

KLASIFIKASI TIPE SEL NORMAL/ABNORMAL BERDASARKAN CITRA PAP-SMEAR MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

Muhamad Fathurahman¹², Rachmadhani Ajeng Nurmufthi¹, Elan Suherlan¹²

¹Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas YARSI, Jakarta

²Lab. Komputasi Cerdas, Fakultas Teknologi Informasi, Universitas YARSI, Jakarta

E-mail: muhammad.fathurrachman@yarsi.ac.id, ajengmufthi@gmail.com, elan.suherlan@yarsi.ac.id

Abstract

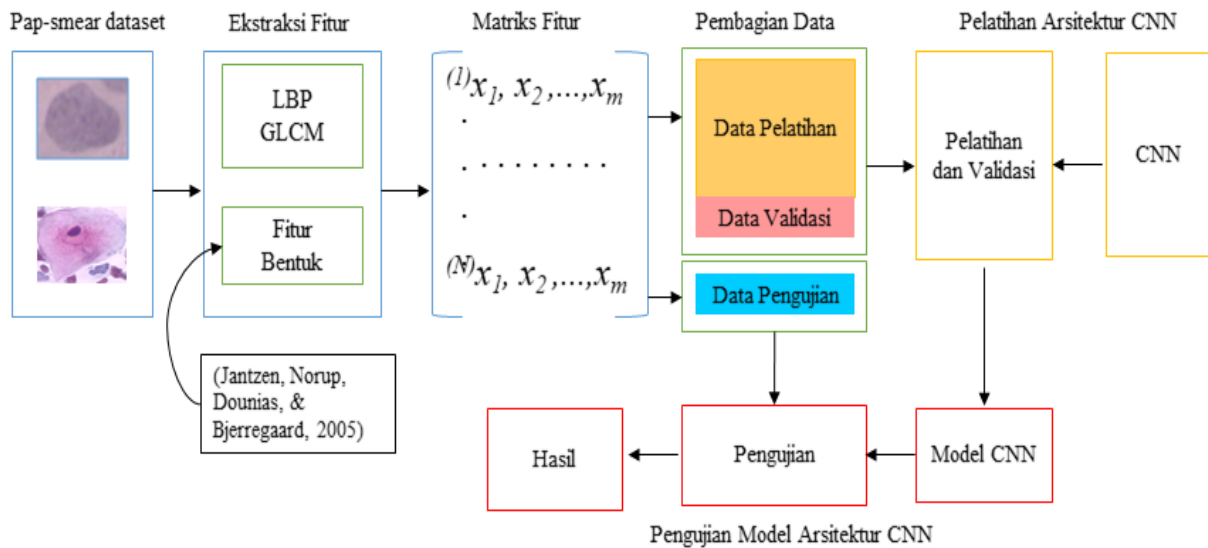
The classification of cell types plays an essential role in monitoring the growth of cancer cells. One of the methods to determine the cancer type is to analyze the *pap-smear* images manually. Nevertheless, the manual analysis of *pap-smear* images by the expert has several limitations, such as time-consuming and prone to misdiagnosis. For reducing the risks, it requires the automatic classification of cell types based on *pap-smear* images. This study utilizes the convolutional neural network (CNN) architectures to automatically classify the cell type into two-class categories (normal/abnormal) based on three features. These features, such as the local binary pattern, gray level co-occurrence matrix, and shape features, are extracted from *pap-smear* images. This study shows the performance of CNN achieved the maximum accuracy of 99.98%, 100.0%, 99.78% in training, validation, and testing data. Our approach also outperforms the performance of the baseline methods.

