

Klasifikasi Kanker Payudara Menggunakan *Residual Neural Network*

Reynold Erwandi ¹, Suyanto ²

School of Computing, Telkom University

Jl. Telekomunikasi Terusan Buah Batu, Bandung, West Java 40257, Indonesia

¹rewandi@student.telkomuniversity.ac.id, ²suyanto@telkomuniversity.ac.id

Abstract

Breast cancer is one of the most dangerous type of cancer, especially for women. In 2015, it became the deadliest cancer after lung cancer in America. Some studies found that both self-detection and prevention are important factors in dealing with this cancer. The process of diagnosing breast cancer traditionally takes a long time, moreover pathologists are not 100% sure of the results of their diagnosis. Therefore, in this study a computer-aided system is created to help doctors to classify cell types based on histopathological images. In this research, a method based on convolutional neural networks with Residual Neural Network (ResNet) architecture is proposed to distinguish histopathological images into some classes of breast cancers. Testing on the BreakHis dataset shows that the best performance of the proposed method gives average accuracies of 99.3% and 94.6% for binary and eight-class classifications, respectively. These results are comparable to state-of-the-art result in the recent study.

Keywords: classification, convolutional neural network, deep learning, medical image processing, Resnet

Abstrak

Kanker Payudara adalah salah satu jenis kanker yang paling berbahaya, terutama bagi wanita. Pada tahun 2015, kanker payudara menjadi kanker paling mematikan setelah kanker paru-paru di Amerika. Sejumlah studi menyatakan bahwa pendeteksi dan penanggulangan secara diri menjadi faktor penting dalam menghadapi kanker payudara. Proses diagnosa kanker payudara secara tradisional memakan waktu yang cukup lama, terlebih lagi para ahli patologi belum 100% yakin atas hasil diagnosa mereka. Oleh karena itu dalam penelitian ini dibuatlah sebuah sistem dengan bantuan komputer yang dapat membantu para dokter untuk mengklasifikasi jenis sel payudara berdasarkan gambar histopatologi. Pada penelitian ini, sebuah metode berbasis *deep convolutional neural network* dengan arsitektur *Residual Neural Network* (ResNet) diusulkan untuk pengklasifikasian berdasarkan gambar histopatologi ke dalam sejumlah kelas. Pengujian pada BreakHis dataset menunjukkan bahwa performa terbaik dari metode yang diusulkan mencapai rata-rata akurasi berturut-turut sebesar 99,3% dan 94,6% untuk klasifikasi dua kelas dan delapan kelas. Hasil ini setara dengan sejumlah penelitian terbaru saat ini.

Kata Kunci: klasifikasi, *convolutional neural network*, *deep learning*, pemrosesan gambar medis, *Resnet*

I. PENDAHULUAN

KANKER Payudara adalah jenis kanker yang paling banyak diderita didunia terutama pada kaum wanita. Berdasarkan *Centers for Disease Control and Prevention* (CDC), kanker payudara merupakan kanker yang memiliki jumlah kasus tertinggi dan menduduki nomor urut kedua dalam jenis kanker yang paling mematikan di Amerika Serikat pada tahun 2015[1]. Pendeteksian kanker payudara dapat dilakukan menggunakan berbagai metode seperti menggunakan *x-rays* untuk mengambil gambar *mammograms* dan pemindaian menggunakan *ultrasound*. Namun, metode yang paling efektif dalam mendeteksi adanya kanker yaitu dengan pemeriksaan jaringan tubuh (biopsi) dan melakukan analisis histopatologi[2]. Langkah pertama dalam melakukan pengobatan adalah pemeriksaan yang tepat. Pada kasus kanker payudara, pemeriksaan ini biasanya dilakukan dengan menggunakan gambar biomedik seperti *mammograms* dan histopatologi. Pemeriksaan secara manual seperti ini membutuhkan seorang ahli dan waktu yang relatif lama. Selain itu, para ahli pun masih ada kemungkinan membuat kesalahan dalam melakukan pemeriksaan gambar tersebut.

