

# ANALISIS DAMPAK TRANSFER LEARNING PADA SEGMENTAI SEMANTIK CITRA HEWAN MENGGUNAKAN U-NET

Michael Stephen Lui<sup>1</sup>, Michael David<sup>2</sup>, Muhammad Rafif Al Aziz<sup>3</sup>, Novanto Yudistira<sup>4</sup>

<sup>1, 2, 3, 4</sup> Teknik, Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya, Jl. Veteran No. 8, Malang, 65145, Indonesia

E-mail: <sup>1</sup>[michaellui@student.ub.ac.id](mailto:michaellui@student.ub.ac.id), <sup>2</sup>[michaeldavid@student.ub.ac.id](mailto:michaeldavid@student.ub.ac.id), <sup>3</sup>[muhrafifala@student.ub.ac.id](mailto:muhrafifala@student.ub.ac.id), <sup>4</sup>[yudistira@ub.ac.id](mailto:yudistira@ub.ac.id)

---

## ABSTRACT

---

Segmentasi merupakan salah satu metode pengolahan citra yang membagi citra menjadi beberapa segmen. Segmentasi pada percobaan ini menggunakan metode *deep learning*, yaitu *convolutional neural network* (CNN) dengan arsitektur U-Net. CNN adalah salah satu metode *deep learning* yang sangat populer pada pengolahan citra dan arsitektur U-Net biasa digunakan untuk segmentasi citra berjenis semantik. Hasil segmentasi dianalisa menggunakan metrik *Intersection-over-Union* (IoU) menunjukkan bahwa model U-Net dengan *transfer learning* memiliki performa yang lebih baik dibandingkan dengan model U-Net tanpa *transfer learning*.

### Kata kunci:

convolutional neural network, deep learning, pengolahan citra, segmentasi semantik, transfer learning, u-net

---

## 1. Pendahuluan

Pengolahan citra adalah salah satu topik yang masih dikembangkan pada era revolusi industri 4.0 ini. Pengembangan suatu sistem yang mampu mengenali suatu obyek memiliki banyak manfaat, baik dalam sektor industri, teknologi, maupun medis.

Segmentasi adalah suatu metode pengolahan citra yang membagi citra menjadi beberapa segmen. Tujuan dari pembentukan segmen tersebut adalah untuk membedakan obyek dengan non-obyek. Terdapat beberapa jenis segmentasi seperti semantik, instans, deteksi obyek, dan lain-lain. Segmentasi pada penelitian ini menggunakan metode *deep learning*, yaitu proses pembelajaran dengan model *convolutional neural network* (CNN) arsitektur U-Net yang menghasilkan segmentasi berjenis semantik.

CNN adalah salah satu metode *deep learning* yang sangat populer pada pengolahan citra dan arsitektur U-Net biasa digunakan untuk segmentasi citra berjenis semantik [1]. *Transfer learning* adalah suatu jenis pembelajaran yang menggunakan bobot yang telah ada sebelumnya. Tujuan utama dari *transfer learning* adalah untuk mempersingkat waktu pembelajaran dan performa model. Pada penelitian ini, bobot awal yang digunakan berasal dari MobileNetV2. Beberapa aplikasi dari U-Net telah dilakukan pada berbagai bidang akhir-akhir ini seperti pada segmentasi sel [7] dan segmentasi vena retina [8][9].

Proses pembelajaran akan dilaksanakan dua kali, yaitu model U-Net dengan *transfer learning* dan model U-Net tanpa *transfer learning*. Hasil segmentasi kedua model U-Net akan dianalisis menggunakan metrik *Intersection-over-Union* (IoU) [2].

## 2. Dataset

Dataset yang digunakan pada penelitian ini adalah Oxford-IIIT pet, yang merupakan kumpulan citra dari berbagai jenis kucing dan anjing [3]. Dataset tersebut berisi sebanyak 7349 citra. Dataset telah dibagi menjadi dataset latih dan uji, dan memiliki rasio mendekati 50%. Alasan penggunaan dataset ini adalah

adanya fitur *true mask* yang berupa gambar hasil segmentasi yang tepat. Fitur tersebut digunakan untuk mengevaluasi hasil segmentasi dengan metrik IoU.

