

Implementasi Arsitektur *Half-UNet* untuk Mendeteksi Kanker Payudara pada Citra Ultrasonografi

Billy Glen^{1*}, Yohannes²

Informatika, Universitas Multi Data Palembang, Palembang, Indonesia
 *e-mail *Corresponding Author*: bill_swen@yahoo.com

Abstract

Breast cancer is one of the biggest causes of death for women worldwide. Breast cancer is a metastatic cancer and can spread to other organs, such as bones, liver, lungs and brain. Breast cancer can be detected at an early stage, but it is difficult to find and cases of breast cancer are on the rise. Therefore, this study uses the Half-UNet architecture for breast cancer sonogram dataset. The dataset used consists of 780 breast sonograms which are divided into training data and test data with a ratio of 80:20. The Dice Coefficient results obtained on the Half-UNet architecture is 0.7063. The U-Net value can provide better Dice Coefficient results, but the Half-UNet architecture has comparable values and provides results in a relatively faster time.

Keywords: *Breast Cancer; Deep Learning; Half-UNet; Image Detection; Ultrasonography*

Abstrak

Kanker payudara merupakan salah satu penyebab terbesar dari kematian wanita di seluruh dunia. Kanker payudara adalah kanker metastatik dan dapat menyebar ke organ lainnya, seperti tulang, hati, paru-paru, dan otak. Kanker payudara dapat dideteksi pada tahap awal, tetapi sulit untuk ditemukan dan kasus kanker payudara terus meningkat. Oleh karena itu, penelitian ini menggunakan arsitektur *Half-UNet* terhadap dataset sonogram kanker payudara. Dataset yang digunakan terdiri dari 780 sonogram payudara yang dibagi menjadi data latih dan data uji dengan rasio 80:20. Hasil *Dice Coefficient* yang didapat pada arsitektur *Half-UNet* berupa 0,7063. Nilai *U-Net* dapat memberikan hasil *Dice Coefficient* yang lebih baik, akan tetapi arsitektur *Half-UNet* memiliki nilai yang sebanding dan memberikan hasil dengan waktu yang relatif lebih cepat.

Kata kunci: *Deep Learning; Deteksi Gambar; Half-UNet; Kanker Payudara; Ultrasonografi*

1. Pendahuluan

Kanker payudara merupakan salah satu penyebab terbesar dari kematian wanita di seluruh dunia. Pada tahun 2018, *Global Cancer Observatory* (GLOBOCAN) melaporkan bahwa kanker payudara adalah kanker yang sangat sering didiagnosis oleh wanita di seluruh dunia dengan jumlah lebih dari 2 juta kasus, dan sekitar 626.679 wanita meninggal setiap tahun akibat kanker payudara [1]. Kanker payudara tetap menjadi penyebab kasus kanker wanita terbesar diseluruh dunia hingga saat ini.

Kanker payudara adalah kanker metastatik dan dapat menyebar ke organ lainnya, seperti tulang, hati, paru-paru, dan otak. Banyak kasus kanker payudara terjadi pada wanita. Faktor-faktor seperti umur, riwayat keluarga, mutasi pada gen, dan gaya hidup yang tidak sehat dapat menyebabkan timbulnya kanker payudara [2]. Gejala umum untuk kanker payudara adalah adanya gumpalan pada payudara, pembengkakan pada ketiak, keluar cairan yang bersih atau berdarah, sakit pada putting payudara, dan puting terbalik. Pada tahap lanjut, kanker payudara dapat menyebabkan gejala sakit tulang, susah nafas, kurang nafsu makan, penurunan berat badan yang tidak disengaja, sakit kepala, dan kelemahan [3].

Mamografi dapat digunakan untuk menemukan kanker payudara pada tahap awal dan merupakan metode utama untuk mendeteksi kanker payudara. Hasil penelitian menunjukkan skrining mamografi mengurangi jumlah kematian sekitar 40% [4]. Akan tetapi, mesin mamografi tidak selalu tersedia diseluruh tempat karena biaya yang besar dan susah menemukan kelainan pada jaringan payudara yang padat. Metode alternatif untuk melakukan deteksi kanker payudara adalah ultrasonografi (USG).

Ultrasonografi adalah sebuah teknis diagnosis yang menggunakan gelombang suara untuk menghasilkan gambar dari gema suara. Ultrasonografi bisa dilakukan sebagai tambahan setelah tes mamografi serta dapat digunakan untuk berbagai diagnosis lainnya. Ultrasonografi juga dapat menemukan kelainan pada jaringan payudara yang padat dan tidak menggunakan radiasi.

