.

Selanjutnya dilakukan pengumpulan data dari dataset publik berupa gambar medis kanker serviks. Dataset gambar rumah sakit pasien kanker serviks yang diambil berasal dari Dataset yang digunakan merupakan dataset publik yaitu **Intel & MobileODT Cervical Cancer**

Screening [13]. Dataset ini berisi total 1481 gambar yang terdiri atas 3 label tipe penyakit kanker serviks sebagai berikut:

- Tipe 1 (terdiri atas 250 gambar)
- Tipe 2 (terdiri atas 781 gambar)
- Tipe 3 (terdiri atas 450 gambar)

Secara medis, pasien dengan serviks tipe 1 hanya membutuhkan skrining standar. Adapun pasien dengan serviks tipe 2 dan tipe 3 maka membutuhkan proses skrining tingkat lanjut [12]. Sample gambar dari 3 kategori kanker serviks (tipe 1, tipe 2, dan tipe 3) dapat dilihat pada gambar 4.1. Pada dataset ini tidak diberikan sampel data normal sehingga hanya terdapat 3 kategori atau tipe saja.

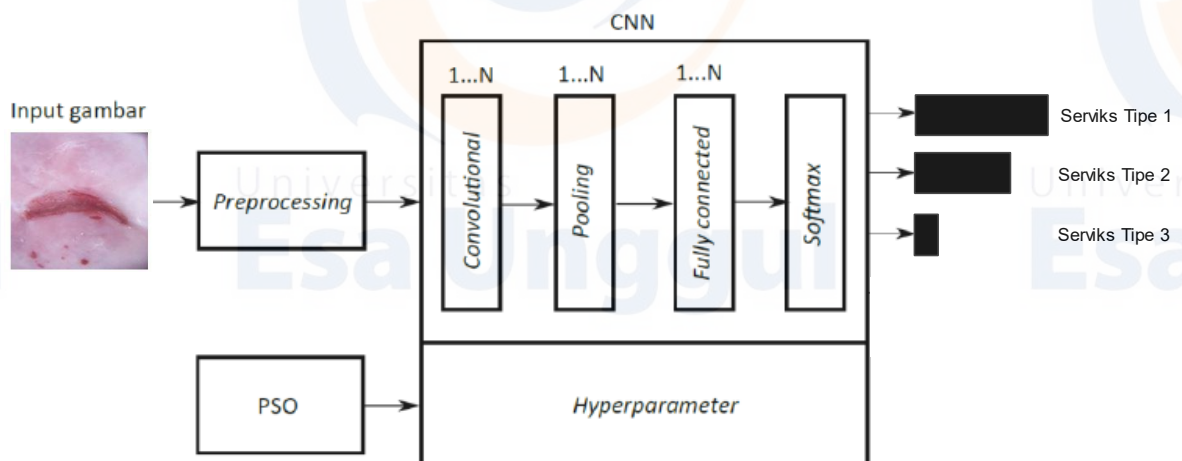


Gambar 4.1. Sample gambar *training* untuk setiap tipe serviks. Gambar (a) adalah Tipe 1, gambar (b) adalah Tipe 2, dan Gambar (c) adalah Tipe 3.

Karena dataset ini memiliki jumlah gambar yang tidak seimbang antara kelas atau tipe kanker serviksnya, maka kami juga membuat versi dataset yang lebih kecil berdasarkan ukuran gambar dari tipe kanker yang terendah yaitu sejumlah 250 gambar. Sehingga total gambar untuk 3 tipe kanker serviks menjadi 750 gambar yang sebanyak 70% dijadikan sebagai data *training* dan sisanya 30% menjadi data *testing*. Untuk mempercepat proses *training*, kami menggunakan ukuran resolusi 32 x 32 piksel secara *default*.

Tahap 2: Pengembangan *framework* KankerNet berbasis optimisasi PSO

Framework yang akan dikembangkan diberi nama KankerNet. *Framework* ini terdiri arsitektur AlexNet yang dioptimalkan menggunakan PSO. Rancangan *framework* KankerNet yang akan diusulkan diberikan pada gambar 4.2.



Gambar 4.2. Rancangan *Framework* KankerNet yang akan diusulkan

Framework KankerNet memiliki 3 proses utama yaitu

- *Preprocessing* untuk mengatur resolusi gambar input agar proses *training* tidak terlalu terbebani. Kami menggunakan tiga bentuk resolusi yaitu: 32 x 32, 64 x 64, dan 128 x 128 piksel.
- Dasar *framework* KankerNet yang dikembangkan berasal dari arsitektur *convolutional neural networks* AlexNet yang telah tersusun dari lapisan *convolutional*, ReLU, *pooling*, *dropout*, *fully connected*, dan *softmax*.
- Nilai terbaik untuk *parameter* KankerNet akan ditentukan secara otomatis berdasarkan pendekatan optimisasi *particle swarm optimization* (PSO).
- Penentuan parameter eksperimen PSO yang digunakan mencakup jumlah populasi partikel, konstanta percepatan, kecepatan maksimal dan jumlah iterasi.

Tahap 3: Koding model KankerNet

Pada tahapan 3 akan dilakukan implementasi koding dari model KankerNet yang telah dirancang. *Tools* yang digunakan untuk eksperimen adalah Matlab yang diterapkan pada komputer dengan spesifikasi processor Intel Core i7 3.5 GHz yang dilengkapi dengan *Graphical Processing Unit* Geforce GTX 950M dan RAM sebesar 12 GB.

Tahap 4: Pengujian *framework* KankerNet pada dataset kanker Serviks

Pada Langkah 4, pengujian dilakukan dengan nilai *default* untuk beberapa parameter *training* berikut ini:

- *Initial learning rate* senilai 0.0001
- *Learning rate drop factor* senilai 0.1
- *L2 Regularization* senilai 0.004
- *Minibatch* senilai 10


Untuk melihat sensitifitas AlexNet terhadap parameter *epoch*, kami menetapkan nilai *learning rate* menjadi 0.0001 dan *minibatch* senilai 10.

- Pada eksperimen yang pertama, parameter *epoch* akan diujicoba berdasarkan nilai berikut ini: 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 150, 200, dan 300.
- Berikutnya, kami akan menggunakan 1 nilai epoch yang paling optimal kemudian melakukan pengujian terhadap parameter lainnya seperti *minibatch* dan *learning rate*.
- Kemudian dari nilai *minibatch* dan *learning rate* yang terbaik akan digunakan untuk eksperimen berikutnya yaitu: pertama untuk melihat pengaruh resolusi gambar input dan kedua untuk melihat pengaruh rasio atau perbandingan antara komposisi data *training* dan data *testing* terhadap performa model AlexNet.
- Selain itu, kami juga akan membandingkan pengaruh dataset yang diseimbangkan (*trimmed*) dengan dataset orisinal.
- Terakhir, setelah mendapatkan nilai terbaik dari kombinasi parameter-parameter yang telah disebutkan sebelumnya, maka pengujian dilakukan terhadap 3 Model arsitektur AlexNet yang digunakan pada penelitian ini (lihat gambar 4.3).

Pada pengujian berikutnya, kami menerapkan metode PSO untuk melakukan optimisasi dari ketiga model arsitektur AlexNet. Perbedaan utama dari ketiga model convolutional neural network ini terdapat pada jumlah lapisan konvolusinya yaitu sebagai berikut ini:

- Model AlexNet 1. Pada model ini jumlah lapisan konvolusi hanya 1.
- Model AlexNet 2. Pada model ini jumlah lapisan konvolusi ada 2.
- Model AlexNet 3. Pada model ini jumlah lapisan konvolusi ada 3.

Lapisan konvolusi pada model AlexNet 2 dan AlexNet 3 berada pada lapisan yang berdekatan sebagaimana yang diperlihatkan pada gambar 4.3. Adapun ketika PSO digunakan, setiap model tersebut akan diberi tambahan sebuah lapisan dropout yang berada sebelum lapisan *fully connected* (*fc*).



(a) Model AlexNet 1

(b) Model AlexNet 2

(c) Model AlexNet 3

Gambar 4.3 Arsitektur dari ke-3 model AlexNet berdasarkan variasi jumlah lapisan konvolusi pada setiap blok (a) AlexNet 1 (b) AlexNet 2 (c) AlexNet 3

Untuk percobaan optimisasi dengan PSO, terdapat dua skema pada pengujian ini. Pada skema yang pertama, parameter yang akan dioptimisasi dengan PSO adalah *epoch* dan *minibatch*. Adapun pada skema yang kedua, parameter yang akan dioptimisasi dengan PSO adalah *epoch*, *minibatch*, dan persentase *dropout*.

Pada metode PSO, terdapat beberapa parameter yang ditetapkan berdasarkan nilai standar yang biasa digunakan yaitu sebagai berikut:

- Populasi = 5
- Iterasi = 10
- Nilai *epoch* maksimal adalah = 15 dan minimalnya adalah = 1
- Nilai *minibatch* maksimal adalah = 40 dan minimalnya adalah = 1 0
- Nilai persentase *dropout* maksimal adalah = 100 dan minimalnya adalah = 0
- *Velocity* maksimal adalah 5 dan minimalnya adalah -5
- Nilai laju pembelajaran akselerasi kognitif dan sosial untuk meng-*update* nilai *global best* dan *previous best* masing-masing adalah 1.4

Untuk mengukur performa dari model CNN AlexNet, kami menggunakan metrik akurasi yang dapat diturunkan berdasarkan *confusion matrix* yang diberikan pada Tabel 4.1.

Tabel 4.1 *Confusion Matrix* yang digunakan untuk mengevaluasi model AlexNet

Kanker serviks	Hasil Prediksi		
	Tipe 1	Tipe 2	Tipe 3
Tipe 1	X ₁₁	X ₁₂	X ₁₃
Tipe 2	X ₂₁	X ₂₂	X ₂₃
Tipe 3	X ₃₁	X ₃₂	X ₃₃

Untuk setiap kelas i , *total true positive*, *total true negative*, *total false positive*, dan *total false positive* dapat dihitung dengan cara sebagai berikut

$$TTP_{all} = \sum_{j=1}^4 x_{jj}$$

Sehingga metrik *overall accuracy* A dapat dihitung dengan cara dibawah ini

$$A = \frac{TTP_{all}}{All}$$

Dimana *All* adalah total nilai seluruh elemen didalam *confusion matrix*. Metrik lainnya adalah *CPU time* yang digunakan untuk mengukur lama proses *training framework* KankerNet. Indikator pencapaian adalah performa prediksi kanker yang baik. Target akurasi, *precision* dan *recall* yaitu mencapai setidaknya diatas 60% agar dapat diterima secara penelitian. Adapun waktu *training* akan semakin lama disebabkan proses optimisasi *metaheuristics*. Namun hal ini dapat dikurangi dengan penggunaan GPU.