Saat ini sistem dengan bantuan komputer sudah banyak membantu manusia di berbagai bidang, contohnya dalam bidang kesehatan. Banyak penelitian dilakukan untuk proses pengklasifikasian kanker payudara seiring dengan berkembangnya *machine learning* dan *deep learning*. Sistem dengan bantuan komputer ini dapat membantu para ahli patologi dalam melakukan pemeriksaan dengan lebih konsisten dan produktif. Proses klasifikasi otomatis dengan menggunakan bantuan komputer pada gambar histopatologi ini dilakukan dengan menganalisa pola tertentu pada citra bergantung pada ada atau tidaknya sel yang menyebabkan kanker pada jaringan tubuh yang diperiksa. Proses analisis citra digital otomatis untuk pemeriksaan kanker telah menjadi topik riset selama lebih dari 40 tahun[3]. Namun, kebanyakan dari riset tersebut menggunakan *dataset* yang sangat kecil dan biasanya tidak tersedia secara umum. Hingga akhirnya *dataset* gambar histopatologi kanker payudara yang disebut *BreakHis database* diperkenalkan oleh Spanhol et al.[4]. *Dataset* tersebut mulai banyak digunakan pada riset-riset yang berkaitan dengan analisis kanker payudara pada tahun-tahun berikutnya dikarenakan *dataset* tersebut mengandung gambar histopatologi kanker payudara yang cukup. Untuk mendapatkan hasil yang akurat dan solusi yang terpercaya, diajukan metode dengan menggunakan teknik Convolutional Neural Network (CNN) yang diperkenalkan oleh LeCun et al.[5], yang mana telah banyak digunakan untuk menghasilkan hasil terbaik dalam beberapa permasalahan analisa pola citra digital. Model arsitektur yang diajukan menggunakan Residual Neural Network (ResNet) yang diperkenalkan oleh Kaiming He et al.[6] karena arsitektur ResNet telah terbukti menghasilkan salah satu *state-of-the-art* dalam melakukan proses pengklasifikasian citra digital pada ajang kompetisi ILSVRC15.

II. TINJAUAN PUSTAKA

Seiring dengan perkembangan teknologi, *machine learning* dan *deep learning* semakin populer dalam beberapa tahun terakhir ini. Hal ini menyebabkan kenaikan perhatian dan peningkatan dalam banyak aspek, salah satunya adalah *Computer Vision* (CV). CV atau dalam istilah Bahasa Indonesia yaitu penglihatan komputer, adalah bidang dalam ilmu komputer yang berupaya agar sebuah komputer dapat melihat, memproses dan mengidentifikasi sebuah citra layaknya mata manusia. Penelitian tentang pengklasifikasian kanker payudara-pun ikut meningkat dengan metode yang bermacam-macam contohnya mendeteksi berdasarkan bentuk dan tekstur[7] atau mendeteksi berdasarkan garis pada gambar *mammograms*[8].

A. Convolutional Neural Network

CNN diperkenalkan pertama kali oleh Kunihiko Fukushima pada 1980[9], namun belum populer seperti saat ini karena keterbatasan teknologi pada zaman itu. Lalu LeCun et al.[5][10] mengimprovisasinya pada tahun 1989 dan 1998 untuk membuat pengklasifikasian angka tulisan tangan. Keunggulan CNN dalam mendapatkan performa yang baik tanpa harus menentukan sebuah fitur membuatnya populer. Hingga saat ini CNN telah banyak digunakan untuk mendapatkan hasil yang signifikan dalam permasalahan CV[11]. Dalam pengklasifikasian kanker payudara, Spanhol et al. [12] menggunakan pendekatan CNN dengan arsitektur

AlexNet pada *dataset BreakHis* yang diusulkannya menghasilkan tingkat akurasi rata-rata 79,85%. Han et al. [13] menggunakan *Class structure-based deep convolutional neural network* (CSDCNN) yang diusulkannya menghasilkan tingkat akurasi rata-rata 93,2%. Kemudian Nawaz et al.[14] menggunakan pendekatan CNN dengan arsitektur *DenseNet* berhasil menghasilkan tingkat akurasi rata-rata 95,4% yang mana menjadi *state-of-the-art* saat penelitian ini ditulis.