Kanker payudara dapat dideteksi pada tahap awal, namun sulit terdeteksi karena ukuran yang sangat kecil. Jika kanker payudara dapat dideteksi pada fase awal, maka dapat mengurangi risiko pada saat melakukan pengobatan dan mengurangi biaya perawatan. Akan tetapi, jumlah kasus kanker payudara terus meningkat dan kesalahan manusia dapat menyebabkan salah diagnosis akibat banyaknya diagnosis yang perlu diperiksa.

Penelitian *computer vision* dapat dimanfaatkan untuk membantu dalam mendeteksi kanker payudara pada tahap awal. Sistem *computer-aided detection* (CADe) telah banyak digunakan untuk membantu dokter dalam melakukan diagnosis. Perkembangan *deep learning* saat ini dapat digunakan untuk banyak bidang, terutama kesehatan. Salah satu algoritma yang dikenal dalam bidang *deep learning* adalah *Convolutional Neural Network* (CNN).

Terdapat banyak arsitektur pada CNN, diantaranya adalah *U-Net*. Arsitektur *U-Net* adalah arsitektur yang dikembangkan untuk segmentasi gambar biomedis pada departemen *Computer Science*, universitas Freiburg di Jerman. Arsitektur ini didasarkan pada arsitektur *Fully Convolutional Network* yang dimodifikasi sehingga dapat digunakan dengan jumlah gambar latih yang sedikit dan memberikan hasil segmentasi yang lebih akurat. Hasil segmentasi yang dilakukan dalam *International Symposium on Biomedical Imaging (ISBI) cell tracking challenge* pada tahun 2015 memberikan hasil yang sangat baik dan mendapatkan juara pertama dalam kategorinya [5]. *U-Net* juga telah digunakan untuk segmentasi citra di berbagai bidang, seperti segmentasi keretakan [6] dan medis [5].

U-Net telah banyak dikembangkan sebagai basis arsitektur menjadi variasi dari *U-Net*, salah satunya adalah *Half-UNet*. Arsitektur *Half-UNet* dibangun sebagai modifikasi dari arsitektur *U-Net* dengan tujuan untuk menyederhanakan *U-Net*. Ide yang digunakan dalam arsitektur ini adalah menyatukan jumlah *channel* pada seluruh layer, melakukan *full-scale feature fusion* yang didapat dari setiap bagian *encoder* dengan menggunakan sistem operasi *addition* setelah *upsampling*, dan penggunaan *Ghost Module* untuk menghasilkan fitur pada gambar yang sama dengan konvolusi biasa dan parameter yang lebih ringan. Arsitektur *Half-UNet* mengurangi 98.6% parameter dibandingkan dengan *U-Net* dan dapat memberikan hasil yang sebanding dengan *U-Net* [7].

Dalam penelitian ini, digunakan arsitektur *Half-UNet* untuk mendeteksi kanker payudara pada citra ultrasonografi.

2. Tinjauan Pustaka

Penelitian kanker payudara pada mamografi telah banyak dilakukan, sebagai metode skrining utama pada payudara. Salah satu metode sederhana yang diusulkan untuk melakukan deteksi kanker payudara adalah dengan melakukan deteksi pada gambar mamografi melalui *averaging* dan *thresholding*, lalu menggunakan teknik *Max-Mean* dan *Least-Variance* untuk mendapatkan hasil segmentasi kanker payudara. Metode ini memberikan hasil segmentasi yang cepat karena menggunakan teknik *image processing* sederhana, akan tetapi nilai *averaging* dan *threshold* harus diatur secara manual [8].

Selain dari itu, kanker payudara dapat dideteksi dengan memanfaatkan *Artificial Neural Network* (ANN) untuk mendeteksi mikrokalsifikasi pada payudara. Penelitian ini melakukan segmentasi dan menggunakan *filter Sobel* untuk mendeteksi tepi pada gambar mamografi. Setelah itu, digunakan *Artificial Neural Network* untuk mendapatkan nilai *Regression* pada gambar yang telah diproses pada fitur *Entropy* dan *Standard Deviation*. Model ini memberikan nilai regresi 0,96 pada gambar payudara terinfeksi dan 0,87 pada gambar payudara normal, serta memiliki akurasi yang bagus [9].

Banyak model *deep learning* yang dapat digunakan untuk melakukan segmentasi dan klasifikasi pada gambar mamografi untuk kanker payudara. Dalam suatu penelitian, digunakan berbagai jenis model untuk mengklasifikasi kanker payudara, yaitu *InceptionV3*, *DenseNet121*, *ResNet50*, *VGG16*, dan *MobileNetV2*. Selain dari itu, digunakan model *U-Net* yang dimodifikasi untuk melakukan segmentasi pada gambar mamografi. Hasil dari seluruh model menghasilkan nilai akurasi yang sangat baik dengan menggunakan model *U-Net* yang dimodifikasi dan dataset yang telah dilakukan augmentasi [10].