BAB 5. HASIL DAN PEMBAHASAN

Spesifikasi hardware dan software yang digunakan pada penelitian ini adalah sebagai berikut::

- Software
 - a. Sistem Operasi : Windows 10 Pro 64Bit
 - b. Bahasa Pemrograman : Matlab 2020b
- Hardware
 - a. Processor : Intel(R) Core(TM) i7-6700HQ CPU @ 2.60GHz
 - b. RAM : 12GB
 - c. HDD : 1TB
 - d. Nvidia GPU GeForce GTX 950M

5.1 Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter *epoch*

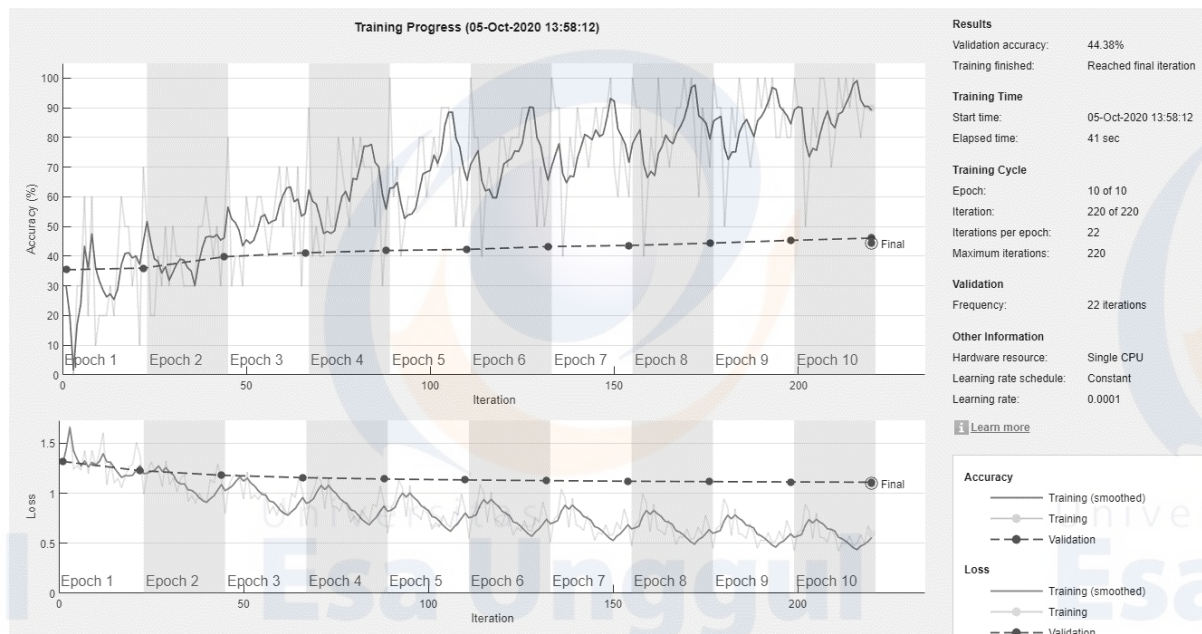
Tabel 5.1 menunjukkan hasil kinerja (secara akurasi dan efisiensi waktu) AlexNet terhadap dataset Intel & MobileODT Cervical Cancer Screening berdasarkan parameter *epoch*.

Tabel 5.1. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan parameter *epoch* pada proses *training* AlexNet

No	<i>Epoch</i>	Akurasi (%)	CPU <i>time</i> (detik)
1	10	44.38	41
2	20	46.10	74
3	30	47.24	105
4	40	47.43	139
5	50	47.72	113
6	60	48.19	202
7	70	48.57	231
8	80	49.71	265
9	90	49.71	346
10	100	49.52	327

11	150	49.90	486
12	200	49.71	647
13	300	52.19	976

Pada percobaan pertama, akurasi pada AlexNet adalah 44.38%. Proses *training* berhasil meningkatkan akurasi, namun hasil validasi tidak setinggi hasil *training*. *Training* terhenti pada epoch 10 dengan tren akurasi yang meninggi (lihat gambar 5.1). Pada *epoch* 20 hasil akurasi pada AlexNet berhasil ditingkatkan menjadi 46.10% dan pada *epoch* 30 akurasi menjadi 47.24%.



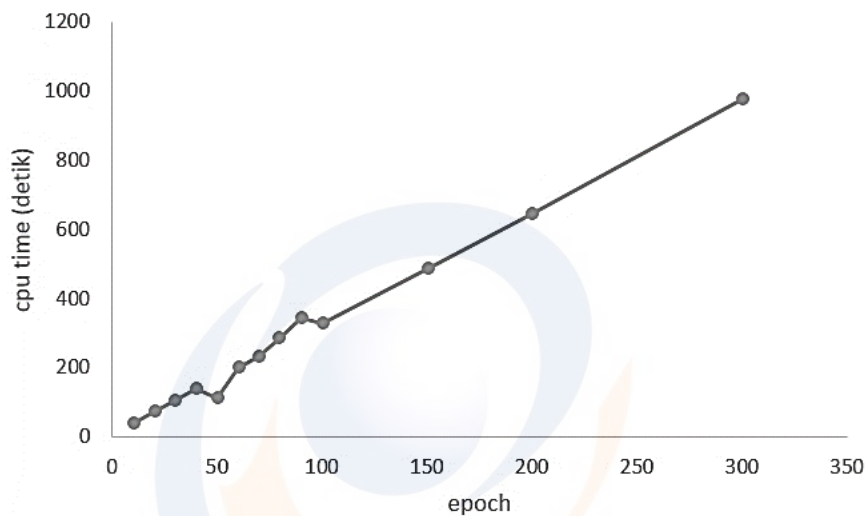
Gambar 5.1. Kinerja akurasi dan waktu komputasi CPU model AlexNet 1 pada *epoch* 10

Adapun peningkatan *epoch* dari 30 menjadi 40 nampaknya tidak memberikan pengaruh pada akurasi (hanya meningkat sebesar 0.19%). Demikian pada *epoch* 50, akurasi hanya meningkat sebesar 0.29%. Hal ini dapat disebabkan faktor *generator* bilangan acak pada proses inisiasi nilai bobot-bobot model AlexNet. Maksudnya, kombinasi nilai bobot awal yang dihasilkan dapat membuat model tersebut terjebak dalam akurasi stagnan dimana proses pencarian nilai *gradient* tidak berhasil menemukan kombinasi nilai bobot baru yang dapat menghasilkan akurasi yang lebih baik.

Pada *epoch* 60 berhasil meningkatkan akurasi cukup signifikan menjadi 48.19%. Namun, percobaan berikutnya (*epoch* 70) perbaikan akurasi tidak signifikan yaitu hanya 0.38%.

Menariknya, *epoch* 80 berhasil menaikkan akurasi menjadi 49.71. Percobaan berikutnya dilakukan pada *epoch* 90 yang tidak memberikan kenaikan ataupun penurunan akurasi.

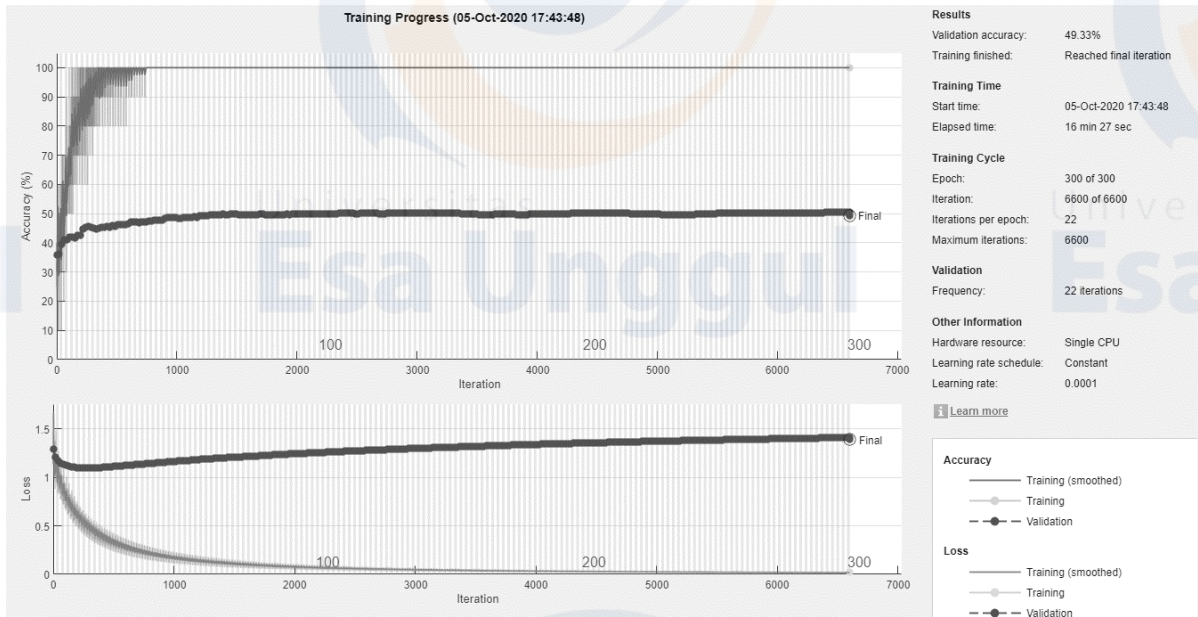
Gambar 5.2 menunjukkan penambahan *epoch* berakibat terhadap waktu komputasi yang juga semakin bertambah. *Epoch* 10 hanya membutuhkan waktu 41 detik. Namun waktu yang dibutuhkan untuk *epoch* 80 adalah 4 menit 25 detik. Gambar tersebut menunjukkan tren waktu komputasi berbanding lurus dengan penambahan *epoch*.



Gambar 5.2 Waktu komputasi (CPU *time*) berbanding lurus dengan iterasi yang dilakukan saat proses *training* (*epoch*)

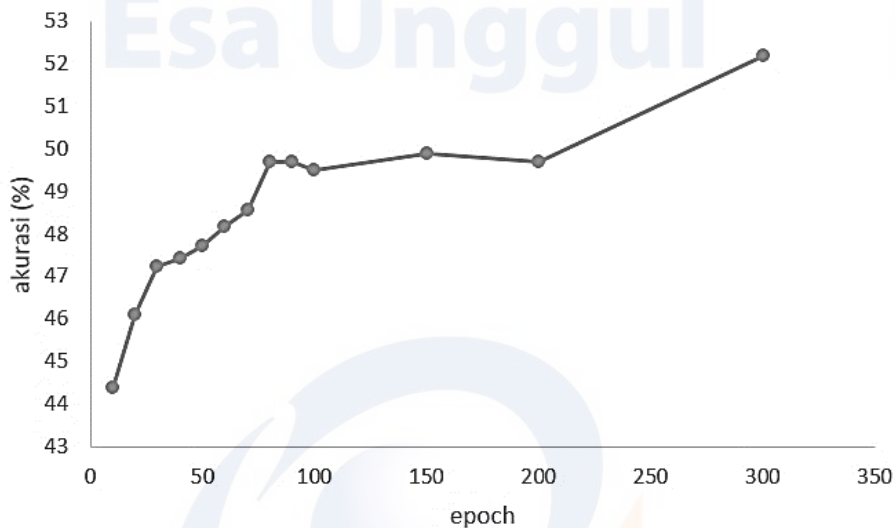
Percobaan berikutnya dilakukan pada *epoch* 100, akurasi justru mengalami penurunan menjadi 49.52%. Untuk melihat efek parameter *epoch* lebih jauh, jumlah iterasi ditambahkan menjadi 150 dan hasilnya berhasil meningkatkan akurasi menjadi 49.90%. Namun, ketika *epoch* ditambahkan menjadi 200 ternyata mengembalikan akurasi seperti pada *epoch* 90. Padahal, waktu yang dibutuhkan justru semakin meningkat menjadi hampir 11 menit.

Hal ini menunjukkan justru *epoch* yang tinggi tidak menjamin efektifitas ataupun efisiensi. Untuk memastikan hal ini, maka *epoch* dapat ditingkatkan lagi. Untuk memastikan pengaruh parameter *epoch*, kami melakukan eksperimen dengan nilai 300. Hasilnya adalah akurasi dapat mencapai 52.19% seperti yang dapat dilihat pada gambar 5.3. Waktu yang dibutuhkan untuk mencapai akurasi tersebut adalah 16 menit dan 16 detik dengan iterasi total yang diperlukan sebanyak 6600.



Gambar 5.3. Hasil akurasi AlexNet terhadap parameter *epoch* 300

Secara umum, penambahan *epoch* memberikan pengaruh positif sebagaimana tren peningkatan akurasi yang ditampilkan pada gambar 5.4. Akan tetapi, antara *epoch* 100 hingga 200, akurasi nampak berfluktuasi sehingga memberikan pengaruh yang positif terhadap kinerja AlexNet. Selain itu, penambahan *epoch* melebihi 300 akan semakin membebani waktu komputasi yang dibutuhkan model AlexNet. Namun demikian, akurasi maksimal yang dihasilkan hanya mencapai 52.19% yang sudah membutuhkan *epoch* yang cukup besar yaitu 300.



Gambar 5.4. Hasil akurasi AlexNet terhadap parameter *epoch*

5.2 Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter *minibatch* dan *learning rate*

Tabel 5.2 menunjukkan perbandingan hasil akurasi dan efisiensi waktu model CNN AlexNet berdasarkan parameter *minibatch* dan *learning rate*. Pada parameter *minibatch*, kami mengujinya dengan nilai 10, 20, 30, dan 40. Adapun parameter *epoch* yang digunakan adalah 150 karena berdasarkan eksperimen sebelumnya nilai ini menunjukkan model AlexNet sudah menjadi stabil.