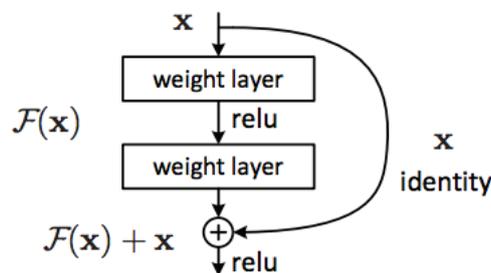
B. Transfer Learning

Transfer Learning (TL) adalah teknik untuk menggunakan bobot model yang telah dilatih menggunakan *dataset* yang sangat besar (biasanya menggunakan *ImageNet*) lalu nantinya akan diadaptasikan dengan *dataset* yang akan digunakan. Teknik ini sangat populer dalam pendekatan berbasis CNN sebagai langkah awal dalam memulai proses pengklasifikasian dikarenakan melatih jaringan dari awal bukanlah sebuah ide yang baik dilihat dari sisi komputasional yang cukup berat dan waktu yang cukup lama untuk mendapatkan bobot jaringan yang mendekati optimal. Penelitian ini menggunakan TL pada model yang telah dilatih sebelumnya menggunakan gambar *ImageNet* dan nantinya akan dimodifikasi untuk dapat mengklasifikasikan gambar histopatologi untuk kanker payudara.

C. Residual Neural Network

Residual Neural Network (ResNet) adalah teknik yang dikembangkan oleh Microsoft pada tahun 2015. Teknik ini mengizinkan *neural network* yang lebih dalam dapat tetap dilatih secara efektif. Hal ini dibuktikan pada kompetisi ImageNet 2015 yang mana ResNet yang berhasil menempati juara-1[6].

Dalam arsitektur *neural network* biasa, saat kedalaman jaringan terlalu banyak akurasi yang didapat akan mulai menurun dan akan berujung pada tingkat *error* yang lebih tinggi[6]. ResNet berhasil memecahkan permasalahan tersebut dengan menambahkan sebuah cara untuk melompat atau melewati sejumlah layer yang dinamakan *Residual Learning* seperti pada Gambar 1[6]. Cara ini berhasil menghilangkan permasalahan *Vanishing Gradient Problem* yang banyak terjadi pada *neural network* biasa.



Gambar 1. *Residual Learning Block*

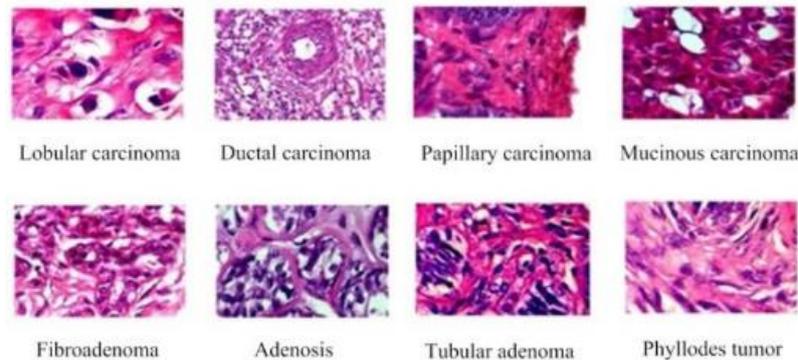
Pada penelitian ini dilakukan sedikit perubahan pada arsitektur ResNet untuk dapat mengklasifikasi berdasarkan gambar histopatologi. Arsitektur ini menggunakan ukuran kernel 7x7 pada layer konvolusi pertama agar dapat mendeteksi detail dan fitur penting pada gambar histopatologi. Lalu dengan penggunaan metode *transfer learning*, *softmax layer* yang digunakan untuk menentukan *class* hasil pengklasifikasian dimodifikasi dari yang sebelumnya berjumlah 1000 *class* (total class ImageNet) menjadi 2 *class* untuk eksperimen *binary class* dan 8 *class* untuk eksperimen *multi class*.

III. METODE PENELITIAN

A. Dataset

Penelitian ini menggunakan *dataset BreakHis* yang diusulkan oleh Spanhol et al.[4]. *BreakHis* adalah *dataset* yang cukup besar yang terdiri dari 7909 gambar. Sumber data ini didapatkan dari 82 pasien pada Lab *Pathological Anatomy and Cytopathology* (P&D) di Brazil[4]. *BreakHis* dibagi berdasarkan 2 *class* utama

(*benign & malignant*) yang masing-masing memiliki 4 *subclass* yang dapat dilihat contohnya pada Gambar 2[14]. *Ductal carcinoma* (DC), *Lobular carcinoma* (LC), *Mucinous carcinoma* (MC), dan *Papillary carcinoma* (PC) pada *class malignant*. *Adenosis* (A), *Fibroadenoma* (F), *Phyllodes tumor* (PT), dan *Tubular adenoma* (TA) pada *class benign*. Setiap *class* terdiri dari 4 faktor pembesaran: 40X, 100X, 200X, dan 400X. Masing-masing gambar memiliki 3 *channel RGB* dan berukuran 700x460 *pixels*.