Selain dari mamografi, penelitian kanker payudara pada gambar USG juga telah banyak dilakukan. Dilakukan sebuah penelitian yang menggunakan metode *preprocessing Hilbert Transform* pada gambar USG, lalu dilakukan segmentasi dengan menggunakan transformasi *marker-controlled watershed*. Fitur dari hasil segmentasi diekstraksi dengan menggunakan fitur *Gray Level Co-Occurance Matrix (GLCM)* dan fitur *Shape-based*. Dari hasil ekstraksi, digunakan metode klasifikasi KNN, *Decision Tree (DT)*, dan *Ensemble* untuk membandingkan antara kanker payudara jinak dan ganas. Model ini memberikan nilai akurasi yang sangat baik pada metode klasifikasi *Ensemble* yang menggunakan *RUSboost* [11].


Model *deep learning* yang lebih dalam juga dapat digunakan sebagai klasifikasi kanker payudara. Dilakukan sebuah penelitian yang menggunakan model *DarkNet-53* yang dilatih menggunakan *transfer learning* dan dilakukan ekstraksi fitur. Dua algoritma *optimizer* digunakan untuk melatih fitur lebih dalam, yaitu *differential evolution (DE)* dan *grey wolf optimizer (GWO)*, untuk menemukan fitur terbaik dan dihubungkan sebagai fitur untuk klasifikasi. Penelitian ini memberikan hasil yang sangat baik, memberikan akurasi sampai 99,1% menggunakan *Cubic SVM* sebagai *classifier*, serta mempercepat waktu komputasi yang dibutuhkan untuk mendapatkan hasilnya [12].

Arsitektur *U-Net* juga digunakan dalam segmentasi kanker payudara pada gambar USG. Dilakukan teknik *preprocessing* berupa *Speckle Reducing Anisotropic Diffusion (SRAD)* dan meningkatkan *contrast* dengan menggunakan *histogram equalization*. Arsitektur *U-Net* digunakan untuk melakukan segmentasi gambar, dan area segmentasi terbesar diambil jika memiliki beberapa hasil segmentasi. Model ini memberikan hasil akurasi yang cukup baik [13].

Berdasarkan penelitian-penelitian terdahulu yang telah diuraikan, telah banyak arsitektur dan model yang telah digunakan untuk melakukan segmentasi pada kanker payudara. Oleh karena itu, penelitian ini akan menggunakan arsitektur *Half-UNet* yang belum pernah dilakukan dalam segmentasi kanker payudara.

3. Metodologi

Dataset yang digunakan dalam penelitian ini berupa *Breast Ultrasound Images Dataset*. Dataset ini terdiri dari kumpulan gambar ultrasonografi pada 600 payudara wanita dari umur 25 sampai 75 tahun. Dataset ini mengandung 780 citra yang memiliki ukuran rata-rata 500x500 piksel dan memiliki *mask ground truth* pada setiap citra. Citra payudara ini dibagi menjadi 3 kategori, yaitu *normal*, *benign*, dan *malignant* [14]. Contoh citra sonografi payudara dan *mask ground truth* dapat dilihat pada Gambar 1.

