

KLASIFIKASI KANKER PAYUDARA BERBASIS CITRA ULTRASOUND MENGGUNAKAN METODE TRANSFER LEARNING CNN

¹Putri Anna Diah Irawati, ²Fajar Astusti Hermawati

Teknik Informatika, Universitas 17 Agustus 1945 Surabaya
Jl. Semolowaru No. 45, Menur Pumpungan, Kec. Sukolilo, Surabaya

¹putrianna.di@gmail.com

²fajarastuti@untag-sby.ac.id

Abstract

Breast cancer is a deadly cancer that most often affects women. According to an article released by the World Health Organization, (2021) nearly 2.3 million women were diagnosed with breast cancer with 685 thousand deaths. Patients who have symptoms of breast cancer or feel an abnormality in the breast will need to undergo tests including breast imaging and in some cases tissue sampling (biopsy). There are many imaging techniques for breast cancer, and breast ultrasound is one of them, which can provide quite useful and comprehensive information. The use of deep learning to classify types of breast cancer is also widely carried out and transfer learning methods are quite popular in the classification of the medical field. In this study, a desktop-based application is created for the classification of breast cancer types into malignant, benign, and normal classes using transfer learning methods from the pretrained Alexnet network. The experiment was carried out eight times with a combination of three variables, namely the image preprocessing method, the training data distribution method, and the classification method. Evaluation is done by analyzing the confusion matrix and paying attention to the accuracy values, Positive Predictive Value (PPV), and True Positive Rate (TPR). The conclusions obtained from these eight experiments, obtained the best combination of variables for learning, namely by preprocessing the dataset, distributing the dataset using K-fold, and classification using Fully connected layer. After the model is implemented into the application, the overall average evaluation results for PPV = 92.3%, TPR = 86.7%, and Accuracy = 90%.

Keywords: Transfer Learning, Breast Cancer, Alexnet

Abstrak

Kanker payudara adalah kanker mematikan yang paling sering menyerang perempuan. Menurut artikel yang dirilis oleh World Health Organization, (2021) hampir 2.3 juta wanita didiagnosis mengidap kanker payudara dengan 685 ribu meninggal dunia. Pasien yang mendapati gejala kanker payudara atau merasakan ketidaknormalan pada payudara, perlu menjalani tes di antaranya pencitraan payudara dan dalam beberapa kasus pengambilan sampel jaringan (biopsi). Ada banyak teknik pengambilan citra untuk kanker payudara, dan salah satunya teknik ultrasound payudara, dapat memberikan informasi yang cukup berguna dan komprehensif. Pemanfaatan deep learning untuk melakukan klasifikasi jenis kanker payudara juga banyak dilakukan dan metode transfer learning cukup populer dalam klasifikasi bidang medis. Pada penelitian ini, dibuat aplikasi berbasis desktop untuk klasifikasi jenis kanker payudara dengan kelas ganas, jinak, dan normal menggunakan metode transfer learning dari jaringan pretrained Alexnet. Percobaan dilakukan dengan kombinasi tiga variabel penelitian yakni metode preproses citra, metode distribusi data latih, dan metode klasifikasi. Evaluasi dilakukan dengan menganalisis confusion matrix dan memperhatikan nilai akurasi, Positive Predictive Value (PPV), dan True Positive Rate (TPR). Kesimpulan yang didapat dari kedelapan percobaan ini, didapat kombinasi variabel terbaik untuk pembelajaran yakni dengan preproses dataset, distribusi dataset menggunakan K-fold, dan klasifikasi menggunakan Fully connected layer. Setelah model diimplementasikan ke aplikasi, secara keseluruhan hasil evaluasi rata-rata untuk PPV = 92,3%, TPR = 86,7%, dan Akurasi = 90%.