Gambar 2. Contoh Gambar Histopatologi pada *Subclass Dataset BreakHis*

B. Pendekatan

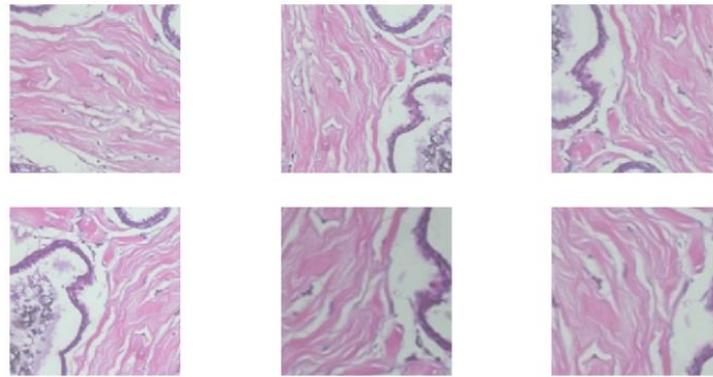
Dalam metode CNN umumnya semakin banyak layer yang digunakan maka akurasi semakin meningkat. Namun, hal tersebut memiliki permasalahan yang disebut *Vanishing Gradient Problem* (VGP). VGP adalah suatu permasalahan yang terjadi dalam *neural network* yang berbasis pembelajaran menggunakan gradien apabila arsitektur jaringan memiliki jumlah layer yang terlalu banyak sehingga menyebabkan hasil gradien yang dihasilkan mendekati nol sehingga perubahan bobot sangat kecil sekali layaknya mesin tidak belajar apapun. Pada penelitian ini diusulkan sistem menggunakan model ResNet yang berhasil menjadi solusi efektif untuk permasalahan VGP [6].

Pada penelitian ini model ResNet akan digunakan dan dimodifikasi untuk keperluan pengklasifikasian gambar histopatologi. Bobot pada *layer* akan diinisialisasi dengan menggunakan model yang sudah dilatih sebelumnya pada gambar *ImageNet*. Layer tersebut akan di *freeze* kecuali layer terakhir untuk diadaptasikan pada *class* yang ada di *dataset BreakHis*. Lalu, layer akan di *unfreeze* sehingga kemudian seluruh jaringan dapat di *training* lebih baik terhadap *dataset BreakHis*. Teknik ini dilakukan untuk mengurangi tingkat kompleksitas dalam proses *training* dan menghindari permasalahan *over fitting*.

C. Data Pre-processing dan Augmentasi Data

Untuk mendapatkan hasil yang terpercaya, penelitian dimulai dengan membagi *dataset* kedalam 3 grup: *data training* (64%), *data validasi* (16%), *data test* (20%). *Data training* digunakan untuk proses training model *ResNet*, *data validasi* digunakan untuk menyesuaikan hyperparameter dan *data test* untuk mengevaluasi performa tanpa bias. Sebelum proses *training* dimulai, dilakukan teknik *Transfer Learning*. Penelitian ini menggunakan bobot model *ResNet50* yang telah dilatih pada *dataset ImageNet* sebelumnya.

Augmentasi data dilakukan untuk meningkatkan jumlah dan variasi dari data yang tersedia dengan melakukan sedikit perubahan. Pada penelitian ini digunakan beberapa teknik augmentasi, yaitu: perubahan kemiringan, perubahan tingkat pembesaran, putar balik gambar secara horizontal dan vertikal, serta perubahan tingkat intensitas pencahayaan, seperti diilustrasikan pada Gambar 3.

