

# Cek Similarity

*by* Habibullah Akbar

---

FILE	2606-6887-1-RV.DOCX (790.7K)	WORD COUNT	3576
TIME SUBMITTED	16-JAN-2021 06:08AM (UTC+0700)	CHARACTER COUNT	21732
SUBMISSION ID	1488375489		

## 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

### Abstrak

Menurut Kementerian Kesehatan Republik Indonesia, kanker serviks memiliki kasus sebesar 23,4 per 100.000 penduduk 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 3 lapisan konvolusi, 3 lapisan ReLu, 2 lapisan pooling, dan 3 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 model AlexNet dilakukan terhadap parameter iterasi (*epoch*), subset data *training* untuk mengupdate bobot AlexNet (*minibatch*), laju pembelajaran (*learning rate*), dan resolusi gambar input yang digunakan sebagai *patch* pembelajaran AlexNet. Dari hasil eksperimen didapati bahwasanya akurasi sangat dipengaruhi oleh jumlah iterasi dari proses pembelajaran model, dimana hasil akurasi terbaik diberikan pada *epoch* 300. Selain itu, 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 membuat network gagal meningkatkan performanya. Hal ini menunjukkan model AlexNet masih memerlukan modifikasi baik dari segi arsitektur maupun optimisasi terhadap *hyperparameter* selain dari yang telah diuji pada penelitian ini.

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

## SERVICAL CANCER CLASSIFICATION USING 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 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 3 convolution layers, 3 ReLu layers, 2 pooling layers, and 3 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. AlexNet model testing is carried out on iteration parameters (*epoch*), training data subsets to update AlexNet weights (*minibatch*), learning rate (*learning rate*), and input image resolution used as AlexNet learning patches. From the experimental results, it was found that accuracy is strongly influenced by the number of iterations of the model learning process, where the best accuracy results are given at epoch 300. In addition, 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 make the network fail to improve its performance. This shows that the AlexNet model still requires modification in terms of both architecture and optimization of hyperparameters apart from what has been tested in this study.

**Keywords:** servical cancer, convolutional neural network, AlexNet

### 1. PENDAHULUAN

Kanker serviks termasuk satu dari jenis-jenis kanker yang paling umum. Setiap tahun, sekitar

setengah juga perempuan diseluruh dunia yang terdiagnosis positif kanker serviks dengan angka kematian lebih dari 300.000 [1]. Di Indonesia sendiri

9 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 men<sup>32</sup>ukan 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<sup>1</sup> 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 menjad<sup>21</sup>umor ganas yang menyerang jaringan di mulut rahim. Penyebab utama dari kanker serviks<sup>29</sup> lah 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 [3], [4]. Namun teknologi CNN ini masih memerlukan penelitian agar benar-benar dapat dikembangkan menjadi alat bantu dokter spesialis patalogi 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 [5] 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 [6]. Selain itu, [7] 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 [8]. Yang lebih menarik lagi, penelitian yang dilakukan oleh [9] 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 untuk

kanker payudara yang diambil dari sampel biopsi tanpa melibatkan proses segmentasi [10].

Permasalahannya, pada penelitian-penelitian yang telah dilakukan sebelumnya, model AlexNet baru diujicoba pada gambar kanker payudara [10] dimana akurasi yang dihasilkan dapat mencapai nilai 80%. Pada penelitian yang dilakukan oleh [11], akurasi yang dihasilkan oleh metode CNN *deep residual network* yang mereka usulkan tidak melebihi 60%.

Gambar 1 menunjukkan secara visual 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 [10] dan (b) sel kanker serviks [11].

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


## 2. METODE

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 [12] terdiri atas 3 lapisan konvolusi, 3 lapisan ReLu, 2 lapisan *pooling*, dan 3 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 Screeni [19] Sample gambar dari 3 kategori kanker serviks (tipe 1, tipe 2, dan tipe 3) dapat dilihat pada gambar 3.



Gambar 3. Samp [3] 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*.

### 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 block 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.

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

Tabel 1. *Confussion 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).

$$TTP_{all} = \sum_{j=1}^3 x_{jj} \quad (2)$$

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).

$$A = \frac{TTP_{all}}{All} \quad (3)$$

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. 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 Screening [12] (tersedia di Kaggle). Dataset ini berisi 1481 gambar untuk 3 tipe kanker serviks. Namun dataset ini memiliki jumlah gambar yang tidak seimbang antara kelas atau tipe kanker serviksnya. Oleh karena itu, kami menggunakan 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 mengubah gambar *training* menjadi ukuran 227 x 27 piksel. Gambar tersebut terdiri atas 3 label yaitu:

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

Contoh sampel dari gambar *training* tersebut diberikan pada gambar x.

Pasien dengan serviks tipe 1 hanya membutuhkan skrining standar. Adapun pasien dengan serviks tipe 2 dan tipe 3 maka membutuhkan proses skrining tingkat lanjut [11].