Kata Kunci: Transfer Learning, Kanker Payudara, Alexnet

1. PENDAHULUAN

Kanker payudara adalah kanker mematikan yang paling sering menyerang perempuan. Kanker payudara terjadi akibat dari sel-sel pada jaringan payudara berubah dan membelah tidak terkendali, hingga mengakibatkan benjolan [1]. Menurut artikel yang dirilis oleh World Health Organization, (2021) hampir 2.3 juta wanita didiagnosis mengidap kanker payudara dengan 685 ribu meninggal dunia. Namun benjolan yang terdapat di payudara tidak semuanya dikategorikan sebagai kanker ganas. Sementara itu kanker ganas adalah jenis kanker berbahaya yang perkembangannya selnya tidak terkendali. Oleh sebab itu pasien yang mendapati gejala kanker payudara atau merasakan ketidaknormalan pada payudara, perlu menjalani tes di antaranya pencitraan payudara dan dalam beberapa kasus pengambilan sampel jaringan (biopsi). Pengujian tersebut dimaksudkan untuk menentukan jenis kanker; apakah termasuk kanker ganas atau kanker jinak agar dapat segera ditangani dengan tepat. Untuk deteksi dan diagnosis kanker payudara, teknik *ultrasound* payudara memberikan informasi yang cukup baik dan komprehensif, dengan tangkapan citra meliputi kelenjar getah bening di aksila, antara otot dada dan di daerah subklavia, leher dan rantai toraks [3].

Pemanfaatan *deep learning* untuk melakukan klasifikasi jenis kanker payudara juga banyak dilakukan. Di antaranya adalah penelitian yang dilakukan oleh Shia, Lin dan Chen, (2021) yang melakukan klasifikasi tumor ganas pada citra *ultrasound* payudara dengan pendekatan *unsupervised machine learning*. Latif *et al.*, (2020) menggunakan *Deep Convolutional Neural Network* (CNN) untuk menghilangkan *noise* sekaligus melakukan klasifikasi kanker ganas dan jinak. Zhang *et al.*, (2021) melakukan evaluasi akurasi dari model *deep learning* untuk diagnosis kanker payudara dan subtipe molekular.

Metode transfer learning adalah salah satu pendekatan *deep learning* yang paling populer dalam klasifikasi bidang medis. Metode ini menggunakan kembali model *deep learning* terdahulu atau *pretrained network*, dan menggubahnya untuk pembelajaran baru. Model CNN yang sering dipakai dalam melakukan klasifikasi kanker payudara adalah Alexnet, VGGNet dan Inception [7].

Pada penelitian ini, dibuat aplikasi berbasis *desktop* untuk klasifikasi jenis

kanker payudara dengan kelas ganas, jinak, dan normal menggunakan metode *transfer learning* dari jaringan *pretrained* Alexnet. Percobaan dilakukan dengan kombinasi tiga variabel penelitian yakni metode preproses citra, metode distribusi data latih, dan metode klasifikasi. Evaluasi dilakukan dengan menganalisis *confusion matrix* dan memperhatikan nilai akurasi, *Positive Predictive Value* (PPV), dan *True Positive Rate* (TPR).

2. METODE PENELITIAN

Pada bagian ini akan dibahas mengenai metode-metode dan teori yang menjadi dasar dalam pelaksanaan penelitian.

2.1. Kajian Pustaka

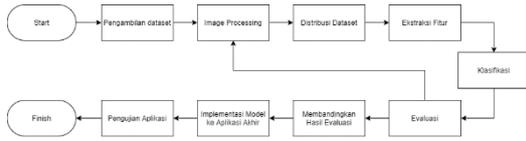
Dalam penelitian yang dilakukan Shia, Lin dan Chen, (2021), klasifikasi tumor ganas pada citra *ultrasound* payudara dilakukan dengan diekstraksi fitur dengan deskriptor *Pyramid Histogram of Oriented Gradients* (PHOG). Kemudian diklasifikasi dengan kombinasi antara *Locally Weighted Learning* (LWL) dan *Sequential Minimal Optimisation* (SMO). Metode *K-Nearest Neighborhood* (KNN) digunakan sebagai fungsi pembobotan sebagai fungsi *kernel* dalam LWL. Hasil dari penelitian ini adalah didapat model dengan tingkat sensitivitas 81.64% dan spesifisitas 87.76%.

Latif *et al.*, (2020) menggunakan *Deep Convolutional Neural Network* (CNN) untuk menghilangkan *noise* sekaligus melakukan klasifikasi kanker ganas dan jinak. Dari hasil penelitian ini, didapatkan model CNN dengan akurasi klasifikasi kanker ganas dan jinak sebesar 88%.

Zhang *et al.*, (2021) melakukan evaluasi akurasi dari model *deep learning* untuk diagnosis kanker payudara dan subtipe molekular. *Deep learning Model* (DLM) yang dioptimalkan dibuat dari set data pelatihan, kemudian kinerjanya diverifikasi dengan set pengujian dan set pengujian eksternal. Hasil dari pengujian menggunakan DLM mendapatkan hasil akurasi, sensitivitas, dan spesifisitas masing-masing 89.7%, 91.3%, dan 86.9%.