Keywords : *CNN, Classification, Cell, Neural Network, Pap-smear*

Abstrak

Klasifikasi jenis sel memainkan peranan penting dalam memantau pertumbuhan sel kanker. Salah satu metode untuk menentukan jenis kanker adalah dengan menganalisis secara manual gambar *pap-smear*. Namun demikian, analisis manual gambar *pap-smear* oleh ahli memiliki beberapa keterbatasan seperti memakan waktu lama dan rentan terhadap kesalahan diagnosis. Untuk mengurangi risiko pembatasan seperti di atas, klasifikasi otomatis tipe sel diperlukan. Penelitian ini memanfaatkan arsitektur *convolutional neural network* (CNN) untuk secara otomatis mengklasifikasikan tipe sel ke dalam kategori dua kelas (normal / abnormal) berdasarkan tiga fitur berbeda termasuk *local binary pattern*, *gray level co-occurrence Matrix*, dan fitur bentuk (*shape feature*). Penelitian ini menunjukkan bahwa, kinerja CNN mencapai akurasi maksimum 99,98%, 100,0%, 99,78% dalam data pelatihan, validasi dan pengujian. Selain itu, pendekatan yang digunakan juga mengungguli kinerja dari metode umum lainnya.

Kata Kunci : *CNN, Klasifikasi, Sel, Neural Network, Pap-smear*



Gambar 1. Desain Eksperimen

1. PENDAHULUAN

Klasifikasi jenis sel memiliki peranan penting dalam memantau perkembangan penyakit kanker (Jantzen & Dounias, 2006). Salah satu metode yang digunakan untuk melihat perkembangan sel adalah dengan menganalisis citra-pap smear. Citra *pap-smear* adalah gambar pengamatan sel tunggal di bawah mikroskop yang diproses menggunakan metode pewarnaan *Pa-panicolau* untuk mendeteksi tahapan suatu penyakit, salah satunya adalah kanker (Jantzen & Dounias, 2006). Namun, pemeriksaan secara manual memiliki beberapa kelemahan diantaranya adalah membutuhkan waktu yang lama (Ampazis, Dounias, & Jantzen, 2010), dan dapat terjadi kesalahan pada saat analisis karena berdasarkan pada pengalaman pakar. Untuk mengurangi resiko dari kesalahan diatas, sistem klasifikasi jenis sel pada citra sel tunggal *pap-smear* dibutuhkan.

Sejumlah penelitian sistem klasifikasi jenis sel tunggal secara otomatis telah banyak dilakukan dengan menggunakan algoritma pembelajaran mesin khususnya pada tahapan klasifikasi. Algoritma yang telah digunakan adalah *neural network* (Ampazis dkk., 2010), (Devi, Ravi, Vaishnavi, & Punitha, 2016), *least square support vector machine*, *multi layer perceptron*, *random forest*, *bayesian*, dan *ensemble* (Bora, Chowdhury, Mahanta, Kundu, & Das, 2017), *linear discriminant analysis*, *k-nearest neighbour*, (Chankong, Theera-Umpon, & Auephanwiriyakul, 2014). Klasifikasi citra sel tunggal *pap-smear* sulit dilakukan karena citra sel tunggal *pap-smear* terdapat *overlapped-cell*

(citra sel tunggal yang tumpang tindih) dan dimensi gambar yang besar sehingga membutuhkan waktu komputasi yang lebih lama. Untuk menangani masalah di atas, sebelum melakukan tahapan klasifikasi, dilakukan alih bentuk (*transformation*) pada citra sel tunggal *pap-smear* yang disebut dengan ekstraksi fitur. Ekstraksi fitur dilakukan untuk memperoleh informasi relevan dari citra sel tunggal *pap-smear* dalam bentuk beberapa nilai numerik sebelum diproses oleh algoritma klasifikasi. Pada penelitian Bora dkk (Bora dkk., 2017), fitur bentuk (*shape features*), fitur tekstur dan *ripple descriptor* digunakan sebagai dasar dalam mengklasifikasikan jenis sel tunggal. Penelitian (Bora dkk., 2017) mendapatkan nilai akurasi sebesar 96.51%. Pada penelitian Chankong dkk (Chankong dkk., 2014), klasifikasi sel tunggal dilakukan berdasarkan fitur bentuk yang diperoleh dari hasil segmentasi citra sel tunggal menggunakan *fuzzy c-means*. Nilai akurasi yang didapatkan oleh (Chankong dkk, 2014) adalah 99.27%. Selain itu, pendekatan *multi-feature fusion* berdasarkan fitur *gray level co-occurrence matrix* (GLCM), fitur bentuk, dan fitur pola biner (*local binary pattern*) menggunakan *deep belief network* (DBN) menghasilkan nilai akurasi maksimal 97.35% (Muhamad, Wasito, Mufidah, & Ghaisani, 2018). Penelitian sebelumnya lebih menekankan pada proses ekstraksi fitur dan alih bentuk fitur untuk meningkatkan akurasi klasifikasi citra sel tunggal. Oleh karena itu penelitian ini mengusulkan metode klasifikasi berdasarkan fitur GLCM, LPB dan fitur bentuk (*shape feature*) yang dialih bentukkan (*transformasi*) melalui arsitektur *convolutional neural network* (CNN). Penelitian ini bertujuan