Pengujian dilakukan dengan beberapa parameter *training* berikut ini:

- *Initial learning rate* senilai 0.0001
- *Learning rate drop factor* senilai 0.1
- *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. Hal ini bermaksud untuk melihat sensitifitas dari model AlexNet berdasarkan jumlah iterasi *training*. Berikutnya, akan dilakukan pengujian parameter terhadap *mini batch* dan *learning rate*.

#### 3.1. Hasil Eksperimen Sensitifitas AlexNet terhadap Parameter epoch

Tabel 2 menunjukkan hasil kinerja (secara akurasi dan efisiensi waktu) AlexNet terhadap dataset tel & 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 tidak memberikan kenaikan ataupun penurunan akurasi.

Gambar 4 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 4. Waktu komputasi (CPU time) berbanding lurus dengan 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 ditunjukkan pada gambar 5. 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



Gambar 5. Kinerja akurasi dan waktu komputasi CPU model AlexNet pada epoch 300

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.

Dari keseluruhan percobaan yang telah dilakukan dapat disimpulkan performa model

AlexNet yang terbaik diberikan untuk kombinasi parameter epoch 300, *minibatch* sebesar 10, *learning rate* sebesar 0.0001, dan resolusi gambar input 32 x 32 piksel. Hasil akurasi yang diberikan mencapai 52.19% dengan waktu komputasi 976 detik.

Dari hasil diatas ada beberapa hal yang dapat disimpulkan. Model AlexNet tidak mampu memberikan performa akurasi yang tinggi karena jumlah lapisan bloknnya terlalu sedikit dibandingkan dengan model *convolutional neural network* lainnya. Jika dibandingkan dengan penelitian [11], CNN yang digunakan adalah model residual network dimana lapisannya dapat mencapai sekitar 100 lapisan. Meskipun lapisannya sudah sangat banyak, hasil akurasinya hanya mencapai 60%. Hal ini menunjukkan bahwasanya klasifikasi kanker serviks memberikan tantangan yang besar bagi dunia kedokteran ketika ingin memasukkan unsur otomatisasi proses skrining. Dengan kata lain, *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 4 parameter yang telah diuji, parameter yang paling berpengaruh terhadap akurasi model AlexNet adalah parameter iterasi atau *epoch*. Adapun parameter *minibatch* dan *learning rate* cenderung kurang berpengaruh terhadap akurasi model AlexNet. Adapun untuk parameter resolusi gambar input, hasil akurasi justru semakin menurun dimana waktu komputasinya juga semakin tinggi. Hal ini menunjukkan bahwasanya model AlexNet tidak mampu secara efektif mengklasifikasikan gambar sel kanker serviks.

Pada penelitian berikutnya, jumlah lapisan blok dan lapisan *fully-connected* pada arsitektur AlexNet bisa ditambah. Selain itu, jumlah data 250 belum mencukupi untuk melatih model AlexNet dengan baik. Sehingga model ini dapat diujicoba lagi dengan dataset yang jauh lebih besar.

#### 5. DAFTAR PUSTAKA

- [1] P. A. Cohen, A. Jhingran, A. Oaknin, and L. Denny, 2019. "Cervical cancer," *Lancet*, vol. 393, no. 10167, pp. 169–182
- [2] H. Khatimah and L. Sofiana, 2019. "Evaluasi Program Pencegahan Kanker Payudara dan Kanker Serviks di Kabupaten Sleman," Universitas Ahmad Dahlan
- [3] Z. Liu *et al.*, "Segmentation of organs-at-risk in cervical cancer CT images with a convolutional neural network," 2020. *Phys. Medica*, vol. 69, pp. 184–191.
- [4] P. Wang, J. Wang, Y. Li, L. Li, and H. Zhang, 2020. "Adaptive Pruning of Transfer

- Learned Deep Convolutional Neural Network for Classification of Cervical Pap Smear Images,” *IEEE Access*, vol. 8, pp. 4 674–50683
- [5] D. C. Ciresan, A. Giusti, L. M. Gambardella, and 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. 41 17–18
- [6] T. Araújo *et al.*, 2017. “Classification of breast cancer histology images using convolutional neural networks,” *PLoS One*, vol. 27 2, no. 6, p. e0177544
- [7] S. Sornapudi *et al.*, 2018. “Deep learning nuclei detection in digitized histology images by superpixels,” *J. Pathol. Inform.*, 6 1. 9
- [8] Y. Song *et al.*, 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.
- [9] 13 R. Rasti, M. Teshnehlab, and S. L. Phung, 2017. “Breast cancer diagnosis in DCE-MRI using mixture ensemble of convolutional neural networks,” *Pattern Recognit.*, vol. 72, 8 381–390
- [10] M. Żejmo Michał and Kowal, J. Korbicz, and 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.
- [11] 23 J. Payette, J. Rachleff, and C. de Graaf, 2017. “Intel and MobileODT Cervical Cancer Screening Kaggle Competition: cervix type classification using Deep Learning and image classification.” Stanford University
- [12] Intel, 2017. “Intel & MobileODT Cervical Cancer Screening Which cancer treatment will be most effective?. Tersedia [https://www.kaggle.com/c/intel-mobileodt-cervical-cancer-screening] diakses 5 Oktober 2020.