Nilai *minibatch* 10 memberikan hasil akurasi dan CPU time terbaik yaitu 49.90% dan 486 detik. Menariknya peningkatan nilai *minibatch* 20 dan 30 justru membuat akurasi berkurang dengan total waktu yang dibutuhkan hampir sama. Namun demikian pada nilai *minibatch* 40, hasil akurasi naik lagi menjadi 46.29% namun memerlukan tambahan waktu sebesar 66 detik. Hal ini menunjukkan parameter *minibatch* tidak memberikan pengaruh signifikan terhadap performa model CNN AlexNet. Dengan kata lain, nilai *minibatch* 10 sudah cukup baik.

Tabel 5.2. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan parameter *minibatch* dan *learning rate*

No	<i>minibatch</i>	<i>learning rate</i>	Akurasi (%)	CPU time (detik)
1	10	0.0001	49.90	486
2	20	0.0001	46.29	484
3	30	0.0001	37.33	444
4	40	0.0001	46.29	552
5	10	0.001	47.81	616
6	10	0.01	45.90	691

Pada pengujian parameter *learning rate*, kami menggunakan nilai 0.0001, 0.001, dan 0.01. Semakin besar nilai *learning rate* maka semakin besar fluktuasi proses *training* bobot model jaringan saraf. Oleh karena itu, kami hanya membatasi nilainya sampai 0.01. Nilai akurasi yang terbaik diberikan pada *learning rate* sebesar 0.001 yaitu 47.81% dengan waktu komputasi sebesar 616 detik. Namun demikian nilai ini juga tidak berpengaruh besar karena hanya berkisar antara 45.90% dan 47.81%. Akan tetapi, hasil eksperimen menampakkan

bahwasanya nilai *learning rate* yang semakin besar juga menambah waktu komputasi. Oleh karena itu, nilai *learning rate* yang terbaik adalah 0.0001.

Sebagai tambahan, kami juga menguji pengaruh resolusi gambar input sel kanker serviks. Tabel 5.3 menjelaskan pengaruh parameter resolusi terhadap akurasi dan waktu komputasi yang dibutuhkan CPU. Adapun parameter lainnya ditetapkan sebagai berikut ini: *learning rate* sebesar 0.0001, *minibatch* sebesar 10, dan *epoch* sebesar 150.

Tabel 5.3. Akurasi dan waktu yang dibutuhkan CPU untuk proses *training* model AlexNet berdasarkan resolusi gambar input

No	Resolusi gambar input (piksel)	Akurasi (%)	CPU time (detik)
1	32 x 32	49.90	486
2	64 x 64	46.10	2621
3	128 x 128	34.67	7382

Dari percobaan resolusi 64 x 64 piksel, hasil akurasi tidak bertambah. Seperti yang telah diduga, waktu komputasi meningkatkan sebesar 5.4 kali lipat. Hal ini wajar karena dimensi total gambar input meningkat dari yang awalnya 1024 dimensi (untuk resolusi 32 x 32 piksel) menjadi 4096 yaitu sebesar 4 kali lipat. Adapun ketika resolusi gambar input dinaikkan lagi menjadi 128 x 128 piksel ternyata hasil akurasi semakin menurun menjadi 34.67%.

Hal ini menunjukkan ukuran gambar yang semakin besar justru membuat model AlexNet menjadi semakin tidak efektif. Selain itu, waktu komputasi yang dibutuhkan menjadi sangat besar yaitu 7382 detik atau 123 menit 2 detik. Jika dibandingkan dengan waktu komputasi resolusi gambar input 32 x 32 maka kelipatannya menjadi 15 kali lipat lebih.

5.3 Hasil Eksperimen Sensitifitas terhadap Rasio Data *Training* dan *Testing*

Tabel 5.4 menunjukkan perbandingan hasil akurasi dan efisiensi waktu model CNN AlexNet berdasarkan rasio daripada data *training* dan data *testing* yang digunakan. Kami bervariasi data *training* menjadi 70%, 80%, dan 90%. Parameter *epoch* yang digunakan adalah 150, *minibatch* sebesar 10, *learning rate* sebesar 0.0001, dan resolusi gambar input 32 x 32 piksel. Dataset *trimmed* adalah dataset yang jumlah data pada setiap Tipe sudah diseimbangkan (yaitu sejumlah 250 gambar) sesuai dengan ketersediaan data yang terkecil. Adapun data orisinal adalah dataset yang tidak dikurangi (1481 gambar).

Tabel 5.4 Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan rasio data *training* dan *testing*

No	Rasio <i>training</i> : <i>testing</i>	Dataset	Akurasi (%)	CPU <i>time</i> (detik)
2	0.5:0.5 (Payette et al., 2017)	<i>trimmed</i>	45.60	642
3	0.7:0.3	<i>trimmed</i>	49.33	593
4	0.8:0.2	<i>trimmed</i>	50.00	615
5	0.9:0.1	<i>trimmed</i>	50.67	643
7	0.5:0.5 (Payette et al., 2017)	orisinal	50.41	1316
8	0.7:0.3	orisinal	53.38	1184
9	0.8:0.2	orisinal	56.42	1248
10	0.9:0.1	orisinal	58.11	1637

Pada percobaan rasio data *training* dan *testing*, didapati hasil akurasi yang terbaik adalah 58.11%. Nilai ini didapatkan rasio 0.9:0.1. Kami juga membandingkan ketika rasio yang digunakan adalah 50:50 ([12]) dan ternyata akurasi hanya mencapai 50.41%.

5.4 Hasil Eksperimen Sensitifitas terhadap Jumlah Lapisan Konvolusi

Setelah mendapatkan nilai rasio data *training* dan *testing* yang optimal (yaitu 0.9:0.1), kami melakukan pengujian terhadap ketiga model AlexNet (lihat gambar 4). Dari pengujian ini, kami ingin melihat pengaruh jumlah lapisan konvolusi pada setiap blok pada arsitektur AlexNet terhadap akurasi dan komputasi waktu yang dibutuhkan pada proses *training*-nya. Jumlah *epoch* yang digunakan adalah 15 untuk membandingkannya dengan model standar *residual network* (Payette et al., 2017) yang memiliki arsitektur yang lebih kompleks (yaitu memiliki 32 lapisan secara total). Model AlexNet 1 merupakan model awal yang telah digunakan dimana jumlah lapisan konvolusi pada setiap blok hanya ada 1 seperti yang telah dijelaskan sebelumnya. Pada model AlexNet 2, jumlah lapisan konvolusi setiap blok digandakan sedangkan pada model AlexNet 3, dilipat sebanyak 3 kali dibandingkan pada model AlexNet 1.

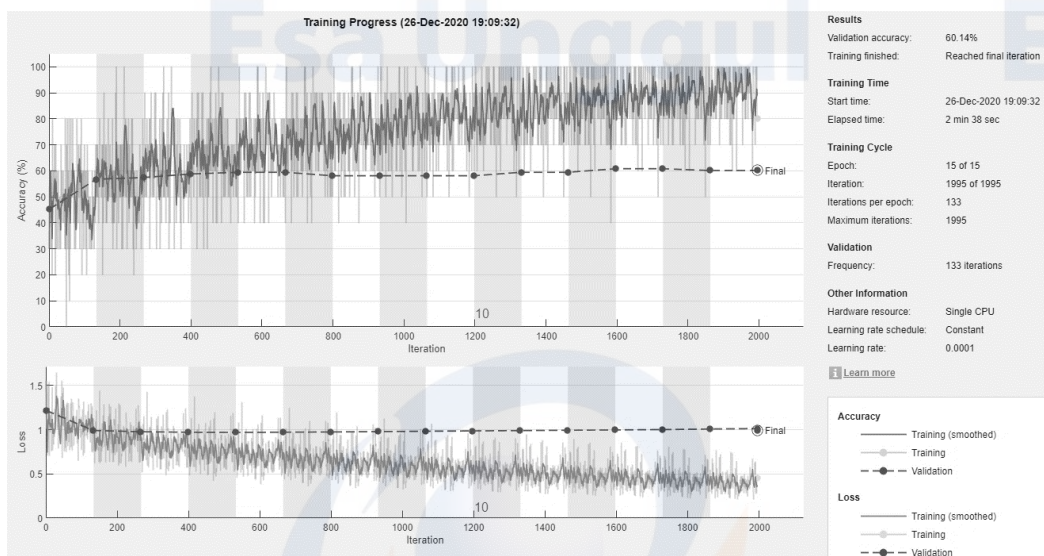
Tabel 5.5 menunjukkan hasil akurasi dan efisiensi waktu dari ketiga model tersebut. Dari hasil eksperimen, didapati model AlexNet 2 mampu mencapai akurasi 60.14%, yaitu sedikit lebih rendah (0.86%) dibandingkan dengan model *residual network* yang memiliki total lapisan hampir 2 kali lipat (Payette et al., 2017). Menariknya, model AlexNet 3 yang memiliki

total lapisan 21 (3 lapisan konvolusi untuk setiap blok) justru menghasilkan akurasi yang paling rendah. Hal ini dapat disebabkan jumlah dataset *training* (1481 gambar) tidak memadai untuk meng-*update* bobot pada lapisan *network* yang kompleks. Sehingga hasil training menjadi tidak efektif. Adapun waktu komputasi dari ketiga model tidak terpaut jauh.

Tabel 5.5 Perbandingan akurasi dan waktu model yang diusulkan terhadap model *residual network* (Payette et al., 2017).

No	Model	Total lapisan	Akurasi (%)	CPU time (detik)
1	<i>Residual Network</i> (Payette et al., 2017)	32	61.00	-
2	AlexNet 1	15	51.35	145
3	AlexNet 2	18	60.14	158
4	AlexNet 3	21	47.97	178

Dari percobaan-percobaan sebelumnya yang telah dilakukan dapat dilihat bahwasanya performa model AlexNet yang terbaik diberikan oleh model AlexNet 2 (memiliki total lapisan 18). Model ini menggunakan parameter *epoch* 15, *minibatch* sebesar 10, *learning rate* sebesar 0.0001, resolusi gambar input 32 x 32 piksel. Adapun, rasio *training* dan *testing* yang digunakan adalah 0.9:0.1. Hasil akurasi yang diberikan mencapai 60.14% dengan waktu komputasi 178 detik seperti yang dapat dilihat pada gambar 5.5.



Gambar 5.5. Kinerja akurasi dan waktu komputasi CPU model AlexNet 2 pada *epoch* 15

5.5 Hasil Eksperimen Pengaruh metode optimisasi *Particle Swarm Optimization* (PSO) dan Parameter *Dropout* terhadap Arsitektur AlexNet

Pengujian terakhir dan terpenting adalah pengujian model AlexNet yang dioptimisasi dengan metode PSO. Dari pengujian ini, kami ingin melihat apakah PSO dapat menemukan parameter-parameter yang terbaik pada model-model AlexNet secara otomatis.

Terdapat 2 skema pengujian disini:

- Skema 1 *framework* KankerNet: parameter yang akan dioptimisasi dengan PSO adalah *epoch* dan *minibatch*. Model AlexNet yang diuji dengan skema ini diberi nama sebagai PSO-AlexNet X.
- Skema 2 *framework* KankerNet: parameter yang akan dioptimisasi dengan PSO adalah *epoch*, *minibatch*, dan persentase *dropout*. Model AlexNet yang diuji dengan skema ini diberi nama sebagai PSO-D-AlexNet X.
- Nilai X adalah nomor dari model AlexNet X menunjukkan ketiga tipe arsitektur *framework* KankerNet yaitu AlexNet 1, AlexNet 2, dan AlexNet 3.

Parameter selain *epoch* dan *minibatch* nilainya diset tetap sesuai dengan parameter terbaik yang telah ditemukan pada percobaan-percobaan sebelumnya yaitu:

- *learning rate* = 0.0001
- resolusi gambar input adalah 32 x 32 piksel
- rasio data *training* dan *testing* adalah 0.9:0.1
- dataset yang digunakan adalah data orisinal berisi 1481 gambar

Kedua skema KankerNet akan digunakan untuk melihat apakah PSO memberikan pengaruh terhadap arsitektur AlexNet. Pertama, pengujian dilakukan untuk skema 1 terhadap model AlexNet yang pertama yaitu AlexNet 1. Hal ini disebabkan karena model ini memiliki kompleksitas yang paling rendah dibandingkan kedua model KankerNet lainnya. Berikutnya, pengujian pengaruh metode PSO dan *dropout* dilakukan untuk ketiga model AlexNet. Sebagai perbandingan, hasil optimisasi manual dari percobaan-percobaan sebelumnya ditampilkan lagi pada tabel 5.6 untuk memudahkan perbandingan terhadap model KankerNet yang dioptimisasi dengan PSO.