2.2. Tahapan Penelitian

Dalam penelitian ini akan dilakukan delapan kali percobaan dengan kombinasi tiga variabel. Variabel tersebut antara lain metode image preprocessing, metode distribusi kelas dan metode klasifikasi.

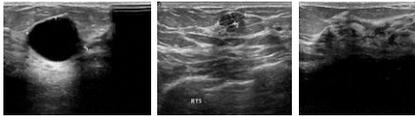


Gambar 1 Diagram Alur Penelitian

Berikut adalah penjabaran setiap tahap dari Flowchart Alur Penelitian Klasifikasi Kanker Payudara.

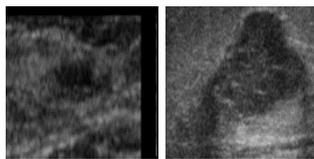
2.2.1. Pengambilan Dataset

Data gambar yang digunakan dalam penelitian ini ada dua, yang pertama adalah *dataset* citra *ultrasound* payudara yang dikumpulkan oleh Al-Dhabyani *et al.*, (2020) pada tahun 2018. *Dataset* terdiri dari 780 gambar *ultrasound* dengan spesifikasi; rata-rata berukuran 500 x 500 piksel, bertipe PNG, dan dikelompokkan ke dalam tiga kelas (*benign*, *malignant*, dan *normal*).



Gambar 2 Citra Ultrasound Payudara Kelas Benign, Malignant, dan Normal

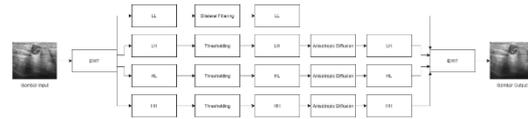
Dataset kedua yang dipakai dalam penelitian ini adalah *dataset* citra kanker payudara dari Mendeley Data. *Dataset* tersebut dikumpulkan oleh Rodrigues, (2018) yang berjumlah 250 *dataset* citra, terdiri dari 100 citra *benign* dan 150 citra *malignant*. Spesifikasi gambar berjenis bmp dengan ukuran rata-rata 75x95 piksel.



Gambar 3 Citra Ultrasound Payudara Kelas Benign dan Malignant

2.2.2. Metode Image Preprocessing

Preprocessing citra dilakukan dengan menggunakan metode *hybrid* untuk mengurangi *noise* bintik pada citra *ultrasound*. Metode ini diusulkan oleh Hermawati, Tjandrasa and Suciati, (2018). Metode ini menggabungkan metode *decomposition wavelet* dengan *bilateral filtering*.



Gambar 4 Alur Preprocessing Citra

Langkah awal, citra input akan didekomposisi dengan *Discrete Wavelet Transform* (DWT) yang menghasilkan *subband* perkiraan citra asli (LL) dan tiga *subband* yang menyajikan tiga informasi detail; yakni vertikal (LH), horizontal (HL), dan diagonal (HH). Fungsi *wavelet* yang digunakan adalah fungsi Daubechies 'db8.' *Subband* perkiraan akan difilter menggunakan fungsi *bilateral* menurut *Persamaan 1*. Fungsi *bilateral* adalah fungsi nonlinier yang dapat menghilangkan *noise* sekaligus tetap mempertahankan tepian gambar.

Persamaan 1 *Bilateral Filtering*

$$I(P) = \frac{1}{C} \sum_{q \in N(P)} (G_{\sigma_d}(\|q - p\|) \cdot G_{\sigma_r}(\|I(q) - I(P)\|)) \cdot I(q) \quad (1)$$

Dengan:

$I(P)$ = Citra input

$N(P)$ = *Window* lokal yang berpusat di piksel P

$q \in N$ = Piksel selain P yang ada di *window* N

$G_{\sigma_d}()$ = Fungsi Gaussian

σ_d = Standar deviasi

C = Konstan untuk menormalisasi fungsi sehingga jumlah bobot tetap 1

Sementara itu *subband* detail dihitung *threshold*-nya menggunakan *Persamaan 2* dengan ketentuan seperti *Persamaan 3*.