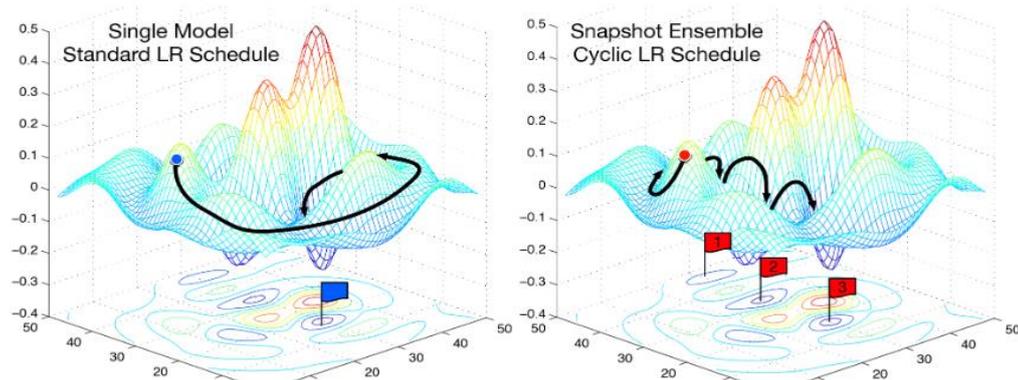


Gambar 3. Contoh Hasil Augmentasi Data

D. Proses Training

Hal pertama dalam proses *training* penelitian ini adalah mencari *learning rate* (LR) yang optimal dengan menggunakan teknik *cyclical learning rate* (CLR) yang diusulkan oleh Smith et al.[15]. CLR melakukan eksplorasi pada sejumlah LR tertentu dan menghitung *loss* pada LR tersebut sehingga dapat ditentukan LR yang dapat digunakan untuk mendapatkan *loss* yang optimal. Berdasarkan hasil dari CLR yang didapat, proses *training* pada penelitian ini dilanjutkan dengan menggunakan LR $10e-2$ karena terlihat *loss* masih dapat berkurang.

Setelah itu proses *training* dimulai dengan menggunakan *optimizer Stochastic Gradient Descent with Restart* (SGDR) yang diusulkan oleh Huang et al.[16]. Mirip seperti SGD, namun pada SGDR terdapat istilah *restart* dimana LR akan di *reset* kembali ke nilai awal setelah melakukan sejumlah epoch tertentu. Perbedaan ini dapat diamati pada Gambar 4[16]. Pada grafik sebelah kiri adalah proses optimasi menggunakan SGD dimana pencarian solusi akan terus menuju ke titik lebih rendah selanjutnya dengan melakukan perhitungan gradien. Pada grafik sebelah kanan adalah proses optimasi menggunakan SGDR dimana pencarian solusi akan terus menuju ke titik lebih rendah selanjutnya dengan melakukan perhitungan gradien, namun ada beberapa lompatan yang ditandai dengan anak panah yang melompat. Lompatan ini terjadi saat proses *restart* atau mengembalikan LR ke nilai awal sehingga menyebabkan terjadinya perubahan yang cukup drastis. Hal ini memungkinkan bobot jaringan untuk menghindari terperangkap pada *local minima* dan menemukan solusi yang lebih optimal dengan meningkatkan tingkat konvergensi pada *neural network* yang berbasis pembelajaran menggunakan gradien.



Gambar 4. Visualisasi Perbandingan SGD dengan SGDR

Dalam pembuatan model, penelitian ini menggunakan *framework* FastAI dan berbasis PyTorch. Model ini dilatih dan diuji menggunakan perangkat *desktop* dengan prosesor i5 dan GPU NVIDIA GTX1070ti sebanyak 450 *epochs* atau selama 10 jam untuk tiap eksperimen.

E. Evaluasi

Pada penelitian ini dilakukan 2 eksperimen yaitu, pertama eksperimen pengklasifikasian *binary class*. Lalu eksperimen pengklasifikasian *multi-class* sebanyak 8 *class*. Hasil performa dari sistem yang dibuat dievaluasi berdasarkan akurasinya pada tingkat *image-level* dengan rumus seperti pada (1).

$$Akurasi = \frac{T}{N} \quad (1)$$

Dimana T adalah jumlah gambar yang terklasifikasi dengan benar dan N adalah jumlah seluruh gambar yang dicoba untuk diklasifikasikan.

IV. HASIL DAN DISKUSI

Setelah berhasil melakukan *training* pada model yang dibuat, proses testing dilakukan dengan menggunakan data test yang telah dibuat saat *pre-processing* data. Akurasi pada model ini dihitung pada 4 kategori yang berbeda berdasarkan faktor pembesaran pada *dataset BreakHis*. Untuk mengevaluasi performa yang didapatkan, dilakukan perbandingan antara model yang diusulkan dengan model lain yang didapatkan pada penelitian tentang pengklasifikasian kanker payudara pada *dataset BreakHis*.