untuk mengevaluasi pengaruh representasi fitur dari proses alih bentuk menggunakan arsitektur CNN terhadap nilai akurasi dari klasifikasi citra sel tunggal *pap-smear*.

Sistematika penulisan artikel ini disusun sebagai berikut. Bagian dua membahas tentang kerangka eksperimen yang digunakan pada penelitian ini mencakup dataset, metode ekstraksi fitur dan metode evaluasi. Bagian tiga membahas mengenai hasil eksperimen. Kesimpulan dan rencana kerja selanjutnya diberikan pada bagian empat.

2. METODE DAN DATASET

2.1 Desain Eksperimen

Alur desain eksperimen dapat dilihat pada Gambar 1. Tahapan pertama sebelum melakukan klasifikasi adalah melakukan ekstraksi fitur pada citra sel tunggal. Metode ekstraksi fitur yang digunakan pada penelitian ini adalah LBP dan GLCM serta fitur bentuk yang didapatkan dari penelitian (Jantzen dkk., 2005). Rincian fitur dapat dilihat pada Tabel 1 di bawah ini:

Tabel 1. Hasil ekstraksi fitur

Jenis Fitur	Jumlah Fitur
LBP	59
GLCM	4
Fitur Bentuk	20
Total	83

Hasil ekstraksi fitur dari setiap citra sel tunggal dihimpun menjadi sebuah dataset. dataset ini dibagi menjadi tiga bagian subset yang terdiri dari data *pelatihan*, *data validasi* dan *data pengujian*. Metode pembagian data menggunakan metode *hold-out crossvalidation*. Data pelatihan dan validasi digunakan untuk melakukan pelatihan dan mencari konfigurasi yang tepat pada arsitektur CNN sedangkan data pengujian digunakan untuk mengukur performa dari arsitektur CNN yang telah didapatkan pada proses pelatihan. Proporsi pembagian data pelatihan 90 %, validasi dan pengujian 5 %. Jumlah dari setiap proporsi dapat dilihat pada Tabel 2 di bawah ini.

Tabel 2. Proporsi pembagian data pelatihan, validasi dan pengujian

Pelatihan	Validasi	Pengujian
827	44	46

Adapun arsitektur CNN yang diujikan pada penelitian ini adalah sebanyak tiga arsitektur yang memiliki jumlah layer dan jumlah *hidden unit* yang berbeda. Parameter ini dapat dilihat pada Tabel 5 di bawah ini.


Tabel 3. Arsitektur CNN

Arsitektur	Jumlah Layer	Unit Layer
CNN ₁	2	(256,128)
CNN ₂	3	(256, 128, 64)
CNN ₃	4	(256,128,64,32)

Parameter lain yang diatur pada arsitektur CNN adalah nilai *batch size* = 20, *drop out* = 0.5, *kernel-size* = 2, *stride* = 2, *epoch* = 10, dan *regularization* = 0.0001. Selanjutnya, arsitektur CNN yang telah dibangun sesuai dengan parameter di atas, dilatih menggunakan data pelatihan dan dievaluasi menggunakan data validasi dan pengujian. Eksperimen pelatihan dan evaluasi dari setiap arsitektur CNN dilakukan sebanyak 30 kali kemudian dihitung nilai rata-rata akurasi yang didapatkan.