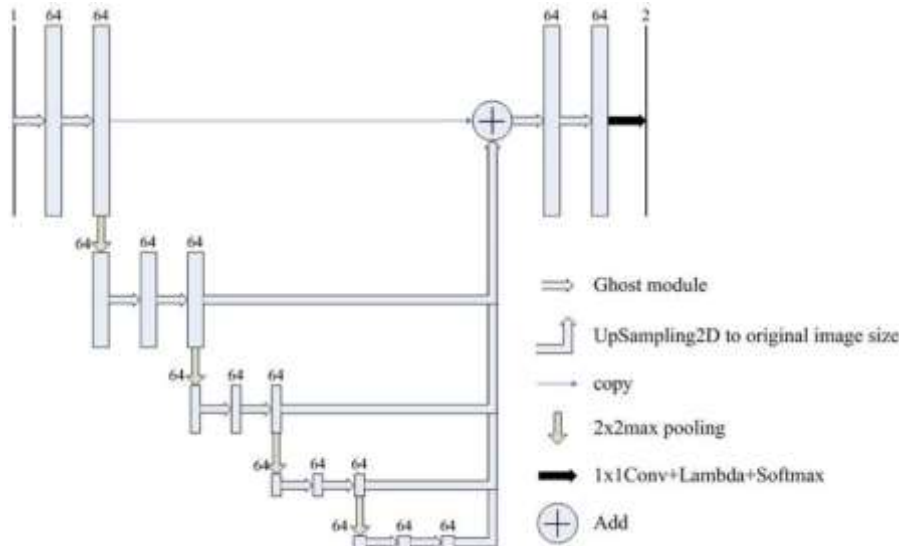


Gambar 1. Sonogram Kanker Payudara

Dataset akan dilakukan *preprocessing* sebelum dapat digunakan. Beberapa citra kanker payudara memiliki lebih dari satu *mask ground truth*, sehingga dua citra *mask* perlu digabungkan menjadi satu citra *mask*. Citra gambar juga akan dilakukan *resize* menjadi ukuran 256x256 piksel. Setelah itu, dataset dibagi menjadi dua, yaitu data latih dan data uji, dengan rasio sebesar 80:20. Data latih berjumlah 624 citra dan data uji berjumlah 156 citra.


Data dilatih pada arsitektur *Half-UNet* dengan melakukan konvolusi *Ghost Module* dan melakukan *Downsampling 2x2 max pooling*. Pada layer terakhir, dilakukan *Upsampling* pada seluruh layer konvolusi menjadi ukuran awal dan dilakukan operasi *addition* untuk

menghubungkan setiap layer konvolusi. Hasil *feature learning* yang didapatkan dari citra dihubungkan menjadi layer dengan satu *channel* yang menggunakan fungsi aktivasi *sigmoid* untuk menghitung probabilitas dari setiap kelas. Untuk mengoptimalkan hasil dari model yang dibuat, digunakan *optimizer Adam* untuk menghasilkan nilai akurasi yang lebih baik. Gambar 2 menunjukkan struktur dan alur kerja dari layer yang digunakan pada arsitektur *Half-UNet*.



Gambar 2. Arsitektur Half-UNet

Pada layer *Ghost Module*, konvolusi pada gambar dibagi menjadi dua bagian. Pada bagian pertama, input akan dilakukan konvolusi biasa dengan jumlah yang dibagi dengan rasio yang diatur. Hasil fitur pada konvolusi tersebut akan digunakan untuk membuat fitur baru dengan melakukan konvolusi *depthwise*, lalu kedua hasil fitur akan digabungkan sehingga ukuran akhir output sama dengan nilai input [15]. Gambar 3 menunjukkan perbedaan proses konvolusi biasa dan konvolusi dari *Ghost Module*.



Gambar 3. Layer Konvolusi dan *Ghost Module*

Setelah dilakukan tahap pengujian, hasil yang didapat akan dievaluasi. Metode yang akan digunakan untuk melakukan evaluasi adalah metode *Dice Coefficient*. Metode *Dice Coefficient* mengevaluasi hasil *mask* yang diprediksi oleh model CNN dengan *mask ground truth* dengan menghitung nilai rata-rata harmonik antara *Precision* dan *Recall*. *Dice coefficient* memberikan kepentingan yang sama pada nilai *false positive* dan *false negative*, sehingga dapat lebih baik digunakan pada dataset yang tidak seimbang [16]. Hasil prediksi dari model CNN dibandingkan terhadap *mask ground truth* untuk memberikan nilai *Dice Coefficient* yang didapatkan oleh model CNN. Hasil *Dice Coefficient* arsitektur CNN dalam 1 *epoch* adalah rata-

rata dari seluruh nilai *Dice Coefficient* yang didapatkan dalam 1 *epoch*. Formula *Dice Coefficient* dapat dinyatakan sebagai yang ada pada persamaan (1).

$$Dice = \frac{2TP}{2TP + FN + FP} \tag{1}$$

Dimana TP merupakan *true positive*, FN merupakan *false negative*, dan FP merupakan *false positive*.

Selain dari itu, jumlah parameter dan *FLOPs* dari model akan dievaluasi. Parameter dalam model adalah bobot pada *layer* yang mempelajari suatu data atau objek dengan mengubah nilai bobot. *FLOP*, atau *floating-point operation*, adalah operasi matematis yang mengandung angka desimal. *FLOPs* dalam model adalah jumlah operasi *floating-point* yang dilakukan dalam satu model. Formula untuk menghitung jumlah parameter dan *FLOPs* pada suatu model dapat dinyatakan sebagai yang ada pada persamaan (2) dan (3).

$$Params = (K^2 * C_{in} + 1) * C_{out} \tag{2}$$

$$FLOPs = 2 * K^2 * C_{in} * C_{out} * H_{out} * W_{out} \tag{3}$$

Dimana:

- K : Ukuran kernel
- C_{in} : Jumlah *channel input*
- C_{out} : Jumlah *channel output*
- H_{out} : Panjang ukuran *output*
- W_{out} : Lebar ukuran *output*

4. Hasil dan Pembahasan

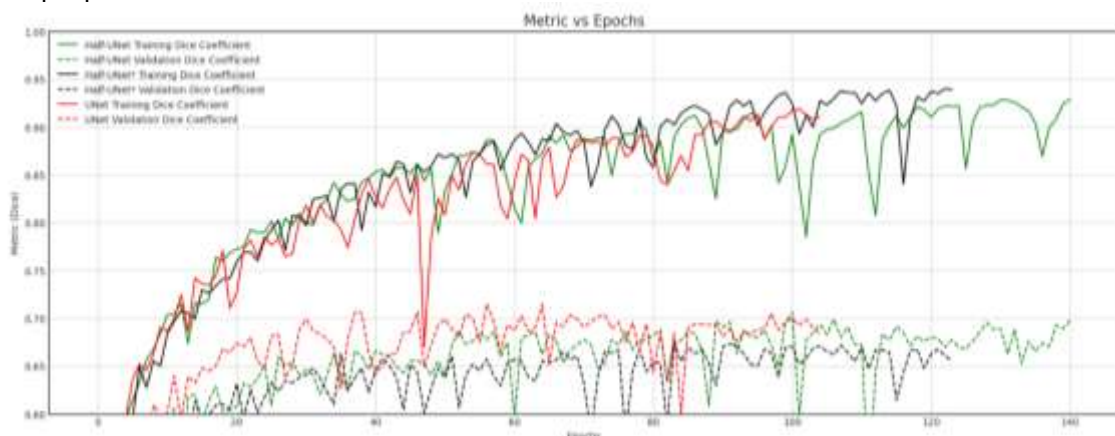
Pengujian yang dilakukan dalam penelitian ini adalah perbandingan antara arsitektur *Half-UNet* dengan arsitektur *U-Net* dan variasi arsitektur *Half-UNet* yang tidak menggunakan *Ghost Module*. Semua pengujian dilakukan hingga model tidak berkembang dalam 40 *epoch* dan mengambil hasil terbaik berdasarkan nilai *Dice Coefficient*.

Sebelum melakukan proses penelitian, dataset kanker payudara dilakukan *resize* menjadi 256x256 piksel. Citra kanker payudara yang memiliki dua *ground truth mask* akan digabungkan menjadi satu. Dataset dibagi dengan rasio data latih dan data uji sebesar 80:20 dan dengan *randomization seed* bernilai 15, serta menggunakan *optimizer Adam* dengan *learning rate* 0.0001 sesuai dengan penelitian lain yang telah dilakukan sebelumnya [17].

Data latih yang didapatkan setelah dataset kanker payudara dibagi akan digunakan untuk melatih semua model menggunakan parameter yang telah ditentukan dan menggunakan data uji sebagai validasi pelatihan.

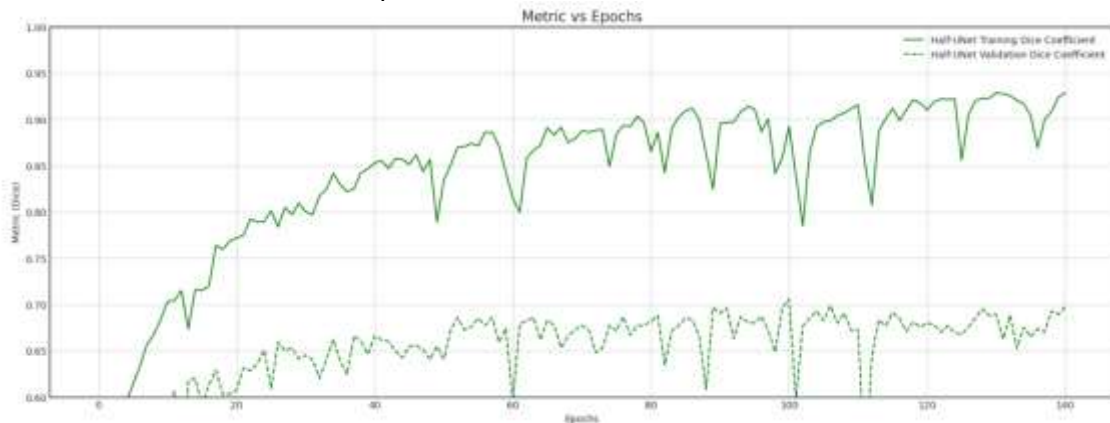
Hasil dari pengujian data latih pada seluruh model arsitektur menghasilkan nilai yang relatif sama. *Dice Coefficient* pada data latih berkisar pada nilai 0,93, sementara *Dice Coefficient* pada data uji berkisar pada nilai 0,7. Hasil grafik *Dice Coefficient* dapat dilihat pada Gambar 4.