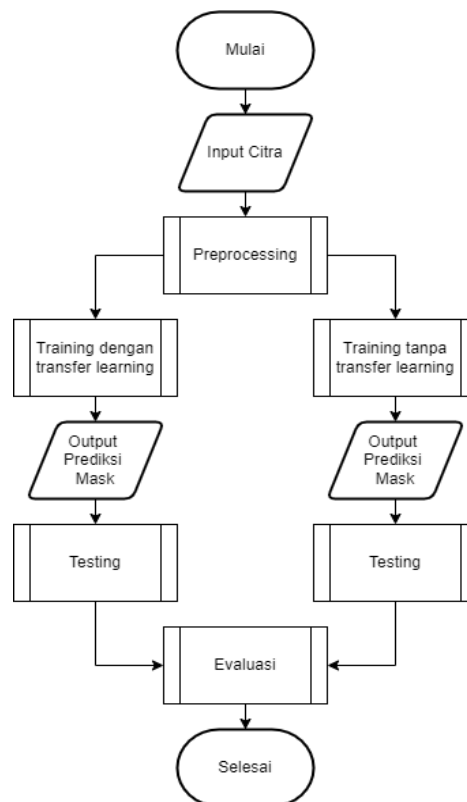


Gambar 1. Contoh isi dataset Oxford-IIIT Pet.

### 3. Metodologi Penelitian

Penelitian ini menganalisa dampak *transfer learning* pada segmentasi citra hewan dengan metode *deep learning*, yaitu *convolutional neural network* (CNN) dengan arsitektur U-Net. Pemrosesan awal yang dilakukan adalah normalisasi dan augmentasi. Bobot awal yang digunakan pada model dengan *transfer learning* berasal dari MobileNetV2. Proses pelatihan dilaksanakan sebanyak 20 epoch dengan learning rate awal sebesar 0,001. Optimizer yang digunakan adalah *Adaptive Moment Estimation* (Adam) dengan fungsi loss *sparse categorical crossentropy*.

Hasil segmentasi akan bertipe semantik, yang akan membagi citra menjadi tiga segmen, yaitu hewan, tepi, dan bukan hewan dan tepi. Hasil segmentasi akan dievaluasi dengan metrik *Intersection-over-Union* (IoU) [2], yang akan membandingkan hasil segmentasi dengan *true mask* yang berasal dari dataset. Penelitian akan dilaksanakan sesuai dengan diagram pada Gambar 2.



Gambar 2. Diagram alur penelitian.

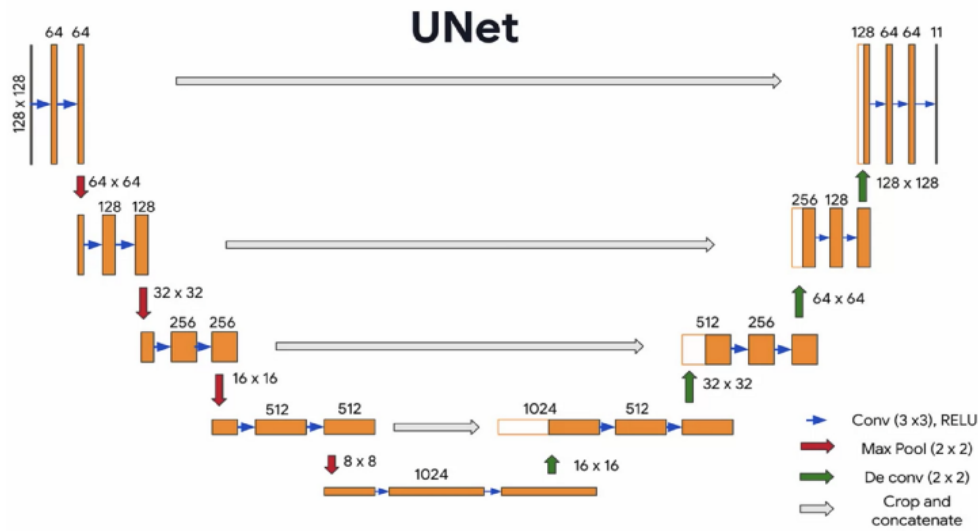
### 3.1. Normalisasi

Normalisasi merupakan tahap dalam pemrosesan awal citra yang merubah nilai pixel dengan cara membagi nilai pixel dengan angka 255 sehingga akan menghasilkan nilai diantara 0 dengan 1.

### 3.2. Augmentasi

Augmentasi adalah proses transformasi citra seperti rotasi, pergeseran, pemotongan, pembalikan, dan lain-lain yang dilakukan secara acak. Augmentasi digunakan untuk meningkatkan jumlah data latih dan mengurangi kemungkinan terjadinya kasus overfitting [4].

### 3.3. U-Net



Gambar 3. Arsitektur U-Net.