2.2 Dataset

Dataset yang digunakan pada penelitian ini adalah Herlev dataset yang bersumber dari (Jantzen & Dounias, 2006). Dataset ini berisi citra sel tunggal *pap-smear* berjumlah 917 citra yang terdiri dari tujuh jenis sel tunggal yang berbeda. Tujuh jenis sel tunggal yang dapat dikategorikan menjadi dua kelas



Gambar 2. Arsitektur CNN

utama yaitu normal dan abnormal (Jantzen & Dounias, 2006). Jumlah distribusi dari setiap kelas dapat dilihat pada tabel 1 di bawah ini.

Tabel 4. Herlev Dataset (Jantzen & Dounias, 2006)

No	Jenis Sel	Jumlah	Kategori
1	<i>Superficial squamous epithelial</i>	74	Normal
2	<i>Intermediate squamous epithelial</i>	70	
3	<i>Columnar epithelial</i>	98	
4	<i>Mild squamous non-keratinizing dysplasia</i>	182	Abnormal
5	<i>Moderate squamous non-keratinizing dysplasia</i>	146	
6	<i>Severe squamous non-keratinizing dysplasia</i>	197	
7	<i>Squamous cell carcinoma in situ intermediate</i>	150	

2.3 Convolutional Neural Network

Convolutional neural network merupakan pengembangan dari multilayer neural network yang secara khusus untuk menerima masukan berupa citra dua dimensi (2D) (Lecun, Bottou, Bengio, & Haffner, 1998). Secara umum, CNN terbagi menjadi tiga *layer* (lapisan) yaitu *convolutional layer*, *pooling layer* dan *fully-connected layer* (FC). *Convolutional layer* menerima sebuah citra dan melakukan komputasi menggunakan sebuah *filter*. Hasil komputasi dari *Convolutional Layer* adalah sebuah *feature maps*.

Selanjutnya, *feature map* dijadikan sebagai masukan pada *pooling layer*. *Pooling layer* bertujuan melakukan penyusutan dimensi pada *feature map*. Hasil pemrosesan pada *pooling layer* akan diproses pada *convolutional layer* berikutnya. Setelah melakukan komputasi hingga pada *convolutional* dan *pooling layer* terakhir. Keluaran dari *convolutional* dan *pooling layer* dimasukkan pada *fully-connected layer*. Lapisan pada *fully connected layer* memiliki mekanisme yang sama dengan arsitektur multilayer perceptron, bobot yang terhubung pada setiap layer diperbaharui menggunakan algoritma *gradient-descent* (Zhou, 2018). Ilustrasi arsitektur CNN dapat dilihat pada Gambar 2.s

2.4 Fitur Bentuk (Shape Feature)

Pada penelitian ini, fitur bentuk yang digunakan merujuk pada penelitian yang dilakukan oleh (Jantzen et al., 2005). Jantzen dkk, melakukan ekstraksi fitur dengan mengukur 14 atribut pada sel dan inti sel (nucleus) yang terdapat pada citra *pap-smear* sel tunggal yang telah dilakukan proses segmentasi (Jantzen dkk., 2005). Atribut yang diukur pada citra *pap-smear* sel tunggal tersegmentasi dapat dilihat pada Tabel 2 di bawah ini

Tabel 5. Fitur Bentuk (Jantzen dkk., 2005)

No	Nama Atribut
1	N Area
2	C Area
3	N/C Ratio
4	N Brightness
5	C Brightness
6	N Shortest diameter
7	N longest diameter
8	N elongation
9	N roundness
10	C shortest diameter
11	C longest diameter
12	C elongation
13	C roundness
14	N perimeter
15	C perimeter
16	N relative position

17	Maxima in N
18	Minima in N
19	Maxima in C
20	Minima in C

2.5 Local Binary Pattern (LBP)

Local binary pattern adalah metode ekstraksi fitur yang umum digunakan pada pengolahan citra. Metode ini melakukan konversi nilai setiap *pixel x* pada citra *gray level* dengan mempertimbangkan nilai barisan bilangan biner yang didapatkan dari perbandingan setiap nilai *pixel* tetangga *y* menggunakan aturan sebagai berikut:

$$t(y) = \begin{cases} 1 & y > x \\ 0 & y \leq x \end{cases} \quad (1)$$

y adalah nilai *pixel* tetangga dari *pixel x*. Fungsi ini diterapkan kepada semua *pixel* tetangga dari *x* dengan pola memutar mengikuti arah jarum jam yang akan membentuk sebuah kombinasi bilangan biner. Kombinasi bilangan biner yang terbentuk dari *pixel* tetangga dari *x* kemudian dikonversi ke nilai desimal dan diinisialisasi sebagai nilai baru pada *pixel x* sesuai formula di bawah ini