Tabel 5.6 Perbandingan akurasi dan waktu model terhadap pengaruh optimisasi PSO pada pencarian *epoch* dan *minibatch* pada ketiga model KankerNet

No	Model	Nilai Optimal			Akurasi (%)	CPU <i>time</i> (detik)
		<i>epoch</i>	<i>minibatch</i>	<i>dropout</i>		
1	AlexNet 1	Hasil dari eksperimen 5.4			51.35	145
2	AlexNet 2	dimana <i>epoch</i> = 15 dan			60.14	158
3	AlexNet 3	<i>minibatch</i> = 10 (lihat tabel 5.5)			47.97	178
4	PSO-AlexNet 1	15	25	-	58.78	5931
5	PSO-D-AlexNet 1	11	12	0.65	59.46	4169
6	PSO-D-AlexNet 2	8	26	0.94	59.46	4333
7	PSO-D-AlexNet 3	13	31	0.65	66.22	5673

Huruf *D* pada model PSO-D-AlexNet *X* menunjukkan bahwa terdapat sebuah lapisan *dropout* pada arsitektur AlexNet. Lapisan dropout ini berada sebelum lapisan *fully connected*. Berdasarkan hasil eksperimen 5.4, tanpa metode PSO, model AlexNet 1 hanya memiliki akurasi sebesar 51.35%. Namun setelah dioptimisasi dengan PSO, tabel 5.6 menunjukkan bahwa hasil akurasi *network* AlexNet 1 bertambah secara signifikan sebesar 7.43% menjadi sebesar 58.78%.

Parameter *dropout* yang berfungsi sebagai *regulator* yang berperan untuk membantu *network* menghindari *overfitting* pada proses *training* ternyata juga mampu meningkat akurasi lebih tinggi lagi yaitu menjadi 59.56%. Hal ini sedikit berbeda dengan model AlexNet 2 karena model PSO-D-AlexNet 2 memberikan hasil yang mirip (sedikit lebih rendah yang sebesar 0.68%) dengan model AlexNet 2. Namun pada model PSO-D-AlexNet 3, penerapan PSO dan parameter *dropout* berhasil memberikan hasil akurasi terbaik yaitu **66.22%**.

5.6 Rangkuman Hasil Eksperimen

Dari keseluruhan percobaan diatas ada beberapa hal yang dapat disimpulkan. Model PSO-D-AlexNet 3 yang memiliki jumlah lapisan terbanyak mampu memberikan performa akurasi yang lebih dari model *residual network* (Payette et al., 2017) yang memiliki lapisan yang hampir 2 kali lebih kompleks. Jika dibandingkan dengan penelitian (Payette et al., 2017), model *residual network* tersebut terdiri atas 32 lapisan sedangkan model PSO-D-AlexNet 3 hanya memiliki 22 lapisan (model AlexNet 3 yang terdiri dari 21 lapisan ditambah 1 lapisan *dropout*). Meskipun lapisannya sudah sangat banyak, hasil akurasinya model *residual network*

hanya mencapai 61% yaitu 5.22% lebih rendah dari model PSO-D-AlexNet 3. Hal ini menunjukkan bahwasanya klasifikasi kanker serviks menggunakan framework KankerNet yang telah dioptimisasi dengan PSO memiliki potensi yang cukup baik bagi dunia kedokteran yang ingin memasukkan unsur otomatisasi proses skrining. Namun demikian, tingkat akurasi domain klasifikasi kanker serviks berdasarkan deep learning masih membutuhkan penelitian-penelitian yang lebih baik lagi.

BAB 6. KESIMPULAN DAN SARAN

6.1 Kesimpulan

Pada penelitian ini, kami telah menguji kinerja model *convolutional neural network* AlexNet sebagai basis *framework* KankerNet yang dioptimisasi dengan metode PSO yang telah diuji pada dataset *Intel & MobileODT Cervical Cancer Screening*. Untuk hasil tanpa optimisasi PSO, dari 3 model arsitektur yang telah diuji, model AlexNet 2 yang memiliki lapisan konvolusi ganda pada setiap bloknnya menghasilkan akurasi yang paling baik yaitu sebesar 60.14% hampir sebesar model standar *residual network*. Namun demikian, ketika menggunakan PSO dan parameter *dropout*, model AlexNet 3 berhasil melampaui model *residual network* tersebut sebesar 5.22% yaitu mencapai akurasi sebesar 66.22%. Hal ini menunjukkan bahwasanya KankerNet mampu mengklasifikasikan gambar sel kanker serviks dengan lebih baik dari model standar *residual network*. Parameter lain yang juga berpengaruh terhadap akurasi model AlexNet adalah parameter iterasi atau *epoch*. Selain itu, semakin besar data *training* yang digunakan maka hasil akurasi juga cenderung meningkat. Adapun parameter *minibatch* dan *learning rate* cenderung kurang berpengaruh terhadap akurasi KankerNet. Sedangkan untuk parameter resolusi gambar input, hasil akurasi justru semakin menurun dimana waktu komputasinya juga semakin tinggi.

6.2 Saran

Pada penelitian berikutnya, akurasi model AlexNet masih perlu ditingkatkan lagi untuk dapat benar-benar pada bidang kesehatan yaitu deteksi penyakit kanker serviks berdasarkan data gambar. Hal ini dapat dilakukan dengan melihat sensitifitas AlexNet terhadap parameter lainnya seperti bobot dan algoritma *learning*. Selain itu, kurangnya data *training* dapat dicoba untuk diatasi menggunakan pendekatan augmentasi dataset yang menggunakan transformasi secara geometri.

DAFTAR PUSTAKA

- Araújo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., ... Campilho, A. (2017). Classification of breast cancer histology images using convolutional neural networks. *PloS One*, 12(6), e0177544.
- Arefan, D., Mohamed, A. A., Berg, W. A., Zuley, M. L., Sumkin, J. H., & Wu, S. (2020). Deep learning modeling using normal mammograms for predicting breast cancer risk. *Medical Physics*, 47(1), 110–118.
- Baksir, A. H., Fuad, A., Tempola, F., & Rosihan, R. (2020). Prediksi Tingkat Kesuburan (Fertility) Dengan Jaringan Saraf Tiruan Metode Backpropagation. *JIKO (Jurnal Informatika Dan Komputer)*, 3(2), 107–112. <https://doi.org/10.33387/jiko.v3i2.1922>
- Ciresan, D. C., Giusti, A., Gambardella, L. M., & Schmidhuber, J. (2013). Mitosis detection in breast cancer histology images with deep neural networks. In *International Conference on Medical Image Computing and Computer-assisted Intervention* (pp. 411–418).
- Clerc, M., & Kennedy, J. (2002). The particle swarm-explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation*, 6(1), 58–73.
- Cohen, P. A., Jhingran, A., Oaknin, A., & Denny, L. (2019). Cervical cancer. *The Lancet*, 393(10167), 169–182.
- Hamidinekoo, A., Denton, E., Rampun, A., Honnor, K., & Zwiggelaar, R. (2018). Deep learning in mammography and breast histology, an overview and future trends. *Medical Image Analysis*, 47, 45–67.
- Intel. (2017). Intel & MobileODT Cervical Cancer Screening Which cancer treatment will be most effective? Retrieved from <https://www.kaggle.com/c/intel-mobileodt-cervical-cancer-screening>
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-International Conference on Neural Networks* (Vol. 4, pp. 1942–1948).
- Khatimah, H., & Sofiana, L. (2019). *Evaluasi Program Pencegahan Kanker Payudara dan Kanker Serviks di Kabupaten Sleman*. Universitas Ahmad Dahlan.
- Liu, Z., Liu, X., Xiao, B., Wang, S., Miao, Z., Sun, Y., & Zhang, F. (2020). Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network. *Physica Medica*, 69, 184–191.
- Payette, J., Rachleff, J., & de Graaf, C. (2017). Intel and MobileODT Cervical Cancer Screening Kaggle Competition: cervix type classification using Deep Learning and image classification. Stanford University.
- Rakhlin, A., Shvets, A., Iglovikov, V., & Kalinin, A. A. (2018). Deep convolutional neural networks for breast cancer histology image analysis. In *International Conference Image Analysis and Recognition* (pp. 737–744).

- Rasti, R., Teshnehlab, M., & Phung, S. L. (2017). Breast cancer diagnosis in DCE-MRI using mixture ensemble of convolutional neural networks. *Pattern Recognition*, 72, 381–390.
- Shi, Y., & Eberhart, R. (1998). A modified particle swarm optimizer. In *1998 IEEE international conference on evolutionary computation proceedings. IEEE world congress on computational intelligence (Cat. No. 98TH8360)* (pp. 69–73).
- Song, Y., Zhang, L., Chen, S., Ni, D., Li, B., Zhou, Y., ... Wang, T. (2014). A deep learning based framework for accurate segmentation of cervical cytoplasm and nuclei. In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 2903–2906).
- Sornapudi, S., Stanley, R. J., Stoecker, W. V, Almubarak, H., Long, R., Antani, S., ... Frazier, S. R. (2018). Deep learning nuclei detection in digitized histology images by superpixels. *Journal of Pathology Informatics*, 9.
- Wang, P., Wang, J., Li, Y., Li, L., & Zhang, H. (2020). Adaptive Pruning of Transfer Learned Deep Convolutional Neural Network for Classification of Cervical Pap Smear Images. *IEEE Access*, 8, 50674–50683.
- Żejmo, M., Kowal, M., Korbicz, J., & Monczak, R. (2017). Classification of breast cancer cytological specimen using convolutional neural network. In *Journal of Physics: Conference Series* (Vol. 783, p. 12060).
- Zhou, S. K., Greenspan, H., & Shen, D. (2017). *Deep learning for medical image analysis*. Academic Press.

Lampiran 1. Surat Pernyataan Ketua Pelaksana



Surat Pernyataan Ketua Pelaksana Program Penelitian

Yang bertandatangan di bawah ini:

Nama : Habibullah Akbar, S.Si.,M.Sc., Ph.D
NIDN/NIK : 0315108201
Fakultas/Prodi : Ilmu Komputer / Magister Ilmu Komputer
Jabatan Fungsional : Lektor

Dengan ini saya menyatakan bahwa proposal program penelitian yang diajukan dengan judul: **Pengembangan *Framework* KankerNet Berdasarkan *Convolutional Neural Networks* dan Model PSO untuk Penyakit Kanker Serviks.**


Yang saya usulkan dalam skema Penelitian Terapan Internal Universitas Esa Unggul tahun 2020 bersifat original dan belum pernah dibiayai oleh lembaga/sumber dana lain.

Bilamana diketahui dikemudian hari adanya indikasi ketidak jujuran/itikad kurang baik sebagaimana dimaksud di atas, maka kegiatan ini dibatalkan dan saya bersedia mengembalikan dana yang telah diterima kepada pihak Universitas Esa Unggul melalui LPPM.

Demikian pernyataan ini dibuat dengan sesungguhnya dan dengan sebenar-benarnya.

Jakarta, 15 Juli 2020

Yang menyatakan,


Habibullah Akbar, S.Si.,M.Sc., Ph.D
NIDN: 0315108201

Lampiran 2. Surat Tugas LPPM



SURAT TUGAS
No.134/ST-PEN/LPPM/UEU/IV/2020

Yang bertandatangan di bawah ini:

Nama : Dr. Erry Yudhya Mulyani, M.Sc
Jabatan : Kepala LPPM

Menugaskan nama-nama di bawah ini:

Nama	Jabatan	NIDN	Fakultas
Habibullah Akbar, S.Si, M.Sc, Ph.D	Ketua	0315108201	Ilmu Komputer
Sandfreni, S.SI, M.T	Anggota	0304029101	Ilmu Komputer

Untuk melakukan kegiatan penelitian dengan judul:

“Pengembangan Framework Kankernet Berdasarkan Convolutional Neural Networks Dan Model PSO Untuk Penyakit Kanker Serviks”.

Demikian surat tugas ini dibuat untuk dipergunakan sebagaimana mestinya.