U-Net (Gambar 3) adalah salah satu jenis CNN yang biasa digunakan untuk segmentasi citra berjenis semantik [5]. U-Net terdiri dari layer input, beberapa layer *downsampler* dan *upsampler*, dan layer output. Pada percobaan ini, layer *downsampler* terdiri dari dua 3x3 konvolusi *unpadded*, yang selanjutnya akan melalui fungsi aktivasi ReLU (1) dan sebuah 2x2 layer konvolusi *maxpool* dengan *stride* 2. Pada setiap tahap *downsampling* akan terjadi penggandaan fitur. Pada layer *upsampler*, terdapat proses *upsampling* diikuti sebuah 2x2 layer konvolusi yang akan membagi jumlah fitur menjadi dua, proses penggabungan fitur, dua 3x3 layer konvolusi, masing-masing dengan fungsi aktivasi ReLU (1). Layer terakhir berupa 1x1 layer konvolusi transposisi yang digunakan untuk membagi 64 komponen vektor fitur menjadi 3 kelas dengan fungsi aktivasi softmax (2).

$$f(x) = \max(0, x) \quad (1)$$

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2)$$

### 3.4. MobileNetV2

MobileNetV2 adalah sebuah model CNN yang dibuat oleh Google. MobileNetV2 terdiri dari sebuah layer *fully convolution* dengan 32 filter, diikuti dengan 19 layer residu. Model ini dibuat dengan tujuan untuk mengurangi kompleksitas model suatu jaringan, sehingga cocok untuk perangkat dengan kemampuan komputasi rendah [6].

### 3.5. Optimizer Adaptive Moment Estimation

*Adaptive Moment Estimation* (Adam) adalah sebuah algoritma optimisasi yang secara eksponen mengurangi nilai rata-rata gradien sebelumnya (3). Algoritma ini juga secara eksponen mengurangi nilai rata-rata gradien kuadrat untuk menghasilkan *learning rate* yang bersifat adaptif (4).

$$\hat{m} = \frac{m}{1-\beta_1^t} \quad (3)$$

$$\hat{s} = \frac{s}{1-\beta_2^t} \quad (4)$$

### 3.6. Fungsi Loss Sparse Categorical Crossentropy

*Sparse categorical crossentropy* adalah suatu variasi fungsi loss *cross entropy* yang digunakan pada saat tiap data memiliki kelas yang independen (*mutually exclusive*). Fungsi ini menghitung logaritma prediksi terhadap tiap kelas (5). Fungsi loss ini bertujuan untuk mengevaluasi performa suatu model klasifikasi yang menghasilkan nilai diantara 0 dan 1. Semakin kecil nilai loss maka semakin baik model tersebut.

$$CCE(p, t) = - \sum_{c=1}^C t_{o,c} \log \log (p_{o,c}) \quad (5)$$

### 3.7. Intersection-over-Union

*Intersection-over-Union* (IoU) adalah metrik yang digunakan untuk mengukur akurasi hasil segmentasi suatu model [2]. IoU mengukur persamaan dari hasil segmentasi (*predicted mask*) dengan segmentasi sebenarnya (*true mask*) yang telah disediakan pada dataset (6).

$$IoU = \frac{A \cap B}{A \cup B} \quad (6)$$


### 3.8. Evaluasi

Penelitian ini menggunakan dataset Oxford-IIIT pet yang memiliki fitur *true mask*. Fitur tersebut digunakan untuk mengevaluasi model pada percobaan ini dengan metrik IoU. Nilai validasi loss dan IoU digunakan untuk menentukan performa model dalam proses pembelajaran. Berdasarkan nilai validasi, terdapat tiga kemungkinan kasus performa pelatihan, yaitu:

1. Nilai loss validasi meningkat dan IoU validasi menurun menunjukkan kasus underfitting.
2. Nilai loss validasi meningkat dan IoU validasi juga meningkat menunjukkan kasus overfitting.
3. Nilai loss validasi menurun dan IoU validasi meningkat merupakan tanda bahwa model belajar dengan lancar.

## 4. Hasil dan Pembahasan

Contoh hasil segmentasi model dengan *transfer learning* dan model tanpa *transfer learning* masing-masing nampak pada gambar 3 dan 4 sebagai berikut :




Gambar 3. Perbandingan citra awal, hasil segmentasi sebenarnya, dan hasil segmentasi U-Net dengan *transfer learning*.

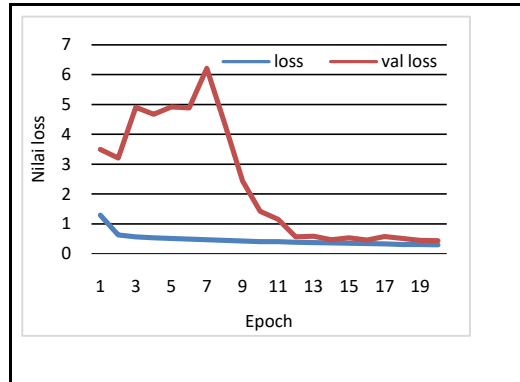


Gambar 4. Perbandingan citra awal, hasil segmentasi sebenarnya, dan hasil segmentasi U-Net tanpa *transfer learning*.