Dari hasil penelitian yang telah dilakukan, diberikan dua nilai pada setiap model, yaitu *Training Dice Coefficient* dan *Validation Dice Coefficient*. Nilai *Training Dice Coefficient* adalah nilai yang dicapai pada data latih, sementara *Validation Dice Coefficient* adalah nilai yang dicapai pada data uji. Hasil terbaik yang diambil adalah nilai *Validation Dice Coefficient* tertinggi yang dicapai pada model.



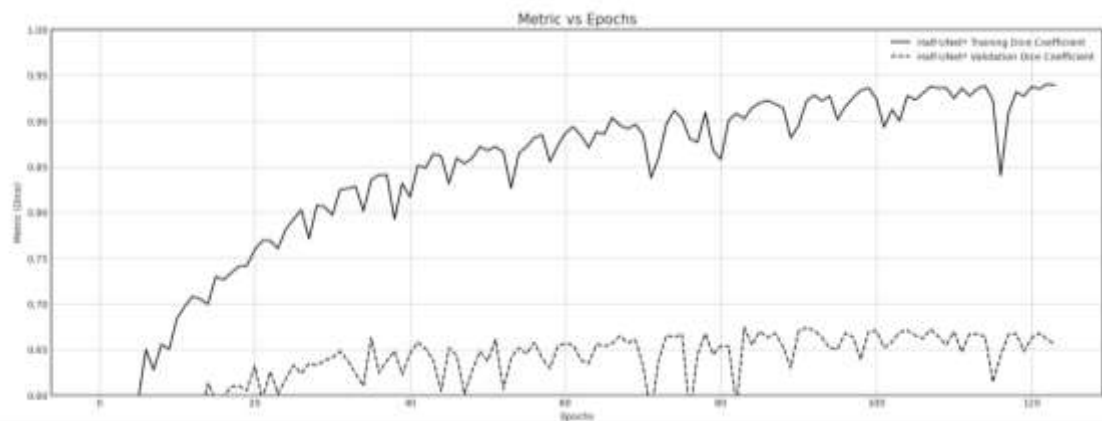
Gambar 4. Hasil *Dice Coefficient*

Hasil terbaik pada model *Half-UNet* dicapai pada *epoch* ke 101, dengan nilai *Validation Dice Coefficient* sebesar 0,7063. Gambar 5 menunjukkan nilai *Dice Coefficient* yang dicapai pada model *Half-UNet* dalam seluruh *epoch*.



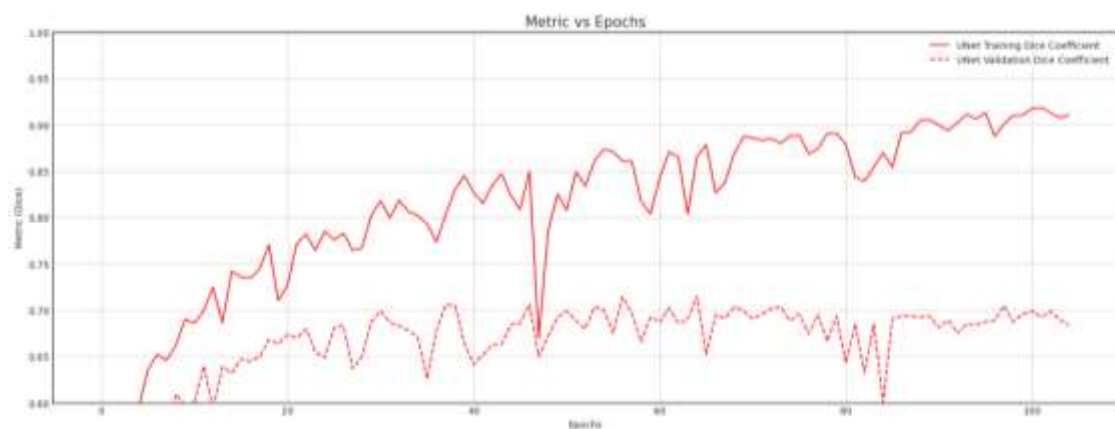
Gambar 5. Hasil *Dice Coefficient* *Half-UNet*

Hasil terbaik pada model variasi *Half-UNet* dicapai pada *epoch* ke 84, dengan nilai *Validation Dice Coefficient* sebesar 0,6742. Gambar 6 menunjukkan nilai *Dice Coefficient* yang dicapai pada model variasi *Half-UNet* dalam seluruh *epoch*.