Jakarta, 13 April 2020

Kepala LPPM

Universitas
Esa Unggul
LPPM
Dr. Erry Yudhya Mulyani, M.Sc
NIK. 209100388

Lampiran 3. Biodata Ketua Tim

A. Identitas Diri

Nama Lengkap (dengan gelar)	Habibullah Akbar, S.Si., M.Sc., Ph. D
Jenis Kelamin	Laki-laki
Jabatan Fungsional	Lektor
NIP/NIK/Identitas lainnya	218030726
NIDN	0315108201
Tempat dan Tanggal Lahir	Jakarta 15 Oktober 1982
E-mail	habibullah.akbar@esaunggul.ac.id
Nomor Telepon/HP	081319110259
Alamat Kantor	Jl. Arjuna Utara no. 9 Kebon Jeruk Grogol Jakarta Barat
Nomor Telapon/Faks	021-5674223
Mata Kuliah yang diampu	1. Topik dalam <i>Artificial Intelligence</i>
	2. Topik dalam <i>Image Processing</i>
	3. Topik dalam <i>Data Mining</i>
	4. Pemrograman Mobile
	5. Pemrograman Web

B. Riwayat Pendidikan

	S-1	S-2	S-3
Nama Perguruan Tinggi	ITB	UTeM	UTeM
Bidang Ilmu	Fisika	Teknologi Informasi dan Komunikasi	Teknologi Informasi dan Komunikasi
Tahun Masuk-Lulus	2002-2006	2008-2010	2010-2016
Judul Skripsi/Tesis/Disertasi	Study dari Pengaruh Medan Magnet Ring terhadap Film Tipis CoFe pada Reaktor Opposed Target Magnetron Sputtering	Defect Inspection Algorithm in Intelligent Real-Time Vision System for Small and Medium Industries	3D Intrinsic Scene Characteristic Extraction Framework for a Single Image
Nama Pembimbing/Promotor	Prof. Dr Mitra Djamal	Prof. Dr Nanna Suryana Herman	Prof. Dr Nanna Suryana Herman Prof. Dr Shahrin Sahib

C. Pengalaman Penelitian dalam 5 Tahun Terakhir

No.	Tahun	Judul Penelitian	Pendanaan	
			Sumber	Jml (Juta Rp)
1	2019	PTUPT: Pengembangan E-Mental Health Berbasis Knowledge Management dalam Mendukung Sistem Informasi Kesehatan Nasional (Siknas) (Position: Co-Researcher).	DIKTI	325
2	2017	Penelitian Dosen Hibah Internal: Deteksi Kantuk Pengendara Mobil Otomatis Berdasarkan Computer Vision	BINUS	10

D. Publikasi Ilmiah Jurnal dalam 5 Tahun Terakhir

No.	Judul Artikel Ilmiah	Nama Jurnal	Vol/ Nomor/ Tahun
1	E-Learning Effectiveness Analysis in Developing Countries: East Nusa Tenggara,	Bulletin of Electrical Engineering and Informatics (Scopus)	7/3/2018
2	Thin film roughness optimization in the tin coatings using genetic algorithms	Journal of Theoretical and Applied Information Technology (Scopus)	94/24/20 17
3	Chaotic Clonal Selection Optimization for Multi-threshold Segmentation.	International Journal of Signal and Imaging Systems Engineering (Scopus)	8/5/2015

E. Pemakalah Seminar Ilmiah (*Oral Presentation*) dalam 5 Tahun Terakhir

No	Nama Temu Ilmiah / Seminar	Judul Artikel Ilmiah	Waktu dan Tempat
1	ICCAI (IOP)	Implementing DSDM and OO Method to Develop Billing in Mental Hospital	2019 Medan
2	IC2IE (IOP)	OCR correction for Indonesian historic newspapers using word repetition, stemmer and n-gram	2019 Lombok
3	ICCSCI (Procedia Computer Science)	Early Detection of Diabetes Mellitus using Feature Selection	2019 Yogyakarta

		and Fuzzy Support Vector Machine	
4	ISESD (IEEE)	Sparse Coded Decomposition for Single-based Specular Removal.	2016 Bandung
5	ICORAS (IEEE)	Removal of Highlights in Dichromatic Reflection Objects Using Segmentation and Inpainting.	2016 Malaysia
6	Seminar Nasional Komputasi Ilmiah dan penerapannya di Dunia Cyber	Komputasi Ilmiah dan penerapannya di Dunia Cyber	2016 Tangerang Selatan
7	The 2nd International Confrence on Linguistics, Language Teaching, Literatures and Cultures	The Next Wave of Disruptive Technology on Language and Culture	2016 Tangerang Selatan

Biodata Anggota Peneliti

A. Identitas Diri

1	Nama Lengkap	Sandfreni, S.SI, MT
2	Jenis Kelamin	Perempuan
3	Jabatan Fungsional	Asisten Ahli
4	NIP/NIK	215090609
5	NIDN	0304029101
6	Tempat dan Tanggal Lahir	Palembang, 04-02-1991
7	E-mail	sandfreni@esaunggul.ac.id
8	Nomor Telepon/HP	08112778791
9	Alamat Kantor	Jl. Arjuna Utara no. 9 Kebon Jeruk Grogol Jakarta Barat
10	Nomor Telapon/Faks	021-5674223
11	Lulusan yang Telah Dihilangkan	-
12	Mata Kuliah yang diampu	1. Rekayasa Perangkat Lunak
		2. Perrograman Berorientasi Objek
		3. Sistem Basis Data
		4. Manajemen Pengetahuan
		5. Manajemen Proyek Sistem Informasi

B. Riwayat Pendidikan

	S-1	S-2
Nama Perguruan Tinggi	Universitas Sriwijaya	Institut Teknologi Bandung
Bidang Ilmu	Sistem Informasi	Sistem Informasi
Tahun Masuk-Lulus	2008-2012	2013-2015
Judul Skripsi/Tesis/Desertasi	Pengembangan Sistem Informasi Pegadaian dengan Menggunakan Metode FAST (Studi Kasus Perum Pegadaian Unit Internasional Plaza Cabang Kenten Palembang)	Pemodelan Requirement Engineering: <i>Role Based Goal Oriented Model</i>
Nama Pembimbing/Promotor	Jaidan Jauhari, MT	Ir. Kridanto Surendro, MSc, PhD

C. Pengalaman Penelitian dalam 5 Tahun Terakhir

No.	Tahun	Judul Penelitian	Pendanaan	
			Sumber*	Jml (Juta Rp)
1	2014	Penelitian Dosen – Program Riset Disentralisasi DIKTI: Perancangan e-readiness Framework Adopsi Cloud Computing pada Perguruan Tinggi	Dikti	120
2	2016	Penelitian Dosen Hibah Internal analisis titik kritis keberhasilan (CSFS) dan indikator kinerja (KPI) staf it pada proses penerapan <i>enterprise resource</i>	Esa Unggul	Insentif
3	2017	Penilaian Level Kapabilitas Organisasi Yang Memanfaatkan Sistem Informasi Untuk Proses BAI04 Dengan <i>Framework Cobit 5</i>	Dikti	20
4	2018	Model Perancangan Strategi IT yang didasarkan pada Manajemen Strategi IT	Esa Unggul	Insentif

D. Pemakalah Seminar Ilmiah (Oral Presentation) dalam 5 Tahun Terakhir

No.	Nama Pertemuan Ilmiah/Seminar	Judul Artikel Ilmiah	Waktu dan Tempat
1	International Conference on Information Science and Applications (ICISA) 2015	Requirement Engineering for Cloud Computing in University Using iStar Hierarchy Method	Thailand, 25-26 Febuari 2015 ICATSE
2	International Conference on Design Engineering and Science (ICDES) 2016	Requirement Engineering: Role Based Goal Orientation	Kuala Lumpur, 27-29 Februari 2016 University of Malaysia
3	International Conference on Computer Applications and	Capability Level that Using Information System: <i>Framework Cobit 5 (BAI 04</i>	Bali, Agustus 2017 Chapter 1 APTIKOM

Information Processing Technology (CAIPT) 2017	Process)	
--	----------	--

Lampiran 4. Bukti Luaran Jurnal



KEMENTERIAN PENDIDIKAN DAN KEBUDAYAAN
JURNAL INFORMATIKA DAN KOMPUTER (JIKO)
PROGRAM STUDI TEKNIK INFORMATIKA
UNIVERSITAS KHAIRUN

JIKO
JURNAL INFORMATIKA
DAN KOMPUTER

Jl. Jati Metro Kampus III Unkhair, Kelurahan Jati Kecamatan Ternate Tengah Kota Ternate. Tlp

SURAT KETERANGAN NASKAH DITERIMA
No.07/JIKO/TI-UNKHAIR/XII/2020

Bersama ini redaksi JIKO (Jurnal Informatika dan Komputer) memberitahukan bahwa naskah dengan identitas:

Judul : KLASIFIKASI KANKER SERVIKS MENGGUNAKAN MODEL CONVOLUTIONAL NEURAL NETWORK ALEXNET
Penulis : Habibullah Akbar, Sandfreni
Afiliasi / institusi : Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Esa Unggul
Email : habibullah.akbar@esaunggul.ac.id
Tanggal Submit : 24 Desember 2020

Naskah tersebut telah melalui proses review dan memenuhi kriteria publikasi di JIKO (Jurnal Informatika dan Komputer) dan akan diterbitkan pada edisi berikutnya dalam versi elektronik dan cetak.

Demikian surat keterangan ini disampaikan untuk digunakan sebagaimana mestinya.

Ternate, 27 Desember 2020
Ketua Redaksi

Abdul Mubarak, S.T., M.Kom

KLASIFIKASI KANKER SERVIKS MENGGUNAKAN MODEL *CONVOLUTIONAL NEURAL NETWORK* (ALEXNET)

Habibullah Akbar¹, Sandfreni²

¹Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Esa Unggul
²Sistem Informasi, Fakultas Ilmu Komputer, Universitas Esa Unggul
Email: habibullah.akbar@esaunggul.ac.id, sandfreni@esaunggul.ac.id

(Naskah masuk: 24 Desember 2020, diterima untuk diterbitkan: 4 Februari 2021)

Abstrak

Menurut Kementerian Kesehatan Republik Indonesia, kanker serviks memiliki kasus sebesar 23,4 per 100.000 penduduk pada tahun 2018. Tingkat prevalensi angka kejadian yang cukup tinggi tersebut tentunya menyulitkan baik pihak pemerintah dan masyarakat dalam upaya pencegahan dan pengendalian kanker. Pada penelitian ini, kami menggunakan model *convolutional neural network* dengan arsitektur AlexNet untuk mengklasifikasikan gambar dari sel kanker serviks. Model ini terdiri atas kombinasi lapisan konvolusi, lapisan ReLu, lapisan pooling, dan lapisan *fully-connected* yang akan mengklasifikasi gambar input serviks menjadi 3 tipe kanker melalui fungsi aktivasi *softmax*. Dataset yang digunakan merupakan dataset standar yaitu dataset *Intel & MobileODT Cervical Cancer Screening*. Pengujian arsitektur model AlexNet dilakukan terhadap parameter iterasi (*epoch*), subset data *training* untuk mengupdate bobot AlexNet (*minibatch*), laju pembelajaran (*learning rate*), resolusi gambar input yang digunakan sebagai *patch* pembelajaran AlexNet, dan ukuran dataset. Dari hasil eksperimen didapat bahwasanya akurasi sangat dipengaruhi oleh arsitektur lapisan konvolusi, dimana hasil akurasi terbaik mencapai lebih dari 60% yang diberikan oleh AlexNet dengan lapisan konvolusi ganda. Hal ini menunjukkan model AlexNet memiliki potensi yang hampir sama dengan model standar *deep residual network* untuk melakukan klasifikasi kanker serviks. Secara umum, waktu komputasi yang dibutuhkan berbanding lurus dengan jumlah iterasi. Menariknya, parameter lain dari arsitektur model AlexNet seperti *minibatch*, *learning rate*, dan resolusi gambar input tidak memberikan pengaruh yang signifikan atau bahkan justru dapat membuat *network* gagal meningkatkan performanya.