Persamaan 2 *Thresholding*

$$T = \frac{\|median(w_i)\|}{0,6745} \quad (2)$$

Persamaan 3 *Soft Tresholding*

$$w'_i = \begin{cases} 0, & \text{jika } |w_i| < T \\ w_i - T, & \text{jika } w_i > T \\ w_i + T, & \text{jika } w_i \leq -T \end{cases} \quad (3)$$

Dengan:

T = Nilai *threshold*

w_i = koefisien diagonal wavelet level dekomposisi ke- i

Kemudian hasil dari *thresholding* akan difilter menggunakan *Anisotropic Dsiffusion Filter* menurut *Persamaan 4*.

Persamaan 4 *Anisotropic Diffusion*

$$C(x, y, z, t) = \frac{1}{(1 + (\frac{\nabla f(i, j)}{k})^2)} \quad (4)$$

Dengan:

- $f(i, j)$ = Fungsi gambar asli
- (i, j) = Koordinat
- $C(x, y, z, t)$ = koefisien difusi horizontal, vertikal, dan diagonal pada iterasi ke- t
- K = Gradien threshold

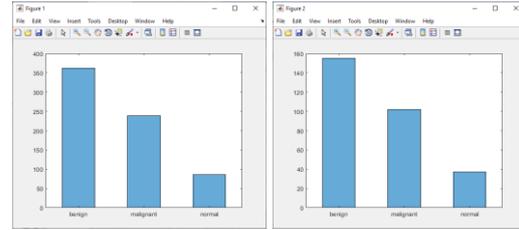
Setelah seluruh proses selesai, dilakukan *Inverse Discrete Wavelet Transform* (IDWT) sehingga menjadi gambar perkiraan. Hasil dari proses ini akan menjadi input dalam proses yang sama sebanyak jumlah level yang didefinisikan.

Pada penelitian ini, fungsi dekomposisi wavelet yang digunakan adalah wavelet Daubechies 8 'db8' dengan level dekomposisi sebanyak tiga kali. Sedangkan nilai parameter yang dipakai dalam melakukan preproses citra dalam penelitian ini adalah sebagai berikut; untuk fungsi bilateral filtering parameter yang didefinisikan adalah standar deviasi d dengan nilai 0.8 dan ukuran window sebesar 5x5. Sedangkan untuk fungsi SRAD, parameter yang didefinisikan adalah jumlah perulangan turunan sebanyak 50, gradien threshold 3, nilai lambda/integral konstan 0.1.

2.2.3. Metode Distribusi Dataset

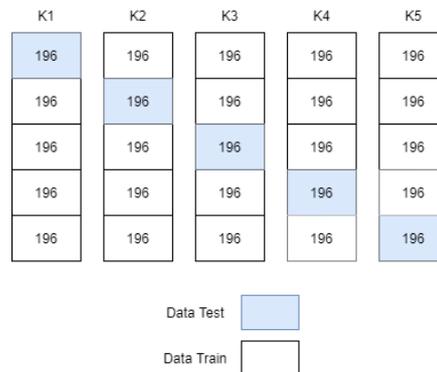
Pada tahap distribusi *dataset*, variabel yang akan diuji adalah variabel metode distribusi dengan nilai variabel yang akan dibandingkan adalah distribusi dengan 7:3 dan distribusi dengan *K-fold Cross Validation*.

Distribusi *dataset* rasio 7:3 adalah distribusi *dataset* yang memisahkan data train dan data test sesuai dengan rasio. Dalam penelitian ini, data train akan diambil sebanyak 70% dari seluruh jumlah *dataset*, sementara data test diambil sebanyak 30% dari seluruh jumlah *dataset*.



Gambar 5 Sebaran Kelas data train (kiri) dan test (kanan)

Sementara distribusi *dataset* dengan *K-fold Cross Validation* adalah teknik distribusi data yang dilakukan dengan membagi data sebanyak k . Pembelajaran jaringan juga akan dilakukan sebanyak k . Pada teknik distribusi ini, set data test akan dipilih berbeda setiap pembelajaran.



Gambar 6 Ilustrasi Pengelompokan Data

2.2.4. Ekstraksi Fitur

Pada tahap ekstraksi fitur, digunakan model pretrained Alexnet yang akan di-transfer learning dengan citra ultrasound untuk melakukan ekstraksi fitur. Arsitektur Alexnet terdiri dari 8 *layer*, dengan input berukuran 227x227x3. *Layer* pertama adalah convolutional layers, dan *layer* berikutnya adalah max-pooling untuk menyusutkan dimensi data. Alexnet menggunakan fungsi aktivasi ReLU. Tiga *layer* terakhir adalah fully connected layer dengan fungsi aktivasi terakhir Softmax. Urutan *layer* dalam Alexnet adalah convolution – max pooling – convolution – max pooling – convolution – convolution – max pooling – fully connected – fully connected – fully connected. Kernel konvolusi pertama dan kedua berukuran 11x11 dan 5x5, kemudian tiga *layer* konvolusi terakhir adalah 3x3.