# Cek Similarity

## ORIGINALITY REPORT

% **12**  
SIMILARITY INDEX

% **10**  
INTERNET SOURCES

% **7**  
PUBLICATIONS

% **7**  
STUDENT PAPERS

## PRIMARY SOURCES

**1** [jurnalmahasiswa.unesa.ac.id](http://jurnalmahasiswa.unesa.ac.id) % **1**  
Internet Source

**2** Submitted to Universitas Brawijaya % **1**  
Student Paper

**3** [repository.its.ac.id](http://repository.its.ac.id) % **1**  
Internet Source

**4** [www.osapublishing.org](http://www.osapublishing.org) % **1**  
Internet Source

**5** Submitted to Aspen University % **1**  
Student Paper

**6** Siraj Khan, Muhammad Sajjad, Tanveer Hussain, Amin Ullah, Ali Shariq Imran. "A Review on Traditional Machine Learning and Deep Learning Models for WBCs Classification in Blood Smear Images", IEEE Access, 2020 % **1**  
Publication

**7** Submitted to University of Sydney % **1**  
Student Paper

Submitted to University of Warwick

8

Student Paper

% 1

9

[eprints.uad.ac.id](https://eprints.uad.ac.id)

Internet Source

% 1

10

[www.hindawi.com](http://www.hindawi.com)

Internet Source

&lt;% 1

11

[ejournal.unkhair.ac.id](http://ejournal.unkhair.ac.id)

Internet Source

&lt;% 1

12

Submitted to Universitas Indonesia

Student Paper

&lt;% 1

13

Jun Zhang, Ashirbani Saha, Zhe Zhu, Maciej A. Mazurowski. "Hierarchical Convolutional Neural Networks for Segmentation of Breast Tumors in MRI With Application to Radiogenomics", IEEE Transactions on Medical Imaging, 2019

Publication

&lt;% 1

14

Submitted to Universitas Esa Unggul

Student Paper

&lt;% 1

15

Erik Meijering. "A bird's-eye view of deep learning in bioimage analysis", Computational and Structural Biotechnology Journal, 2020

Publication

&lt;% 1

16

"Advances in Intelligent Information Hiding and Multimedia Signal Processing", Springer Science and Business Media LLC, 2018

&lt;% 1

- 
- 17 Dalal Bardou, Kun Zhang, Sayed Mohammad Ahmad. "Classification of Breast Cancer Based on Histology Images Using Convolutional Neural Networks", IEEE Access, 2018  
Publication <% 1
- 
- 18 [www.oplossing.be](http://www.oplossing.be)  
Internet Source <% 1
- 
- 19 [id.scribd.com](http://id.scribd.com)  
Internet Source <% 1
- 
- 20 [worldwidescience.org](http://worldwidescience.org)  
Internet Source <% 1
- 
- 21 [digilib.unisayogya.ac.id](http://digilib.unisayogya.ac.id)  
Internet Source <% 1
- 
- 22 [www.science.gov](http://www.science.gov)  
Internet Source <% 1
- 
- 23 Oluwatomisn E. Aina, Steve A. Adeshina, A.M Aibinu. "Classification of Cervix types using Convolution Neural Network (CNN)", 2019 15th International Conference on Electronics, Computer and Computation (ICECCO), 2019  
Publication <% 1
- 
- 24 [docshare.tips](http://docshare.tips)  
Internet Source <% 1
- 
- 25 Wenbo Wang, Haiyan Ni, Lin Su, Tao Hu,

Qunyan Ren, Peter Gerstoft, Li Ma. "Deep transfer learning for source ranging: Deep-sea experiment results", The Journal of the Acoustical Society of America, 2019

Publication

<% 1

26

[www.ijitee.org](http://www.ijitee.org)

Internet Source

<% 1

27

[download.atlantis-press.com](http://download.atlantis-press.com)

Internet Source

<% 1

28

[dhoeszhat.blogspot.com](http://dhoeszhat.blogspot.com)

Internet Source

<% 1

29

[etheses.uin-malang.ac.id](http://etheses.uin-malang.ac.id)

Internet Source

<% 1

30

[www.offshoresoftwaredevelopmentindia.com](http://www.offshoresoftwaredevelopmentindia.com)

Internet Source

<% 1

31

[adoc.tips](http://adoc.tips)

Internet Source

<% 1

32

[www.kemkes.go.id](http://www.kemkes.go.id)

Internet Source

<% 1

EXCLUDE QUOTES ON

EXCLUDE ON

BIBLIOGRAPHY

EXCLUDE MATCHES

< 5 WORDS