Kata kunci: kanker serviks, *convolutional neural network*, AlexNet

CLASSIFICATION OF CERVICAL CANCER USING CONVOLUTIONAL NEURAL NETWORK (ALEXNET)

Abstract

According to the Ministry of Health of the Republic of Indonesia, cervical cancer has cases of 23.4 per 100,000 population in 2018. The high prevalence rate of the incidence rate certainly makes it difficult for both the government and the community to prevent and control cancer. In this study, we used a convolutional neural network model with AlexNet architecture to classify images of cervical cancer cells. This model consists of convolution layers, ReLu layers, pooling layers, and fully-connected layers which will classify cervical input images into 3 types of cancer through the softmax activation function. The dataset used is a standard dataset, namely the Intel & MobileODT Cervical Cancer Screening dataset. The testing of AlexNet architecture was carried out on several parameters including iterations (*epoch*), training data subsets to update AlexNet weights (*minibatch*), learning rate (*learning rate*), input image resolution used as the learning patches, and dataset size. From the experimental results, it was found that accuracy is strongly influenced by the architecture of the convolutional layer, where the best accuracy result was able to reach more than 60% given by AlexNet with double convolution layer. This shows that the AlexNet model has almost the same potential as the standard deep residual network model for classifying cervical cancer. Generally, the required computation time is directly proportional to the number of iterations. Interestingly, other parameters of the AlexNet model architecture such as *minibatch*, *learning rate*, and input image resolution do not have a significant effect or even can make the network fail to improve its performance.

Keywords: cervical cancer, convolutional neural network, AlexNet

1. PENDAHULUAN

Kanker serviks termasuk satu dari jenis-jenis kanker yang paling umum. Setiap tahun, sekitar setengah juta perempuan diseluruh dunia yang terdiagnosis positif kanker serviks dengan angka kematian lebih dari 300.000 [1]. Di Indonesia sendiri kanker serviks berada di urutan keempat yang meningkat dari 1,4 per 1000 penduduk pada tahun 2013 menjadi 1,8 per 1000 penduduk pada tahun 2018 [2]. Tingkat prevalensi angka kejadian yang cukup tinggi tersebut tentunya memerlukan perhatian baik pihak pemerintah, swasta, dan masyarakat dalam upaya pencegahan, pengobatan dan pengendalian penyakit kanker serviks. Angka kematian mencapai 18.279 per tahun kasus kanker serviks di Indonesia. Artinya setiap hari sekitar 50 perempuan Indonesia meninggal dunia.

Penyakit kanker serviks adalah bermula dari pertumbuhan sel yang tidak teratur dan sel-sel ini dapat menyerang organ biologis lainnya baik dengan pertumbuhan langsung di jaringan yang bersebelahan atau dengan migrasi ke sel lainnya (metastasis). Pertumbuhan yang tidak teratur dapat menyebabkan kerusakan DNA, yang mengakibatkan mutasi di gen vital yang mengontrol pembagian sel, dan fungsi lainnya. Jika sudah parah, pertumbuhan sel akan menjadi tumor ganas yang menyerang jaringan di mulut rahim. Penyebab utama dari kanker serviks adalah infeksi Human Papilloma Virus, meskipun terdapat beberapa faktor lain buyang juga dapat mempengaruhi progresifitas kanker.

Umumnya, tes kanker serviks dapat dilakukan dengan pap smear, pemeriksaan HPV, dan pemeriksaan IVA yang didukung dengan tes pencitraan/gambar medis seperti CT scan, mikroskopis dan MRI. Perkembangan teknologi kecerdasan buatan seperti jaringan saraf tiruan dapat diterapkan untuk bidang kesehatan seperti kualitas kesuburan [3]. Model ini memiliki keuntungan ketika fiturnya diketahui dengan baik. Misalkan penentuan kualitas kesuburan bergantung pada fitur usia, konsumsi alkohol, dan kebiasaan merokok. Namun, ketika data yang digunakan berupa gambar maka diperlukan model model jaringan saraf tiruan yang sudah dapat melakukan ekstraksi fitur secara otomatis. Model ini disebut sebagai *convolutional neural network* (CNN). CNN dapat dilatih untuk melakukan segmentasi otomatis terhadap sel kanker ataupun mendeteksi potensi kanker berdasarkan citra medis yang diambil dari pasien [4], [5]. Namun teknologi CNN ini masih memerlukan penelitian agar benar-benar dapat dikembangkan menjadi alat bantu dokter spesialis patologi dalam melakukan diagnosis kanker serviks berdasarkan gambar medis pasien.


Convolutional neural network (CNN) sudah mulai digunakan untuk dalam mendeteksi potensi kanker dari gambar medis. Pada penelitian yang dilakukan oleh [6] membangun model *Convolutional neural network* (CNN) untuk mendeteksi mitosis pada sel kanker pada gambar histologi. Penelitian

yang lebih mendalam mengenai klasifikasi kanker telah dilakukan oleh [7]. Selain itu, [8] telah berhasil menggunakan model LeNet yang sudah dimodifikasi dengan variasi lapisan dan parameter untuk mengurangi beban memori dan komputasi. [14] melakukan studi literatur em pada kanker kulit

CNN juga dapat digunakan untuk segmentasi kanker serviks tanpa harus melakukan klasifikasi [9]. Yang lebih menarik lagi, penelitian yang dilakukan oleh [10] mampu menggabungkan metode segmentasi dan klasifikasi pada kanker dalam satu kerangka diagnosis. Selain itu, varian CNN seperti GoogLeNet dan AlexNet juga telah diterapkan untuk klasifikasi langsung kanker pada gambar histopatologi untuk kanker payudara yang diambil dari sampel biopsi tanpa melibatkan proses segmentasi [11].

Permasalahannya, pada penelitian-penelitian yang telah dilakukan sebelumnya, model AlexNet baru diujicoba pada gambar kanker payudara [11] dimana akurasi yang dihasilkan dapat mencapai nilai 80%. Pada penelitian yang dilakukan oleh [12], akurasi yang dihasilkan oleh metode CNN deep residual network yang mereka usulkan tidak melebihi 61%. Sedangkan pada [15] dengan menggunakan CNN dan ELM akurasi dapat mencapai 99,5%.

Gambar 1 memberikan ilustrasi secara visual tentang penampakan sel kanker serviks nampak tidak lebih sulit untuk diklasifikasi dibandingkan dengan sel kanker payudara. Berikut ini adalah perbandingan gambar kanker payudara dan gambar kanker serviks. Namun demikian bagaimana performa model CNN lainnya seperti AlexNet terhadap gambar kanker serviks masih belum diketahui.



Gambar 1. Perbandingan gambar (a) sel kanker payudara [11] dan (b) sel kanker serviks [12].

Adapun penelitian yang kami lakukan pada studi ini bertujuan untuk melihat bagaimana tingkat akurasi model CNN AlexNet terhadap gambar sel kanker serviks.


2. METODE PENELITIAN

Pada penelitian ini, model *convolutional neural network* yang digunakan adalah model AlexNet yang akan digunakan untuk mentransformasikan input gambar menjadi label penyakit dari kanker serviks.

2.1. Arsitektur Convolutional Neural Network AlexNet

Convolutional Neural Network (CNN) memiliki kelebihan karena tidak memerlukan proses ekstraksi fitur secara eksplisit sebagaimana proses pengolahan citra tradisional. Hal ini disebabkan CNN memiliki lapisan konvolusi yang secara implisit akan mendeteksi dan melakukan ekstraksi fitur dari gambar input.

Ilustrasi model AlexNet yang dapat melakukan prediksi kanker serviks berdasarkan gambar diberikan pada gambar 2. Model ini terdiri dari lapisan konvolusi, lapisan ReLU, lapisan *pooling*, dan lapisan *fully-connected* yang akan mengklasifikasi gambar input serviks menjadi 3 tipe kanker berdasarkan fungsi aktivasi *softmax*.




Gambar 2. Arsitektur convolutional neural network AlexNet yang digunakan pada penelitian ini

Arsitektur CNN diatas dari beberapa struktur seperti yang dijelaskan berikut ini:

2.1.1 Input patch

Data masukan yang dapat diterima CNN adalah *input gambar* atau *patch gambar*. Pada penelitian ini, kami menggunakan dataset Intel & MobileODT Cervical Cancer Screening. Sample gambar dari 3 kategori kanker serviks (tipe 1, tipe 2, dan tipe 3) dapat dilihat pada gambar 3.



Gambar 3. Sample gambar training untuk setiap tipe serviks. Gambar (a) adalah Tipe 1, gambar (b) adalah Tipe 2, dan Gambar (c) adalah Tipe 3.

2.1.2 Blocks.

Setiap blok CNN terdiri atas 3 sub lapisan yaitu lapisan konvolusi, ReLU, dan *pooling*.

- Lapisan konvolusi menerima *input patch* yang terdiri dari piksel-piksel. Lapisan ini

terdiri dari kumpulan filter yang diinisialisasi secara acak untuk mencari representasi fitur dari suatu gambar berdasarkan kategori label penyakit.

Setiap filter mengandung matrik saraf sebagai *receptive field* yang dimana nilai setiap sel saraf akan dilatih untuk mendeteksi fitur dari yang paling sederhana seperti *edge*, *curve* hingga *cell parts*.

- Lapisan ReLU akan menentukan apakah sinyal dari lapisan konvolusi dapat diteruskan pada lapisan berikutnya atau tidak. Bentuk fungsi ReLU dapat dinyatakan dengan $f(x) = \max(0, x)$ yang artinya akan memotong sinyal input yang memiliki nilai kurang dari 0.
- Lapisan *pooling* akan mengurangi beban komputasi dengan cara menurunkan ukuran gambar yang diteruskan dari lapisan ReLU dengan melakukan *down sampling* yang membuat ukuran gambar menjadi lebih kecil. Tujuannya agar lapisan konvolusi berikutnya dapat menemukan fitur gambar yang lebih tinggi.

2.1.3 Lapisan fully-connected

Lapisan koneksi penuh merupakan lapisan *perceptron* yang menghimpun seluruh sinyal lapisan sebelumnya lalu memproses jumlah sinyal tersebut menggunakan fungsi *softmax*. Jumlah *perceptron* yang digunakan sejumlah 4096 dan akan diturunkan sesuai dengan jumlah label yang ada. Label berisi kategori penyakit yang diberikan pada dataset.

Pada gambar 2, blok yang digunakan berjumlah 3. Namun, jumlah blok yang optimal agar CNN dapat memberikan performa prediksi yang baik tidak diketahui kecuali dengan eksperimen. Pada akhir arsitektur AlexNet, fungsi *softmax* digunakan untuk menghitung probabilitas dari tipe kanker serviks. Fungsi *softmax* diberikan pada persamaan (1).

$$y_i(x) = \frac{\exp(y_i(x))}{\sum_{j=1}^n \exp(y_j(x))} \quad (1)$$

Setiap output dari *perceptron* didalam lapisan *fully-connected* akan menjadi input bagi fungsi *softmax* tersebut yang kemudian digunakan untuk menghitung probabilitas dari tipe kanker serviks.

2.2. Pengujian model AlexNet dan Dataset

Spesifikasi hardware yang digunakan pada penelitian ini adalah Processor Intel(R) Core(TM) i7-6700HQ CPU @ 2.60GHz, RAM : 12GB, HDD : 1TB, Nvidia GPU GeForce GTX 950M. Adapun untuk software, kami menggunakan sistem operasi windows 10 Pro 64Bit dan Matlab 2020b.

Dataset yang digunakan merupakan dataset standar yaitu Intel & MobileODT Cervical Cancer



Gambar 4. Arsitektur dari ke-3 model AlexNet berdasarkan variasi jumlah lapisan konvolusi pada setiap blok: (a) Model AlexNet 1 (b) Model AlexNet 2 (c) Model AlexNet 3

Screening [13]. Dataset ini berisi total 1481 gambar yang terdiri atas 3 label tipe penyakit kanker serviks sebagai berikut:

- Tipe 1 (terdiri atas 250 gambar)
- Tipe 2 (terdiri atas 781 gambar)
- Tipe 3 (terdiri atas 450 gambar)

Secara medis, pasien dengan serviks tipe 1 hanya membutuhkan skrining standar. Adapun pasien dengan serviks tipe 2 dan tipe 3 maka membutuhkan proses skrining tingkat lanjut [12].

Karena dataset ini memiliki jumlah gambar yang tidak seimbang antara kelas atau tipe kanker serviksnya, maka kami juga membuat versi dataset yang lebih kecil berdasarkan ukuran gambar dari tipe kanker yang terendah yaitu sejumlah 250 gambar. Sehingga total gambar untuk 3 tipe kanker serviks menjadi 750 gambar yang yang sebanyak 70% dijadikan sebagai data *training* dan sisanya 30% menjadi data *testing*. Untuk mempercepat proses *training*, kami mengubah gambar *training* menjadi ukuran 32 x 32 piksel.