Tabel 1 Dimensi dan Detail dari Arsitektur Alexnet

	Layer	Feature Map	Size	Kernel Size	Stride	Activation
Input	Image	1	227x227x3	-	-	-
1	Convolution	96	55x55x96	11x11	4	Relu
	Max Pooling	96	27x27x96	3x3	2	Relu
2	Convolution	256	27x27x256	5x5	1	Relu
	Max Pooling	256	13x13x256	3x3	2	Relu
3	Convolution	384	13x13x384	3x3	1	Relu
4	Convolution	384	13x13x384	3x3	1	Relu
5	Convolution	256	13x13x256	3x3	1	Relu
	Max Pooling	256	6x6x256	3x3	2	Relu
6	FC	-	4096	-	-	Relu
7	FC	-	4096	-	-	Relu
Output	FC	-	1000	-	-	Softmax

2.2.5. Metode Klasifikasi

Pada tahap klasifikasi, akan ada variabel metode klasifikasi yang diuji. Variabel tersebut antara lain bernilai klasifikasi dengan *Fully connected layer* bawaan dari *pretrained* Alexnet dan klasifikasi dengan SVM yang akan diberi input ekstraksi fitur jaringan Alexnet. Kedua nilai variabel tersebut akan dibandingkan.

Fully connected layer bawaan dari *pretrained* Alexnet atau *neural network* adalah jaringan saraf tiruan yang dibuat berdasarkan oleh jaringan saraf biologis. Cara kerjanya adalah dengan mengkalikan nilai input dengan nilai bobot yang telah didefinisikan. Kemudian, hasil dari perkalian akan diaktifkan menggunakan fungsi aktivasi. Pada model seperti Alexnet, *Fully connected layer* menggunakan fungsi aktivasi ReLu, yang mana mengubah nilai negatif menjadi nilai 0.

Persamaan 5 Perhitungan Antar Node

$$X = \left(\sum_{i=1}^n xiwi \right) + bias \tag{5}$$

Dengan:

- X = Nilai node
- X_i = Nilai node ke- i
- W_i = Bobot ke- i
- Bias = Nilai bias

Nilai bias menentukan apakah keluaran aktivasi dari sebuah neuron akan diteruskan atau tidak melalui jaringan. Penambahan bias ini dapat meningkatkan fleksibilitas model agar sesuai dengan data yang diberikan.

Kemudian pada *node* terakhir, fungsi aktivasi yang digunakan adalah fungsi *softmax*. Fungsi ini menghitung probabilitas dari setiap kelas menggunakan Persamaan 6. Hasil klasifikasi ditentukan dari nilai probabilitas terbesar.

Persamaan 6 Fungsi *Softmax*

$$f(y_i) = \frac{e^{y_i}}{\sum_k e^{y_k}} \tag{6}$$

Dengan:

- e^{y_i} = Fungsi eksponensial vektor input
- e^{y_k} = Fungsi eksponensial vektor *output*
- K = Jumlah kelas

SVM atau *Support vector machine* adalah salah satu teknik klasifikasi yang menggunakan vektor sebagai batas pemisah antara kelas satu dengan kelas yang lain. Vektor pemisah ini disebut *hyperplane*. Untuk mendapatkan posisi optimal dari *hyperplane*, diperlukan mencari titik data terdekat dari *hyperplane*. Titik data tersebut disebut support vector. Untuk melakukan klasifikasi dengan data yang kompleks, tidak bisa hanya dengan SVM biasa. Diperlukan SVM *kernel*, yang dapat mengubah ruang input menjadi dimensi yang lebih tinggi.

Persamaan 7 Garis Linier (*Hyperplane*)

$$W^T x + b = 0 \text{ atau } y = mx + c \tag{3.7}$$

Dengan:

- W^T = Vektor bobot transpose
- X = *Data point*
- B = Bias

Jarak antara sampel dengan garis hyperplane dinyatakan dengan Persamaan 8.