Grafik nilai loss dan IoU model dengan *transfer learning* dan model tanpa *transfer learning* dapat dilihat masing-masingnya pada gambar 5, 6, 7, dan 8 sebagai berikut :



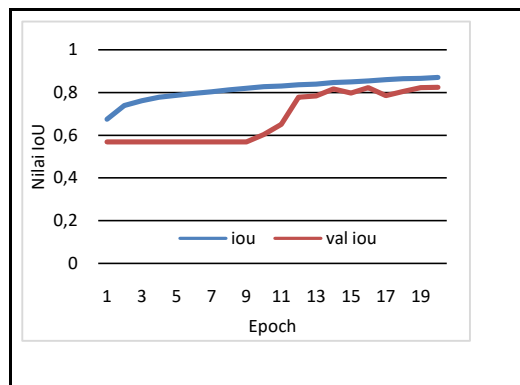
Gambar 5. Nilai loss U-Net dengan *transfer learning*.



Gambar 6. Nilai loss U-Net tanpa *transfer learning*.



Gambar 7. Nilai IoU hasil segmentasi U-Net dengan *transfer learning*.



Gambar 8. Nilai IoU hasil segmentasi U-Net tanpa *transfer learning*.

Hasil akhir dari model U-Net dengan *transfer learning* (1) dan model U-Net tanpa *transfer learning* (2) adalah:

Tabel 1. Nilai loss dan validasi loss pada epoch ke-20

model	loss	val loss
1	0,183	0,272
2	0,298	0,435

Tabel 2. Nilai IoU dan validasi IoU pada epoch ke-20

model	IoU	val IoU
1	0,919	0,896
2	0,871	0,825

## 5. Kesimpulan

Berdasarkan analisa hasil pengujian kedua model maka dapat disimpulkan bahwa:

1. Model U-Net dengan *transfer learning* memiliki nilai loss yang lebih rendah dibandingkan dengan model U-Net tanpa *transfer learning*, sehingga model U-Net dengan *transfer learning* memiliki performa yang lebih baik dibandingkan model U-Net tanpa *transfer learning*.
2. Berdasarkan nilai validasi loss dan IoU, model U-Net dengan *transfer learning* menjalankan proses pelatihan dengan lancar, sedangkan model U-Net tanpa *transfer learning* mengalami *overfitting*.

Berdasarkan nilai IoU, hasil segmentasi model U-Net dengan *transfer learning* lebih baik dibandingkan model U-Net tanpa *transfer learning*.

## Daftar Pustaka

- [1] Guo, D., Pei, Y., Zheng, K., Yu, H., Lu, Y., & Wang, S. (2020). Degraded Image Semantic Segmentation with Dense-Gram Networks. *IEEE Transactions on Image Processing*, 29, 782–795. <https://doi.org/10.1109/TIP.2019.2936111>
- [2] *Intersection over Union (IoU) – Johannes S. Fischer*. (n.d.). Retrieved December 27, 2021, from <https://johfischer.com/2021/11/04/intersection-over-union-iou/>
- [3] *Visual Geometry Group - University of Oxford*. (n.d.). Retrieved December 27, 2021, from <https://www.robots.ox.ac.uk/~vgg/data/pets/>
- [4] *Image Augmentation. Improving Deep learning models | by Sanchit Tanwar | Analytics Vidhya | Medium*. (n.d.). Retrieved December 27, 2021, from <https://medium.com/analytics-vidhya/image-augmentation-9b7be3972e27>
- [5] Ronneberger, O., Fischer, P., & Brox, T. (n.d.). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. <http://lmb.informatik.uni-freiburg.de/>
- [6] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., & Andreetto, M. (n.d.). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*.
- [7] Yudistira, Novanto, et al. "Prediction of sequential organelles localization under imbalance using a balanced deep u-net." *Scientific reports* 10.1 (2020): 1-11.
- [8] Hakim, Lukman, et al. "Regularizer based on Euler characteristic for retinal blood vessel segmentation." *Pattern Recognition Letters* 149 (2021): 83-90.
- [9] Hakim, Lukman, et al. "U-net with graph based smoothing regularizer for small vessel segmentation on fundus image." *International Conference on Neural Information Processing*. Springer, Cham, 2019.