Pengujian dilakukan dengan beberapa parameter training berikut ini:

- *Initial learning rate* senilai 0.0001
- *Learning rate drop factor* senilai 0.1
- *L2 Regularization* senilai 0.004
- *Mini Batch Size* senilai 10

Untuk melihat sensitifitas AlexNet terhadap parameter *epoch*, kami menetapkan nilai *learning rate* menjadi 0.0001 dan *mini batch size* senilai 10. Pada eksperimen yang pertama, parameter *epoch*

akan diujicoba berdasarkan nilai berikut ini: 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 150, 200, dan 300. Berikutnya, kami akan menggunakan 1 nilai *epoch* yang paling optimal kemudian melakukan pengujian terhadap parameter lainnya seperti *mini batch*, *learning rate*. Kemudian dari eksperimen, nilai *minibatch* dan *learning rate* yang terbaik akan digunakan untuk eksperimen berikutnya yaitu untuk melihat pengaruh rasio atau perbandingan antara komposisi data *training* dan data *testing* terhadap performa model AlexNet. Selain itu, kami juga akan membandingkan pengaruh dataset yang disimbangkan (*trimmed*) dengan dataset orisinal. Terakhir, setelah mendapatkan kombinasi parameter yang terbaik, maka pengujian dilakukan terhadap 3 Model arsitektur AlexNet yang digunakan pada penelitian ini (lihat gambar 4).

2.3. Metrik

Untuk mengukur performa dari model CNN AlexNet, kami menggunakan akurasi yang dapat diturunkan berdasarkan *confusion matrix* yang diberikan pada Tabel 1.

Tabel 1. *Confusion Matrix* yang digunakan untuk mengevaluasi model AlexNet

Kanker serviks	Hasil Prediksi		
	Tipe 1	Tipe 2	Tipe 3
Tipe 1	x_{11}	x_{12}	x_{13}
Tipe 2	x_{21}	x_{22}	x_{23}
Tipe 3	x_{31}	x_{32}	x_{33}

Nilai akurasi bisa diperoleh dengan membandingkan jumlah dari hasil prediksi yang tepat terhadap ketiga tipe lalu dibandingkan dengan seluruh hasil prediksi seperti pada persamaan (2).

$$TTP_{all} = \sum_{j=1}^3 x_{jj} \tag{2}$$

Variabel x_{11} adalah total *true* tipe 1, x_{22} total *true* tipe 2, dan x_{33} total *true* tipe 3. Sedangkan *accuracy* keseluruhan diperoleh dari persamaan (3).

$$Akurasi = \frac{TTP_{all}}{All} \tag{3}$$

Variabel *All* adalah seluruh hasil prediksi baik yang tepat (*true*) maupun yang meleset (*false*).

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, penyakit kanker serviks dideteksi berdasarkan *Convolutional Neural Network* dengan arsitektur AlexNet.

3.1. Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter *epoch*

Tabel 2 menunjukkan hasil kinerja (secara akurasi dan efisiensi waktu) AlexNet terhadap dataset

Intel & MobileODT Cervical Cancer Screening berdasarkan parameter epoch.

Tabel 2. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan parameter epoch pada proses training AlexNet

No	Epoch	Akurasi (%)	CPU time (detik)
1	10	44.38	41
2	20	46.10	74
3	30	47.24	106
4	40	47.43	139
5	50	47.72	173
6	60	48.19	207
7	70	48.57	241
8	80	49.71	265
9	90	49.71	346
10	100	49.52	327
11	150	49.90	486
12	200	49.71	647
13	300	52.19	976

Pada percobaan pertama, akurasi pada AlexNet adalah 44.38%. Proses training berhasil meningkatkan akurasi, namun hasil validasi tidak setinggi hasil training. Training berhenti pada epoch 10 dengan tren akurasi yang meninggi. Pada epoch 20 hasil akurasi pada AlexNet berhasil ditingkatkan menjadi 46.10% dan pada epoch 30 akurasi menjadi 47.24%.

Adapun peningkatan epoch dari 30 menjadi 40 nampaknya tidak memberikan pengaruh pada akurasi (hanya meningkat sebesar 0.19%). Demikian pada epoch 50, akurasi hanya meningkat sebesar 0.29%. Hal ini dapat disebabkan faktor generator bilangan acak pada proses inisiasi nilai bobot-bobot model AlexNet. Maksudnya, kombinasi nilai bobot awal yang dihasilkan dapat membuat model tersebut terjebak dalam akurasi stagnan dimana proses pencarian nilai *gradient* tidak berhasil menemukan kombinasi nilai bobot baru yang dapat menghasilkan akurasi yang lebih baik.

Pada epoch 60 berhasil meningkatkan akurasi cukup signifikan menjadi 48.19%. Namun, percobaan berikutnya (epoch 70) perbaikan akurasi tidak signifikan yaitu hanya 0.38%. Menariknya, epoch 80 berhasil menaikkan akurasi menjadi 49.71. Percobaan berikutnya dilakukan pada epoch 90 yang


tidak memberikan kenaikan ataupun penurunan akurasi.

Gambar 5 menunjukkan penambahan epoch berakibat terhadap waktu komputasi yang juga semakin bertambah. Epoch 10 hanya membutuhkan waktu 41 detik. Namun waktu yang dibutuhkan untuk epoch 80 adalah 4 menit 25 detik. Gambar tersebut menunjukkan tren waktu komputasi berbanding lurus dengan pertambahan epoch.


Percobaan berikutnya dilakukan pada epoch 100, akurasi justru mengalami penurunan menjadi 49.52%. Untuk melihat efek parameter epoch lebih jauh, jumlah iterasi ditambahkan menjadi 150 dan hasilnya berhasil meningkatkan akurasi menjadi 49.90%. Namun, ketika ketika epoch ditambahkan menjadi 200 ternyata mengembalikan akurasi seperti pada epoch 90. Padahal, waktu yang dibutuhkan justru semakin meningkat menjadi hampir 11 menit.

Hal ini menunjukkan justru epoch yang tinggi tidak menjamin efektifitas ataupun efisiensi. Untuk memastikan hal ini, maka epoch dapat ditingkatkan lagi. Untuk memastikan pengaruh parameter epoch, kami melakukan eksperimen dengan nilai 300. Hasilnya adalah akurasi dapat mencapai 52.19%. Waktu yang dibutuhkan untuk mencapai akurasi tersebut adalah 16 menit dan 16 detik dengan iterasi total yang diperlukan sebanyak 6600.

Secara umum, penambahan epoch memberikan pengaruh positif sebagaimana tren peningkatan akurasi yang ditunjukkan pada gambar 6. Akan tetapi, antara epoch 100 hingga 200, akurasi nampak berfluktuasi sehingga memberikan pengaruh yang positif terhadap kinerja AlexNet. Selain itu, penambahan epoch melebihi 300 akan semakin membentasi waktu komputasi yang dibutuhkan model AlexNet.



Gambar 5. Waktu komputasi (CPU time) berbanding lurus dengan iterasi yang dilakukan saat proses training (epoch)



Gambar 6. Hasil akurasi AlexNet terhadap parameter epoch

3.2. Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter *minibatch* dan *learning rate*

Tabel 3 menunjukkan perbandingan hasil akurasi dan efisiensi waktu model CNN AlexNet berdasarkan parameter *minibatch* dan *learning rate*. Pada parameter *minibatch*, kami mengujinya dengan nilai 10, 20, 30, dan 40. Adapun parameter epoch yang digunakan adalah 150 karena berdasarkan

eksperimen sebelumnya nilai ini menunjukkan model AlexNet sudah menjadi stabil.

Nilai *minibatch* 10 memberikan hasil akurasi dan CPU *time* terbaik yaitu 49.90% dan 486 detik. Menariknya peningkatan nilai *minibatch* 20 dan 30 justru membuat akurasi berkurang dengan total waktu yang dibutuhkan hampir sama. Namun demikian pada nilai *minibatch* 40, hasil akurasi naik lagi menjadi 46.29% namun memerlukan tambahan waktu sebesar 66 detik. Hal ini menunjukkan parameter *minibatch* tidak memberikan pengaruh signifikan terhadap performa model CNN AlexNet. Dengan kata lain, nilai *minibatch* 10 sudah cukup baik.

Tabel 3. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan parameter *minibatch* dan *learning rate*

No	<i>minibatch</i>	<i>learning rate</i>	Akurasi (%)	CPU <i>time</i> (detik)
1	10	0.0001	49.90	486
2	20	0.0001	46.29	494
3	30	0.0001	37.33	444
4	40	0.0001	46.29	552
5	10	0.001	47.81	616
6	10	0.01	45.99	691

Pada pengujian parameter *learning rate*, kami menggunakan nilai 0.0001, 0.001, dan 0.01. Semakin besar nilai *learning rate* maka semakin besar fluktuasi proses *training* bobot model jaringan saraf. Oleh karena itu, kami hanya membatasi nilainya sampai 0.01. Nilai akurasi yang terbaik diberikan pada *learning rate* sebesar 0.001 yaitu 47.81% dengan waktu komputasi sebesar 616 detik. Namun demikian nilai ini juga tidak berpengaruh besar karena hanya berkisar antara 45.90% dan 47.81%. Akan tetapi, hasil eksperimen menempatkan bahwasanya nilai *learning rate* yang semakin besar juga menambah waktu komputasi. Oleh karena itu, nilai *learning rate* yang terbaik adalah 0.0001.

Sebagai tambahan, kami juga menguji pengaruh resolusi gambar input sel kanker serviks. Tabel 4 menjelaskan pengaruh parameter resolusi terhadap akurasi dan waktu komputasi yang dibutuhkan CPU. Adapun parameter lainnya ditetapkan sebagai berikut ini: *learning rate* sebesar 0.0001, *minibatch* sebesar 10, dan *epoch* sebesar 150.

Tabel 4. Akurasi dan waktu yang dibutuhkan CPU untuk proses *training* model AlexNet berdasarkan resolusi gambar input

No	Resolusi gambar input (piksel)	Akurasi (%)	CPU <i>time</i> (detik)
1	32 x 32	49.90	486
2	64 x 64	46.10	2621
3	128 x 128	34.67	7382

Dari percobaan resolusi 64 x 64 piksel, hasil akurasi tidak bertambah. Seperti yang telah diduga, waktu komputasi meningkat sebesar 5,4 kali lipat. Hal ini wajar karena dimensi total gambar input meningkat dari yang awalnya 1024 dimensi (untuk resolusi 32 x 32 piksel) menjadi 4096 yaitu sebesar 4 kali lipat. Adapun ketika resolusi gambar input

dinaikkan lagi menjadi 128 x 128 piksel ternyata hasil akurasi semakin menurun menjadi 34.67%.

Hal ini menunjukkan ukuran gambar yang semakin besar justru membuat model AlexNet menjadi semakin tidak efektif. Selain itu, waktu komputasi yang dibutuhkan menjadi sangat besar yaitu 7382 detik atau 123 menit 2 detik. Jika dibandingkan dengan waktu komputasi resolusi gambar input 32 x 32 maka kelipatannya menjadi 15 kali lipat lebih.

3.3. Hasil Eksperimen Sensitivitas terhadap Rasio Data *Training* dan *Testing*

Tabel 5 menunjukkan perbandingan hasil akurasi dan efisiensi waktu model CNN AlexNet berdasarkan rasio daripada data *training* dan data *testing* yang digunakan. Kami memvariasikan data *training* menjadi 70%, 80%, dan 90%. Parameter *epoch* yang digunakan adalah 150, *minibatch* sebesar 10, *learning rate* sebesar 0.0001, dan resolusi gambar input 32 x 32 piksel. Dataset *trimmed* adalah dataset yang jumlah data pada setiap Tipe sudah diseimbangkan (yaitu sejumlah 250 gambar) sesuai dengan ketersediaan data yang terkecil. Adapun data *original* adalah dataset yang tidak dikurangi (1481 gambar).