Persamaan 8 Jarak Sampel dengan Hyperplane

$$r = \frac{W^T x_i + b}{||W||} \quad (3.8)$$

Dengan:

x_i = Data point ke- i
 w = Vektor bobot

Sampel paling dekat dengan hyperplane adalah support vector, sementara jarak antara support vector kelas satu dengan yang lain disebut margin.

2.2.6. Metode Evaluasi

Pada tahap evaluasi, teknik evaluasi yang dipakai dalam penelitian ini adalah Confusion matrix dengan menghitung nilai akurasi, True Positive Rate (TPR) atau recall dan Positive Predictive Value (PPV) atau precision. Tahap evaluasi ini akan dilakukan sebanyak delapan kali atau sesuai banyak kombinasi variabel yang diuji. Adapaun persamaan-persamaan dalam menghitung evaluasi adalah sebagai berikut ini.

Persamaan 9 Menghitung Akurasi

$$Akurasi = \frac{TP + FP}{TP + FP + TN + FN} \quad (9)$$

Persamaan 10 Menghitung PPV

$$PPV = \frac{TP}{TP + FP} \quad (10)$$

Persamaan 11 Menghitung TPR

$$TPR = \frac{TP}{TP + FN} \quad (11)$$

Dengan:

TP = True Positive
 TN = True Negative
 FP = False Positive
 FN = False Negative

3. HASIL DAN PEMBAHASAN

Pada bagian ini akan dibahas mengenai hasil penelitian dan analisis.

3.1. Perbandingan Hasil Evaluasi

Dari kedelapan percobaan dengan kombinasi tiga variabel yang telah dilakukan, hasil evaluasi terbaik dari masing-masing percobaan telah dikumpulkan kedalam Tabel untuk dipilih model dengan hasil evaluasi paling baik. Model dengan hasil evaluasi terbaik akan diimplementasikan kedalam aplikasi desktop klasifikasi kanker payudara.

Berikut ini adalah daftar kombinasi variabel pembelajaran yang dilakukan:

- A. Tanpa Preprocessing, distribusi dataset 7:3
- B. Dengan Preprocessing, distribusi dataset 7:3
- C. Tanpa Preprocessing, distribusi dataset K-fold
- D. Dengan Preprocessing, distribusi dataset K-fold
- E. Tanpa Preprocessing, distribusi dataset 7:3, klasifikasi SVM
- F. Dengan Preprocessing, distribusi dataset 7:3, klasifikasi SVM
- G. Tanpa Preprocessing, distribusi dataset K-fold, klasifikasi SVM
- H. Dengan Preprocessing, distribusi dataset K-fold, klasifikasi SVM

Dari tabel perbandingan hasil evaluasi Tabel 2, dapat disimpulkan bahwa dataset setelah dipreproses dapat meningkatkan hasil evaluasi pembelajaran. Perbandingan hasil evaluasi untuk mendukung kesimpulan tersebut adalah hasil evaluasi kombinasi variabel A dengan B, dan C dengan D. Sedangkan kombinasi variabel E, F, G, dan H tidak terjadi perubahan hasil evaluasi. Sehingga dapat disimpulkan bahwa melakukan preproses terhadap dataset tidak berpengaruh banyak pada pembelajaran dengan SVM.

Distribusi dataset sangat berpengaruh dalam meningkatkan hasil evaluasi pembelajaran. Dari hasil evaluasi, dapat dilihat bahwa distribusi dataset dengan K-fold meningkatkan hasil evaluasi daripada distribusi dataset dengan rasio 7:3. Kesimpulan ini didukung dengan membandingkan hasil evaluasi A-B yang mendistribusikan dataset 7:3 dengan hasil evaluasi C-D yang mendistribusikan dataset dengan K-fold. Klasifikasi dengan SVM juga memberikan hasil serupa dengan peningkatan hasil evaluasi setelah distribusi dataset diubah menjadi distribusi dengan K-fold. Perbandingan peningkatan ini dapat diamati dari hasil evaluasi E-F dengan G-H.