Gambar 6. Hasil *Dice Coefficient* Variasi *Half-UNet*

Hasil terbaik pada model *U-Net* dicapai pada *epoch* ke 65, dengan nilai *Validation Dice Coefficient* sebesar 0,7153. Gambar 7 menunjukkan nilai *Dice Coefficient* yang dicapai pada model *U-Net* dalam seluruh *epoch*.




Gambar 7. Hasil *Dice Coefficient* *U-Net*

Dari hasil yang didapatkan, model *U-Net* memberikan nilai *Dice Coefficient* yang terbaik dari model lainnya, akan tetapi model *Half-UNet* juga memberikan nilai yang sebanding terhadap *U-Net* dengan jumlah parameter yang lebih sedikit dan waktu proses yang relatif lebih singkat. Tabel 1 memberikan nilai *Dice Coefficient*, jumlah parameter, dan jumlah proses *FLOPs* yang didapatkan oleh seluruh model.

Tabel 1. Hasil Performa Model *Half-UNet* dan *U-Net*

No.	Model	<i>Dice Coefficient</i>	Parameter	<i>FLOPs</i> (G)
1	<i>Half-UNet</i>	0,7063	206.561	8,26
2	Variasi <i>Half-UNet</i>	0,6742	406.913	17,79
3	<i>U-Net</i>	0,7153	31.377.793	111,21

Contoh prediksi kanker payudara yang dihasilkan oleh berbagai model dapat dilihat pada Gambar 8. Gambar pada kolom ke 1 adalah citra sonogram payudara dan gambar pada kolom ke 2 adalah citra *ground truth mask* kanker pada sonogram payudara. Gambar pada kolom ke 3 adalah hasil prediksi dari model *Half-UNet*, gambar pada kolom ke 4 adalah hasil prediksi dari model variasi *Half-UNet*, dan gambar pada kolom ke 5 adalah hasil prediksi dari model *U-Net*.



Gambar 8. Hasil Prediksi Kanker Payudara

Dibandingkan dengan penelitian terdahulu yang telah dilakukan, arsitektur *Half-UNet* memiliki nilai *Dice Coefficient* yang relatif lebih rendah, akan tetapi model arsitektur *Half-UNet* memiliki nilai parameter dan *FLOPs* yang lebih ringan. Tabel 2 mendetil hasil model *Half-UNet* dibandingkan dengan berbagai model yang didapatkan pada penelitian terdahulu.

Tabel 2. Hasil Performa Model terhadap Penelitian Terdahulu

Model	<i>Dice Coefficient</i> (%)	Parameter (M)	<i>FLOPs</i> (G)
CFF-Net [18]	77,06	9,71	14,70
EfficientU-Net [19]	90,45	5,76	19,35
BTEC-Net + RFS-UNet [20]	84,85	-	27,78
<i>Half-UNet</i>	70,63	0,2	8,26

5. Simpulan

Berdasarkan penelitian yang telah dilakukan dalam deteksi kanker payudara menggunakan arsitektur *Half-UNet*, dapat disimpulkan bahwa metode CNN dapat digunakan untuk mengenal dan mendeteksi kanker payudara pada citra ultrasonografi menggunakan arsitektur *Half-UNet* dengan hasil *Dice Coefficient* 0,7063. Dari seluruh model yang diuji, walaupun model *U-Net* mendapatkan nilai *Dice Coefficient* terbaik, arsitektur *Half-UNet* memberikan nilai yang sebanding dengan *U-Net* dan menggunakan parameter dan *FLOPs* yang lebih ringan, sehingga memberikan waktu komputasi yang lebih cepat.