Tabel 5. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan rasio data *training* dan *testing*

No	Rasio		Dataset	Akurasi (%)	CPU <i>time</i> (detik)
	<i>training/testing</i>				
2	0.5:0.5 ([12])	<i>trimmed</i>	45.00	642	
3	0.7:0.3	<i>trimmed</i>	48.13	593	
4	0.8:0.2	<i>trimmed</i>	50.00	613	
5	0.9:0.1	<i>trimmed</i>	50.67	642	
7	0.5:0.5 ([12])	<i>original</i>	58.41	1316	
8	0.7:0.3	<i>original</i>	53.38	1184	
9	0.8:0.2	<i>original</i>	58.42	1248	
10	0.9:0.1	<i>original</i>	58.11	1637	

Pada percobaan rasio data *training* dan *testing*, didapat hasil akurasi yang terbaik adalah 58.11%. Nilai ini didapatkan rasio 0.9:0.1. Kami juga membandingkan ketika rasio yang digunakan adalah 50:50 ([12]) dan ternyata akurasi hanya mencapai 50.41%.

3.4. Hasil Eksperimen Sensitivitas terhadap Jumlah Lapisan Konvolusi

Setelah mendapatkan nilai rasio data *training* dan *testing* yang optimal (yaitu 0.9:0.1), kami melakukan pengujian terhadap ketiga model AlexNet (lihat gambar 4). Dari pengujian ini, kami ingin melihat pengaruh jumlah lapisan konvolusi pada setiap blok pada arsitektur AlexNet terhadap akurasi dan komputasi waktu yang dibutuhkan pada proses *training*-nya. Jumlah *epoch* yang digunakan adalah 15 untuk membandingkannya dengan model standar *residual network* [12] yang memiliki arsitektur yang lebih kompleks (yaitu memiliki 32 lapisan secara total).

Model AlexNet 1 merupakan model awal yang telah digunakan dimana jumlah lapisan konvolusi pada setiap blok hanya ada 1. Pada model AlexNet 2, jumlah lapisan konvolusi setiap blok digandakan sedangkan pada model AlexNet 3, dilipat sebanyak 3 kali dibandingkan pada model AlexNet 1.

Tabel 6 menunjukkan hasil akurasi dan efisiensi waktu dari ketiga model tersebut. Dari hasil eksperimen, dilapati model AlexNet 2 mampu mencapai akurasi 60.14%, yaitu sedikit lebih rendah (0.86%) dibandingkan dengan model *residual network* yang memiliki total lapisan hampir 2 kali lipat [12]. Menariknya, model AlexNet 3 yang memiliki total lapisan 21 (3 lapisan konvolusi untuk setiap blok) justru menghasilkan akurasi yang paling rendah. Hal ini dapat disebabkan jumlah dataset *training* (1481 gambar) tidak memadai untuk meng-update bobot pada lapisan *network* yang kompleks. Sehingga hasil *training* menjadi tidak efektif. Adapun waktu komputasi dari ketiga model tidak terpatut jauh.

Tabel 6. Perbandingan akurasi dan waktu model yang digunakan terhadap model *residual network* [12].

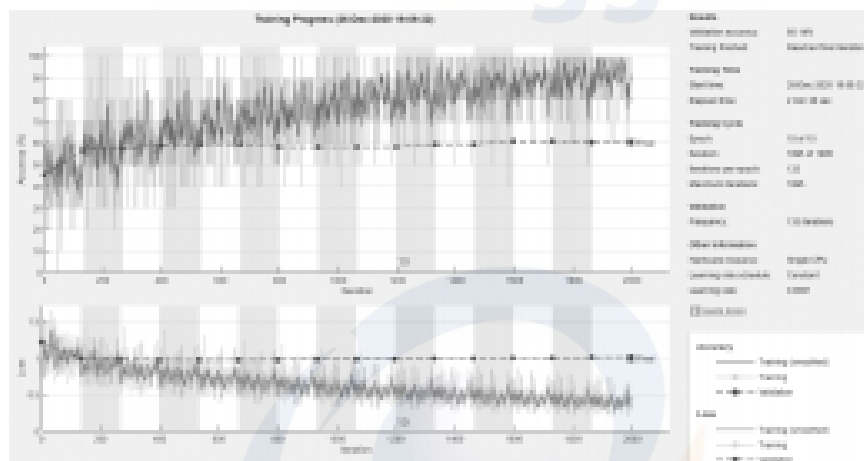
No	Model	Total lapisan	Akurasi (%)	CPU time (detik)
1	<i>residual network</i> ([12])	32	61.00	-
2	AlexNet 1	15	51.35	145
3	AlexNet 2	18	60.14	178
4	AlexNet 3	21	47.87	178

Dari keseluruhan percobaan yang telah dilakukan dapat disimpulkan performa model AlexNet yang terbaik diberikan oleh model AlexNet 2 (memiliki total lapisan 18). Model ini menggunakan parameter *epoch* 15, *minibatch* sebesar 10, *learning rate* sebesar 0.0001, resolusi gambar input 32 x 32 piksel. Adapun, rasio *training* dan *testing* yang digunakan adalah 0.9:0.1. Hasil akurasi yang diberikan mencapai 60.14% dengan waktu komputasi 178 detik seperti yang dapat dilihat pada gambar 7.

Dari hasil diatas ada beberapa hal yang dapat disimpulkan. Model AlexNet yang memiliki jumlah lapisan lebih sedikit mampu memberikan performa akurasi yang hampir sama baiknya dengan model *residual network* [12] yang memiliki lapisan yang hampir 2 kali lebih kompleks. Jika dibandingkan dengan penelitian [12], CNN yang digunakan adalah model *residual neural network* yang terdiri atas 32 lapisan. Meskipun lapisannya sudah sangat banyak, hasil akurasi hanya sedikit lebih baik yaitu 61%. Hal ini menunjukkan bahwasanya klasifikasi kanker serviks menggunakan *deep learning* (CNN) memiliki potensi yang cukup baik bagi dunia kedokteran yang ingin memasukkan unsur otomatisasi proses skrining. Namun demikian, tingkat akurasi domain klasifikasi kanker serviks berdasarkan *deep learning* masih membutuhkan penelitian-penelitian yang lebih baik lagi.

4. KESIMPULAN

Pada penelitian ini, kami telah menguji kinerja model *convolutional neural network* AlexNet terhadap dataset Intel & MobileODT Cervical Cancer Screening. Dari 3 model arsitektur yang telah diuji, model AlexNet 2 yang memiliki lapisan konvolusi ganda pada setiap bloknya menghasilkan akurasi yang paling baik. Hal ini menunjukkan bahwasanya model AlexNet mampu mengklasifikasikan gambar sel kanker serviks. Parameter lain yang juga berpengaruh terhadap akurasi model AlexNet adalah parameter iterasi atau *epoch*. Selain itu, semakin besar data *training* yang digunakan maka hasil akurasi juga cenderung meningkat. Adapun parameter *minibatch* dan *learning rate* cenderung kurang berpengaruh terhadap akurasi model AlexNet. Sedangkan untuk parameter resolusi gambar input, hasil akurasi justru semakin menurun dimana waktu komputasinya juga semakin tinggi.



Gambar 7. Kinerja akurasi dan waktu komputasi CPU model AlexNet 2 pada epoch 15

Pada penelitian berikutnya, akurasi model AlexNet masih perlu ditingkatkan lagi untuk dapat benar-benar pada bidang kesehatan yaitu deteksi penyakit kanker serviks berdasarkan data gambar. Hal ini dapat dilakukan dengan melihat sensitifitas AlexNet terhadap parameter lainnya seperti *dropout* dan algoritma *learning*. Selain itu, kurangnya data *training* dapat dicoba untuk ditasi menggunakan pendekatan augmentasi dataset yang menggunakan transformasi geometri.

5. DAFTAR PUSTAKA

- [1] P. A. Cohen, A. Jhingran, A. Oaknin dan L. Denny, 2019. "Cervical cancer," *Lancet*, vol. 393, no. 10167, pp. 169–182.
- [2] H. Khatimah dan L. Sofiana, 2019. "Evaluasi Program Pencegahan Kanker Payudara dan Kanker Serviks di Kabupaten Sleman," *Doctoral dissertation (Universitas Ahmad Dahlan)*.
- [3] A. H. Baksir, A. Fuad, F. Tempola dan R. Rosihan, 2020. "Prediksi Tingkat Kualitas Kesuburan Pria dengan Jaringan Saraf Tiruan Backpropagation," *JKO (Jurnal Inform. dan Komputer)*, vol. 3, no. 2, pp. 107–112.
- [4] Z. Liu, X. Liu, B. Xiao, S. Wang, Z. Miao, Y. Sun dan F. Zhang, 2020. "Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network," *Phys. Medica*, vol. 69, pp. 184–191.
- [5] P. Wang, J. Wang, Y. Li, L. Li, dan H. Zhang, 2020. "Adaptive Pruning of Transfer Learned Deep Convolutional Neural Network for Classification of Cervical Pap Smear Images," *IEEE Access*, vol. 8, pp. 50674–50683.
- [6] D. C. Cireşan, A. Giusti, L. M. Gambardella, dan J. Schmidhuber, 2013. "Mitosis detection in breast cancer histology images with deep neural networks," in *International Conference on Medical Image Computing and Computer-assisted Intervention*, pp. 411–418.
- [7] T. Araújo, G. Aresta, E. Castro, J. Rouco, P. Aguiar, C. Eloy, A. Polónia dan A. Campilho, 2017. "Classification of breast cancer histology images using convolutional neural networks," *PLoS One*, vol. 12, no. 6, p. 1–14.
- [8] S. Somapathi, R. J. Stanley, W. V., Stoecker, H. Almubarak, R. Long, S. Antani, G. Thoma, R. Zuna dan S. R. Frazier, 2018. "Deep learning nuclei detection in digitized histology images by superpixels," *J. Pathol. Inform.*, vol. 9, pp. 1–10.
- [9] Y. Song, L. Zhang, S. Chen, D. Ni, B. Li, Y. Zhou, B. Lei dan T. Wang, 2014. "A deep learning based framework for accurate segmentation of cervical cytoplasm and nuclei," *Proc. of 2014 36th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2903–2906.
- [10] R. Rasti, M. Tschuchlab dan S. L. Phung, 2017. "Breast cancer diagnosis in DCE-MRI using mixture ensemble of convolutional neural networks," *Pattern Recognit.*, vol. 72, pp. 381–390.
- [11] M. Żejno Michal and Kowal, J. Korbiec dan R. Monczak, 2017. "Classification of breast cancer cytological specimen using convolutional neural network," in *Journal of Physics: Conference Series*, vol. 783, no. 1, p. 12060.
- [12] J. Payette, J. Rachleff dan C. de Graaf, 2017. "Intel and MobileODT Cervical Cancer Screening Kaggle Competition: cervix type classification using Deep Learning and image classification." Stanford University, pp. 1-9.
- [13] Intel, 2017. "Intel & MobileODT Cervical Cancer Screening Which cancer treatment will be most effective?," [Online]. Available: <https://www.kaggle.com/c/intel-mobileodt-cervical-cancer-screening>.
- [14] T. J. Brinker, dkk., 2018. "Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review," *Journal of Medical Internet Research*, vol. 20 (10).
- [15] A. Ghoneim, G. Muhammad, dan M. S. Hossain, 2020. "Cervical cancer classification using convolutional neural networks and extreme learning machines," *Future Generation Computer Systems*, vol. 102, pp. 643-649.

Lampiran 6. Originalitas Penelitian



Surat Pernyataan Originalitas Penelitian

Yang bertandatangan di bawah ini:

Nama : Habibullah Akbar, S.Si.,M.Sc., Ph.D
NIDN : 0315108201
Fakultas / Prodi : Ilmu Komputer / Teknik Informatika
Jabatan Fungsional : Lektor

Dengan ini menyatakan bahwa penelitian saya dengan judul: **Pengembangan Framework KankerNet Berdasarkan Convolutional Neural Networks dan Model PSO untuk Penyakit Kanker Serviks**


Yang diusulkan dalam skema penelitian terapan sumber dana Hibah Internal untuk Tahun Anggaran 2020 bersifat original dan belum pernah dibiayai oleh lembaga / sumberdana lain.

Bilamana di kemudian hari ditemukan ketidaksesuaian dengan pernyataan ini, maka saya bersedia dituntut dan diproses sesuai dengan ketentuan yang berlaku dan mengembalikan seluruh biaya penelitian yang sudah diterima.

Demikian pernyataan ini dibuat dengan sesungguhnya dan dengan sebenar-benarnya.

Jakarta, 29 Juli 2021

Yang menyatakan,


Habibullah Akbar, S.Si.,M.Sc., Ph.D
0315108201

Type text