

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

**Habibullah Akbar<sup>1</sup>, Sandfreni<sup>2</sup>**

<sup>1</sup>Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Esa Unggul

<sup>2</sup>Sistem Informasi, Fakultas Ilmu Komputer, Universitas Esa Unggul

Email: <sup>1</sup>habibullah.akbar@esaunggul.ac.id, <sup>2</sup>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 didapati 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:** *servical 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 Papiloma Virus, meskipun terdapat beberapa faktor lain bayang 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 cnn 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 hispatologi 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 networks 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).

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

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*



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	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. 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



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


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 *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, pertambahan *epoch* memberikan pengaruh positif sebagaimana tren peningkatan akurasi yang ditampakkan 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 membebani waktu komputasi yang dibutuhkan model AlexNet.



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 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 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 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.

### 3.3. Hasil Eksperimen Sensitifitas 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 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. Perbandingan akurasi dan waktu yang dibutuhkan CPU berdasarkan rasio data *training* dan *testing*

No	Rasio <i>training:testing</i>	Dataset	Akurasi (%)	CPU time (detik)
2	0.5:0.5 ([12])	<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 ([12])	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*, 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 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* [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, 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 [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 terpaut jauh.

Tabel 6. Perbandingan akurasi dan waktu model yang diusulkan 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	158
4	AlexNet 3	21	47.97	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 akurasinya 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 diatasi 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," *JIKO (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. Ciresan, 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. Sornapudi, 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. Teshnehlal 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. Żejmo Michałand Kowal, J. Korbicz 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.