Daftar Referensi

- [1] F. Bray, J. Ferlay, I. Soerjomataram, R. L. Siegel, L. A. Torre, and A. Jemal, "Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries," *CA. Cancer J. Clin.*, vol. 68, no. 6, pp. 394–424, Nov. 2018. doi: 10.3322/caac.21492.
- [2] Y. S. Sun et al., "Risk factors and preventions of breast cancer," *International Journal of Biological Sciences*, vol. 13, no. 11, pp. 1387-1397, Nov. 2017. doi: 10.7150/ijbs.21635.
- [3] G. N. Sharma, R. Dave, J. Sanadya, P. Sharma, and K. K. Sharma, "Various types and management of breast cancer: An overview," *Journal of Advanced Pharmaceutical Technology and Research*, vol. 1, no. 2, pp. 109-126, Apr. 2010.
- [4] L. Abdelrahman, M. Al Ghamdi, F. Collado-Mesa, and M. Abdel-Mottaleb, "Convolutional neural networks for breast cancer detection in mammography: A survey," *Computers in Biology and Medicine*, vol. 131, pp. 104248, Apr. 2021. doi: 10.1016/j.compbiomed.2021.104248.
- [5] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Munich, Germany, 234-241, 2015. doi: 10.1007/978-3-319-24574-4_28.
- [6] J. Aprilyanto and Y. Yohannes, "Implementasi Arsitektur VGG-Unet Dalam Melakukan Segmentasi Keretakan pada Citra Bangunan," *MDP Student Conf.*, vol. 2, no. 1, pp. 257-264, Apr. 2023. doi: 10.35957/mdp-sc.v2i1.4311.
- [7] H. Lu, Y. She, J. Tie, and S. Xu, "Half-UNet: A Simplified U-Net Architecture for Medical Image Segmentation," *Front. Neuroinform.*, vol. 16, pp. 911679, June 2022. doi: 10.3389/fninf.2022.911679.
- [8] A. K. Singh and B. Gupta, "A Novel Approach for Breast Cancer Detection and Segmentation in a Mammogram," *Procedia Computer Science*, vol. 54, pp. 676-682, 2015. doi: 10.1016/j.procs.2015.06.079.
- [9] V. K. Saubhagya, A. Rani, and V. Singh, "ANN based detection of Breast Cancer in mammograph images," in *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*, Delhi, India, 1-6, 2016. doi: 10.1109/ICPEICES.2016.7853734.
- [10] W. M. Salama and M. H. Aly, "Deep learning in mammography images segmentation and classification: Automated CNN approach," *Alexandria Eng. J.*, vol. 60, no. 5, pp. 4701-4709, Oct. 2021, doi: 10.1016/j.aej.2021.03.048.
- [11] T. Sadad et al., "Identification of breast malignancy by marker-controlled watershed transformation and hybrid feature set for healthcare," *Appl. Sci.*, vol. 10, no. 6, pp. 1900, 2020, doi: 10.3390/app10061900.
- [12] K. Jabeen et al., "Breast Cancer Classification from Ultrasound Images Using Probability-Based Optimal Deep Learning Feature Fusion," *Sensors*, vol. 22, no. 3, pp. 807, 2022, doi: 10.3390/s22030807.
- [13] R. Almajalid, J. Shan, Y. Du, and M. Zhang, "Development of a Deep-Learning-Based Method for Breast Ultrasound Image Segmentation," in *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, Orlando, USA, 1103-1108, 2018. doi: 10.1109/ICMLA.2018.00179.
- [14] W. Al-Dhabyani, M. Gomaa, H. Khaled, and A. Fahmy, "Dataset of breast ultrasound images," *Data Br.*, vol. 28, pp. 104863, Feb. 2020, doi: 10.1016/j.dib.2019.104863.
- [15] K. Han, Y. Wang, Q. Tian, J. Guo, C. Xu, and C. Xu, "GhostNet: More features from cheap operations," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, USA, 1577-1586, 2020. doi: 10.1109/CVPR42600.2020.00165.
- [16] X. Li, X. Sun, Y. Meng, J. Liang, F. Wu, and J. Li, "Dice loss for data-imbalanced NLP

- tasks,” in Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 465-476, July 2020. doi: 10.18653/v1/2020.acl-main.45.
- [17] M. S. K. Inan, F. I. Alam, and R. Hasan, “Deep integrated pipeline of segmentation guided classification of breast cancer from ultrasound images,” *Biomed. Signal Process. Control*, vol. 75, pp. 103553, May 2022, doi: 10.1016/j.bspc.2022.103553.
- [18] C. Qin *et al.*, “Dynamically aggregating MLPs and CNNs for skin lesion segmentation with geometry regularization,” *Comput. Methods Programs Biomed.*, vol. 238, pp. 107601, Aug. 2023, doi: 10.1016/j.cmpb.2023.107601.
- [19] M. F. Dar and A. Ganivada, “EfficientU-Net: A Novel Deep Learning Method for Breast Tumor Segmentation and Classification in Ultrasound Images,” *Neural Process. Lett.*, 2023, doi: 10.1007/s11063-023-11333-x.
- [20] S. W. Cho, N. R. Baek, and K. R. Park, “Deep Learning-based Multi-stage segmentation method using ultrasound images for breast cancer diagnosis,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 10, pp. 10273-10292, Nov. 2022, doi: 10.1016/j.jksuci.2022.10.020.