Pada TABEL I untuk pengklasifikasian kanker payudara *binary class* yang menggunakan dataset *BreakHis* Spanhol et al[12] dengan metode AlexNet berhasil mencapai tingkat akurasi tertinggi sebesar 90,4% pada tingkat pembesaran 40x. Dimitropoulos et al[17] dengan metode *Vector of Locally Aggregated Descriptors* (VLAD) berhasil mencapai tingkat akurasi tertinggi sebesar 92,1% pada tingkat pembesaran 100x. Han et al[13] dengan metode CSDCNN berhasil mencapai tingkat akurasi tertinggi sebesar 96,9% pada tingkat pembesaran 100x. Metode ResNet yang diusulkan pada penelitian ini berhasil mencapai tingkat akurasi terbaik sebesar 100% pada tingkat pembesaran 200x.

Pada TABEL II untuk pengklasifikasian kanker payudara *multi class* yang menggunakan dataset *BreakHis* Spanhol et al[12] dengan metode AlexNet berhasil mencapai tingkat akurasi tertinggi sebesar 86,4% pada tingkat pembesaran 40x. Han et al[13] dengan metode CSDCNN berhasil mencapai tingkat akurasi tertinggi sebesar 93,9% pada tingkat pembesaran 100x. Nawaz et al[14] dengan metode DenseNet berhasil mencapai tingkat akurasi tertinggi sebesar 97,42% pada tingkat pembesaran 100x. Metode ResNet yang diusulkan pada penelitian ini berhasil mencapai tingkat akurasi tertinggi sebesar 95,72% pada tingkat pembesaran 200x.

Berdasarkan hasil perbandingan pada kedua tabel dapat disimpulkan bahwa ResNet yang diusulkan pada penelitian ini menghasilkan performa tertinggi dengan rata-rata akurasi 99,3% pada klasifikasi *binary class* dan hampir menyamai performa model *state-of-the art* pada klasifikasi *multi-class* saat ini yang menggunakan arsitektur DenseNet[14] dengan perbedaan dibawah 1%. Metode yang diusulkan dalam penelitian ini mendapatkan hasil terbaik pada tingkat pembesaran 200x pada dataset *BreakHis*. Hasil model dalam penelitian ini juga mampu melebihi hasil dengan metode VLAD[17] dan CSDCNN[13] yang sama sama menggunakan pendekatan CNN baik dalam klasifikasi *binary class* maupun *multi-class*.

TABEL I
PERBANDINGAN PERFORMA DENGAN METODE LAIN DALAM KLASIFIKASI KANKER PAYUDARA *BINARY CLASS*

Model	Magnification Factors				
	40x	100x	200x	400x	average
AlexNet[12]	90,40	87,40	85,00	83,00	86.45
VLAD[17]	91,80	92,10	91,40	90,20	91.37
CSDCNN[13]	95,80	96,90	96,70	94,90	96.07
ResNet (Yang diusulkan)	99,35	99,16	100	98,67	99.30

TABEL II
PERBANDINGAN PERFORMA DENGAN METODE LAIN DALAM KLASIFIKASI KANKER PAYUDARA *MULTI CLASS*

Model	Magnification Factors				
	40x	100x	200x	400x	average
AlexNet[12]	86.4	75.8	72.6	84.6	79.85
CSDCNN[13]	92.8	93.9	93.4	92.9	93.25
DenseNet[14]	93.64	97.42	95.87	94.67	95.40
ResNet (Yang diusulkan)	95.53	92.92	95.72	94.90	94.60

V. KESIMPULAN

Model untuk pengklasifikasian kanker payudara baik dalam *binary class* dan *multi-class* telah sukses diimplementasikan. Pengujian menggunakan *dataset* BreakHis menunjukkan bahwa model yang diusulkan dapat menghasilkan akurasi rata-rata hingga 99,3% dan bersaing dengan *state-of-the-art* saat ini pada pengklasifikasian *multi-class* dengan tingkat akurasi rata-rata sebesar 94,6%. Model ini dapat ditingkatkan menggunakan arsitektur yang lebih kuat, pengatur *hyper-parameter* yang lebih baik dan penggunaan *dataset* yang lebih besar. Hasil dari penelitian ini sangat baik dalam mendeteksi dan mengklasifikasikan tumor pada gambar histopatologi, yang bermanfaat bagi dokter dalam proses diagnosis kanker payudara.