$$x' = des(\{y_1, y_2, \dots, y_N\}) \quad (2)$$

x' adalah nilai desimal yang merupakan konversi dari barisan bilangan biner berdasarkan tetangga *pixel x*, *y* adalah *pixel* tetangga *x* dan *N* adalah jumlah *pixel* tetangga *x*. Setelah semua *pixel* pada citra *gray level* diinisialisasi dengan nilai baru, Fitur LBP didapatkan dari nilai histogram pada citra *gray level* yang telah ditransformasi ke dalam bentuk 1-dimensi (Liu & Kan, 2016).

2.6 Gray Level Co-occurrence Matrix (GLCM)

Gray level co-occurrence matrix (GLCM) adalah metode ekstraksi fitur berdasarkan matrik tabulasi dari setiap nilai *pixel* pada citra *gray scale* (Liu & Kan, 2016). Nilai fitur yang dapat diperoleh dari GLCM adalah *contrast*, *homogeneity*, *energy* dan *correlation*. Perhitungan nilai fitur tersebut menggunakan formula yang diusulkan oleh (Haralick & Shanmugam, 1973) dan dapat dilihat di bawah ini:

$$Contrast = \sum_{i,j} |i - j|^2 m(i, j) \quad (3)$$

$$Homogeneity = \sum_{i,j} \frac{m(i,j)}{1 + |i-j|} \quad (4)$$

$$Energy = \sum_{i,j} m(i, j)^2 \quad (5)$$

$$Correlation = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)m(i,j)}{\sigma_i \sigma_j} \quad (6)$$

m(i,j) adalah nilai pada elemen matrix baris ke *i* dan kolom *j* dari setiap nilai *pixel* pada citra. Sedangkan

μ adalah *mean* dan σ adalah *variance* (Haralick & Shanmugam, 1973).

2.7 Metode Evaluasi

Metode evaluasi yang digunakan pada penelitian ini adalah menghitung nilai akurasi dari hasil klasifikasi berdasarkan formula (7) di bawah ini:

$$\text{Akurasi} = \frac{TP+TN}{K} \quad (7)$$

TP adalah nilai citra sel tunggal abnormal yang diklasifikasikan sebagai citra sel tunggal abnormal. TN adalah citra sel tunggal normal yang diklasifikasikan sebagai citra sel tunggal normal. K adalah jumlah citra sel tunggal.

3. HASIL DAN DISKUSI

Penggunaan arsitektur CNN untuk klasifikasi melibatkan banyak parameter seperti jumlah *layer*, *hidden unit* dan *epoch* yang dapat mempengaruhi nilai akurasi. Oleh karena bagian ini membahas hasil dari eksperimen penggunaan arsitektur CNN berdasarkan konfigurasi parameter yang berbeda. Pada penelitian ini, dilakukan dua tahap eksperimen yang bertujuan untuk mencari konfigurasi parameter terbaik arsitektur CNN dalam melakukan klasifikasi. Eksperimen pertama bertujuan untuk melihat pengaruh perbedaan jumlah *layer* dan *hidden unit* terhadap nilai akurasi dari klasifikasi kelas normal dan abnormal pada citra sel tunggal *pap-smear*. Eksperimen kedua bertujuan untuk melihat pengaruh nilai *epoch* pada arsitektur terbaik berdasarkan eksperimen pertama. Arsitektur CNN yang digunakan pada kedua eksperimen ini merujuk pada Tabel 3 di atas.

3.1 Hasil Eksperimen 1

Hasil eksperimen 1 dapat dilihat pada Tabel 6 di bawah ini.