Tabel 2 Perbandingan Hasil Evaluasi

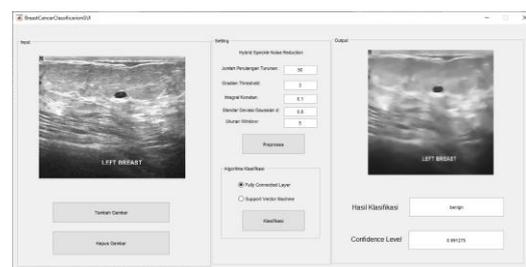
Kombinasi Variabel		Benign	Malignant	Normal	Akurasi
A	PPV	83,4%	100%	82,9%	87,8%
	TPR	97,4%	76,5%	78,4%	
B	PPV	87,1%	93,4%	93,8%	89,8%
	TPR	96,1%	83,3%	81,1%	
C	PPV	86%	96,4%	94,7%	89,8%
	TPR	98,1%	84,4%	69,2%	
D	PPV	94,9%	90,6%	76,5%	90,3%
	TPR	88,6%	89,2%	100%	
E	PPV	89,7%	84,8%	88,2%	87,8%
	TPR	89,7%	87,3%	81,1%	
F	PPV	87,1%	89,4%	86,5%	87,8%
	TPR	91,6%	82,4%	86,5%	
G	PPV	90,5%	86,6%	87,5%	88,8%
	TPR	90,5%	87,9%	84%	
H	PPV	88,3%	89,8%	88,5%	88,8%
	TPR	92,5%	82,8%	88,5%	

Metode klasifikasi dengan *Fully connected layer* lebih unggul sedikit daripada menggunakan metode klasifikasi dengan SVM. Hasil evaluasi terbaik dengan *Fully connected layer* ada pada kombinasi variabel D yang memiliki akurasi 90,3% sementara hasil evaluasi terbaik dengan SVM ada pada variabel G dan H yang masing-masing memiliki akurasi 88,8%. Namun hasil evaluasi kelas normal dari kombinasi variabel D memiliki hasil PPV lebih rendah dengan 76,5%. Yang mana berarti model tersebut lebih melakukan kesalahan klasifikasi dengan menganggap kelas lain sebagai kelas normal. Untuk mengatasi hal tersebut, aplikasi akhir akan menambahkan opsi klasifikasi menggunakan SVM agar hasil klasifikasi lebih meyakinkan.

Kesimpulan yang didapat dari kedelapan percobaan, didapat kombinasi variabel terbaik untuk pembelajaran yakni dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan *Fully connected layer*. Namun, masih terdapat kekurangan pada hasil evaluasi dengan kombinasi variabel tersebut. Sehingga diperlukan metode klasifikasi cadangan untuk lebih meyakinkan hasil klasifikasi. Kombinasi variabel terbaik kedua adalah pembelajaran dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan SVM.

3.2. IMPLEMENTASI ANTARMUKA SISTEM KLASIFIKASI

Jaringan Alexnet dengan hasil evaluasi pembelajaran terbaik diimplementasikan kedalam aplikasi desktop. Model jaringan yang akan diimplementasikan ke aplikasi adalah model yang telah dilatih menggunakan kombinasi variabel dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan *Fully connected layer*. Namun model jaringan yang telah dilatih menggunakan kombinasi variabel dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan SVM tetap diimplementasikan juga sebagai opsi bagi user.



Gambar 7 Tampilan Antarmuka Sistem

Setelah dilakukan pengujian dengan 50 *dataset* baru pada aplikasi, disimpulkan bahwa aplikasi klasifikasi kanker payudara dengan algoritma klasifikasi *fully connected layer* cukup andal dalam memprediksi kelas benign dan malignant. Namun kurang begitu bisa diandalkan dalam klasifikasi kelas normal. Rendahnya nilai TPR dari hasil klasifikasi kelas normal kemungkinan disebabkan oleh kurangnya *dataset* kelas

normal dibandingkan dengan *dataset* kelas benign atau kelas malignant. Namun secara keseluruhan, tingkat akurasi klasifikasi yang dilakukan aplikasi cukup baik dengan nilai 90%. Masih berdasarkan hasil evaluasi di atas, didapatkan hasil evaluasi rata-rata sebagai berikut; PPV = 92,3% TPR = 86,7% dan Akurasi = 90%.