PERNYATAAN

Kami mengucapkan terimakasih kepada orang tua, seluruh kolega di Universitas Telkom, khususnya di Fakultas Informatika, atas segala dukungannya dalam penyelesaian penulisan makalah ini.

REFERENSI

- [1] "USCS Data Visualizations." [Online]. Available: <https://gis.cdc.gov/Cancer/USCS/DataViz.html>. [Accessed: 19-Mar-2019].
- [2] et al Ellis IO, "Pathology and Genetic of Tumours of the Breast and Female Genital Organs, WHO Classification of Tumours," *Invasive breast carcinoma*, pp. 18–19, 23–43, 2003.
- [3] Kunihiko Fukushima, "Computerized Nuclear Morphometry as an Objective Method for Characterizing Human Cancer Cell Populations," *Cancer Res.*, vol. 38, no. 12, pp. 4688–4697, 1978.
- [4] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, "A Dataset for Breast Cancer Histopathological Image Classification," *IEEE Trans. Biomed. Eng.*, vol. 63, no. 7, pp. 1455–1462, 2016.
- [5] L. D. Jackel *et al.*, "Backpropagation Applied to Handwritten Zip Code Recognition," *Neural Computation*, vol. 1, no. 4, pp. 541–551, 1989.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2015.
- [7] F. Narvaez, G. Díaz, and E. Romero, "Multi-view information fusion for automatic BI-RADS description of mammographic masses," *Med. Imaging 2011 Comput. Diagnosis*, vol. 7963, no. 1, p. 79630A, 2011.
- [8] F. Moayed, Z. Azimifar, R. Boostani, and S. Katebi, "Contourlet-based mammography mass classification using the SVM family," *Comput. Biol. Med.*, vol. 40, no. 4, pp. 373–383, 2010.

- [9] Kunihiro Fukushima, "Neocognitron: A Self-organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position Kunihiro," *Nature*, vol. 237, no. 5349, pp. 55–56, 1980.
- [10] P. H. YANN LECUN, LEON BOTTOU, YOSHUA BENGIO, "Gradient-Based Learning Applied to Document Recognition," *Biochem. Biophys. Res. Commun.*, vol. 330, no. 4, pp. 1299–305, 1998.
- [11] G. E. H. Alex Krizhevsky, Ilya Sutskever, "ImageNet Classification with Deep Convolutional Neural Networks," *2018 9th IFIP Int. Conf. New Technol. Mobil. Secur. NTMS 2018 - Proc.*, vol. 2018-Janua, no. February, pp. 1–5, 2018.
- [12] F. A. Spanhol, L. S. Oliveira, C. Petitjean, and L. Heutte, "Breast cancer histopathological image classification using Convolutional Neural Networks," *Proc. Int. Jt. Conf. Neural Networks*, vol. 2016-Octob, pp. 2560–2567, 2016.
- [13] Z. Han, B. Wei, Y. Zheng, Y. Yin, K. Li, and S. Li, "Breast Cancer Multi-classification from Histopathological Images with Structured Deep Learning Model," *Sci. Rep.*, vol. 7, no. 1, p. 4172, Dec. 2017.
- [14] M. Nawaz, A. A., and T. Hassan, "Multi-Class Breast Cancer Classification using Deep Learning Convolutional Neural Network," *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 6, pp. 316–322, 2018.
- [15] L. N. Smith, "Cyclical learning rates for training neural networks," *Proc. - 2017 IEEE Winter Conf. Appl. Comput. Vision, WACV 2017*, no. April, pp. 464–472, 2017.
- [16] G. Huang, Y. Li, G. Pleiss, Z. Liu, J. E. Hopcroft, and K. Q. Weinberger, "Snapshot Ensembles: Train 1, get M for free," pp. 1–14, 2017.
- [17] K. Dimitropoulos, P. Barmoutis, C. Zioga, A. Kamas, K. Patsiaoura, and N. Grammalidis, "Grading of invasive breast carcinoma through Grassmannian VLAD encoding," *PLoS One*, vol. 12, no. 9, pp. 1–18, 2017.