Tabel 1. Hasil Eksperimen 1

Arsitektur	Akurasi		
	Data Pelatihan	Data Validasi	Data Pengujian
CNN ₁	98.40%	97.72%	98.04%
CNN ₂	98.52%	97.95%	99.13%
CNN ₃	98.60%	96.13%	97.60%

berdasarkan hasil eksperimen 1, arsitektur CNN₂ memiliki nilai akurasi pada data pengujian yang lebih tinggi yaitu 99.13% diikuti oleh CNN₁ 98.04% dan CNN₃ sebesar 97.60%. Walaupun CNN₃ memiliki nilai akurasi pada data pelatihan yang lebih besar dari CNN₁ dan CNN₂, hal ini tidak menjadi pertimbangan karena, data pelatihan sudah dikenali pada proses pelatihan sehingga cenderung

memiliki nilai akurasi yang selalu tinggi. Adapun nilai akurasi pada data validasi dan pengujian dapat menggambarkan kemampuan generalisasi dari arsitektur CNN yaitu kemampuan mengklasifikasikan secara benar data yang tidak terlibat pada proses pelatihan. Pada eksperimen ini, terlihat bahwa CNN₂ dan CNN₁ memiliki kemampuan generalisasi yang baik.

3.2 Hasil Eksperimen 2

Eksperimen ini bertujuan untuk melihat pengaruh nilai *epoch* terhadap nilai akurasi hasil klasifikasi pada arsitektur CNN₁ dan CNN₂. Nilai *epoch* yang diuji adalah [10,100,200,300]. Hasil dari eksperimen 2 dapat dilihat pada Tabel 7 di bawah ini.

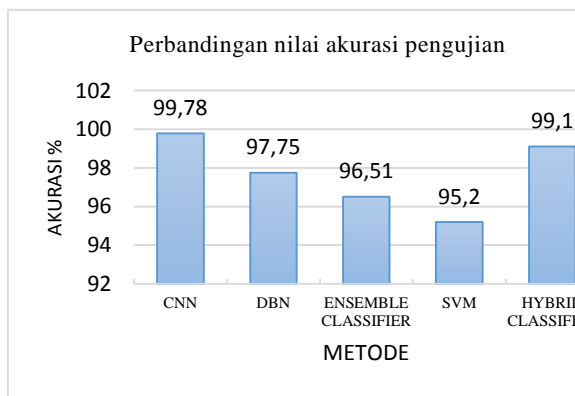
Tabel 2. Hasil eksperimen 2

Arsitektur	Epoch	Akurasi		
		Data Pelatihan	Data Validasi	Data Pengujian
CNN ₁	10	98.40%	97.72%	98.04%
	100	100.0%	100.0%	99.34%
	200	99.98%	99.77%	99.56%
	300	100.0%	99.70%	99.56%
CNN ₂	10	98.52%	97.95%	99.13%
	100	99.96%	99.31%	99.56%
	200	99.98%	100.0%	99.78%
	300	100.0%	99.09%	99.34%

Berdasarkan hasil pada Tabel 7, terjadi peningkatan nilai akurasi pada data pengujian ketika nilai *epoch* ditingkatkan dari 10-200 pada arsitektur CNN₁ dan CNN₂. CNN₂ pada epoch 200, memiliki nilai akurasi pada data pengujian yaitu 99.76% diikuti oleh CNN₁ sebesar 99.56%. Adapun ketika nilai *epoch* ditingkatkan pada nilai 300, nilai akurasi pada arsitektur CNN₂ cenderung menurun, hal ini dapat terjadi karena pendekatan *gradient descent* yang diadopsi oleh algoritma CNN dapat terjebak pada solusi *local minima*.

3.3 Perbandingan dengan Metode Lain

Pada bagian ini, performa CNN berdasarkan fitur LPB, GLCM dan fitur bentuk (Shape Features) akan dibandingkan dengan beberapa penelitian sebelumnya yang dilakukan oleh (Bora dkk., 2017) dan (Muhamad dkk., 2018) yang dapat dilihat pada grafik di bawah ini.



Gambar 1. Perbandingan akurasi metode CNN dengan metode lain

Pada Gambar 3 di atas, CNN₂ berdasarkan fitur bentuk, GLCM dan LBP, memiliki hasil akurasi yang lebih baik dibanding dengan metode DBN oleh (Muhamad dkk., 2018) dan metode Ensemble, SVM dan Hybrid Classifier oleh (Bora dkk., 2017).