4. KESIMPULAN

Dari tabel hasil evaluasi percobaan, dapat disimpulkan bahwa *dataset* setelah dipreproses dapat meningkatkan hasil evaluasi pembelajaran dengan metode klasifikasi *Fully connected layer*. Namun, melakukan preproses terhadap *dataset* tidak berpengaruh banyak pada pembelajaran dengan SVM. Distribusi *dataset* juga sangat berpengaruh dalam meningkatkan hasil evaluasi. Distribusi *dataset* dengan *K-fold* memberikan hasil evaluasi lebih baik daripada distribusi *dataset* dengan rasio 7:3. Pembelajaran baik dengan metode klasifikasi *fully connected layer* atau SVM sama mengalami peningkatan hasil evaluasi setelah dilakukan distribusi *dataset* dengan *K-fold*. Kemudian metode klasifikasi dengan *Fully connected layer* lebih unggul sedikit daripada menggunakan metode klasifikasi dengan SVM. Kesimpulan yang didapat dari kedelapan percobaan ini, didapat kombinasi variabel terbaik untuk pembelajaran yakni dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan *Fully connected layer*.

Model jaringan yang diimplementasikan ke aplikasi adalah model yang telah dilatih menggunakan kombinasi variabel dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan *Fully connected layer*. Namun model jaringan yang telah dilatih menggunakan kombinasi variabel dengan preproses *dataset*, distribusi *dataset* menggunakan *K-fold*, dan klasifikasi menggunakan SVM tetap diimplementasikan juga sebagai opsi bagi user. Setelah dilakukan test validasi akhir terhadap aplikasi dengan 50 gambar ultrasound payudara, dapat disimpulkan bahwa aplikasi klasifikasi kanker payudara yang telah dibuat cukup andal dalam memprediksi kelas *benign* dan *malignant*. Namun kurang begitu bisa diandalkan dalam klasifikasi kelas normal. Rendahnya nilai TPR dari hasil klasifikasi kelas normal kemungkinan disebabkan oleh kurangnya *dataset* kelas normal dibandingkan dengan

dataset kelas *benign* atau kelas *malignant*. Namun secara keseluruhan, hasil evaluasi aplikasi cukup baik dengan nilai rata-rata PPV = 92,3%, TPR = 86,7%, dan Akurasi = 90%.

5. DAFTAR PUSTAKA

- [1] American Cancer Society, *Breast Cancer Facts & Figures 2019-2020*. Atlanta: American Cancer Society, 2019.
- [2] World Health Organization, "Breast cancer," 2021. <https://www.who.int/news-room/fact-sheets/detail/breast-cancer> (accessed Jul. 07, 2021).
- [3] R. Guo, G. Lu, B. Qin, and B. Fei, "Ultrasound Imaging Technologies for Breast Cancer Detection and Management: A Review," *Ultrasound Med. Biol.*, vol. 44, no. 1, pp. 37–70, 2018, doi: 10.1016/j.ultrasmedbio.2017.09.012.
- [4] W. C. Shia, L. S. Lin, and D. R. Chen, "Classification of malignant tumours in breast ultrasound using unsupervised machine learning approaches," *Sci. Rep.*, vol. 11, no. 1, pp. 1–11, 2021, doi: 10.1038/s41598-021-81008-x.
- [5] G. Latif, M. O. Butt, F. Yousif Al Anezi, and J. Alghazo, "Ultrasound Image Despeckling and detection of Breast Cancer using Deep CNN," *Proc. - 2020 RIVF Int. Conf. Comput. Commun. Technol. RIVF 2020*, pp. 1–5, 2020, doi: 10.1109/RIVF48685.2020.9140767.
- [6] X. Zhang *et al.*, "Evaluating the Accuracy of Breast Cancer and Molecular Subtype Diagnosis by Ultrasound Image Deep Learning Model," *Front. Oncol.*, vol. 11, no. March, pp. 1–9, 2021, doi: 10.3389/fonc.2021.623506.
- [7] G. Ayana, K. Dese, and S. Choe, "Transfer Learning in Breast Cancer Diagnoses via Ultrasound Imaging," *Cancers (Basel)*, pp. 1–15, 2021.
- [8] W. Al-Dhabyani, M. Gomaa, H. Khaled, and A. Fahmy, "Dataset of breast ultrasound images," *Data Br.*, vol. 28, pp. 1–5, 2020, doi:

10.1016/j.dib.2019.104863.

- [9] P. S. Rodrigues, "Breast Ultrasound Image," *Mendeley Data*, V1, 2018, doi: <http://doi.org/10.17632/wmy84gzngw.1>.
- [10] F. A. Hermawati, H. Tjandrasa, and N. Suciati, "Hybrid speckle noise reduction method for abdominal circumference segmentation of fetal ultrasound images," *Int. J. Electr. Comput. Eng.*, vol. 8, no. 3, pp. 1747–1757, 2018, doi: 10.11591/IJECE.V8I3.PP1747-1757.