4. KESIMPULAN DAN RENCANA SELANJUTNYA

Penelitian ini mencoba untuk mengevaluasi performa arsitektur CNN berdasarkan fitur bentuk, GLCM dan LBP dengan mengukur nilai akurasi dari hasil klasifikasi. Berdasarkan eksperimen yang dilakukan, arsitektur CNN₂ memperoleh nilai akurasi pada data pengujian sebesar 99.78% dengan jumlah layer = 3, hidden unit = [256,128,64] dan epoch = 200. Selain itu kemampuan arsitektur CNN₂ memiliki kemampuan generalisasi yang baik, hal ini dapat dilihat dari perbandingan nilai akurasi pada data pelatihan, validasi dan pengujian yang dilakukan pada eksperimen 1 dan 2 memiliki selisih yang kecil (*low variance*). Perbandingan dengan penelitian sebelumnya, CNN memiliki nilai akurasi yang lebih baik dibandingkan dengan metode yang diusulkan oleh (Bora dkk., 2017) dan (Muhamad dkk., 2018).

Pada rencana selanjutnya, arsitektur CNN yang lebih kompleks akan digunakan untuk melakukan klasifikasi terhadap tujuh jenis sel berbeda berdasarkan skema *transfer-learning*. Arsitektur CNN dengan skema *transfer-learning* yang akan digunakan meliputi RestNet, GoogleNet, Inception, AlexNet.

5. DAFTAR PUSTAKA

Ampazis, N., Dounias, G., & Jantzen, J. (2010). Pap-Smear Classification Using Efficient Second Order Neural Network Training Algorithms, 230–245. https://doi.org/10.1007/978-3-540-24674-9_25

Bora, K., Chowdhury, M., Mahanta, L. B., Kundu, M. K., & Das, A. K. (2017). Automated classification of Pap smear images to detect cervical dysplasia. *Computer Methods and Programs in Biomedicine*, 138, 31–47. <https://doi.org/10.1016/j.cmpb.2016.10.001>

Chankong, T., Theera-Umpon, N., & Auephanwiriyakul, S. (2014). Automatic cervical cell segmentation and classification in Pap smears. *Computer Methods and Programs in Biomedicine*, 113(2), 539–556. <https://doi.org/10.1016/j.cmpb.2013.12.012>

Devi, M. A., Ravi, S., Vaishnavi, J., & Punitha, S. (2016). Classification of Cervical Cancer Using Artificial Neural Networks. *Procedia Computer Science*, 89, 465–472. <https://doi.org/10.1016/j.procs.2016.06.105>

Haralick, R. M., & Shanmugam, K. (1973). Textural Features for Image Classification. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS*, SMC-3(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>

Jantzen, J., & Dounias, G. (2006). Analysis of Pap-Smear

Image Data. *Proceedings of the Nature-Inspired Smart Information Systems 2nd Annual Symposium*, 10.

Jantzen, J., Norup, J., Dounias, G., & Bjerregaard, B. (2005). Pap-smear Benchmark Data For Pattern Classification. *Proceedings of NiSIS 2005: Nature Inspired Smart Information Systems (NiSIS)*, 1–9.

Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proc. OF THE IEEE*. Retrieved from <http://ieeexplore.ieee.org/document/726791/#full-text-section>

Liu, N., & Kan, J. ming. (2016). Improved deep belief networks and multi-feature fusion for leaf identification. *Neurocomputing*, 216, 460–467. <https://doi.org/10.1016/j.neucom.2016.08.005>

Muhamad, F., Wasito, I., Mufidah, R., & Ghaisani, F. D. (2018). Multi feature fusion using deep belief network for automatic pap-smear cell image classification. *Proceedings - 2017 International Conference on Computer, Control, Informatics and Its Applications: Emerging Trends In Computational Science and Engineering, IC3INA 2017, 2018-Janua*, 18–22. <https://doi.org/10.1109/IC3INA.2017.8251733>

Zhou, X. (2018). Understanding the Convolutional Neural Networks with Gradient Descent and Backpropagation. *Journal of Physics: Conference Series*, 1004(1). <https://doi.org/10.1088/1742-6596/1004/1/012028>