

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Dari hasil penelitian ini dapat diambil kesimpulan sebagai berikut:

1. Arsitektur U-Net berperforma lebih tinggi dibandingkan arsitektur DeepLabV3+ untuk klasifikasi biner (retak/tidak retak) pada skripsi ini dengan detail parameter evaluasi sebagai berikut:

Tabel 5.1 Nilai akurasi, F1, *precision*, dan *recall* untuk arsitektur U-Net dan DeepLabV3+

| U-Net | | | |
|------------------|-------------------|------------------------|-------------------------|
| | Yang et al (2018) | <i>Dataset</i> pribadi | <i>Dataset</i> gabungan |
| Akurasi | 96,26% | 92,52% | 96,13% |
| F1 | 82,34% | 74,18% | 79,60% |
| <i>Precision</i> | 90,23% | 99,88% | 89,13% |
| <i>Recall</i> | 75,43 | 21,77% | 71,43% |

| DeepLabV3+ | | | |
|------------------|-------------------|------------------------|-------------------------|
| | Yang et al (2018) | <i>Dataset</i> pribadi | <i>Dataset</i> gabungan |
| Akurasi | 95,90% | 92,50% | 95,78% |
| F1 | 78,04% | 72,71% | 76,49% |
| <i>Precision</i> | 86,15% | 99,38% | 83,93% |
| <i>Recall</i> | 71,78% | 22,69% | 73,40% |

2. Arsitektur U-Net lebih mampu mendeteksi retak yang tipis dibandingkan arsitektur DeepLabV3+,
3. Hasil pengujian memperlihatkan bahwa performa *neural network* sangat tergantung dari jumlah dan kualitas *dataset* pelatihan yang dipakai. Hasil pengujian dapat dilihat di subbab 4.2,

4. Penggunaan *dataset* pribadi yang terdiri dari foto-foto beton berongga dari uji silinder menunjukkan bahwa *neural network* mampu untuk membedakan antara rongga dengan retak,
5. Arsitektur U-Net dan DeepLabV3+ dengan semua jenis *dataset* pelatihan yang dipakai memiliki rentang *hyperparameter learning rate* (kecepatan langkah pembelajaran) optimal diantara 1e-3 dan 1e-4 dengan *batch size* 8. Rangkuman dari hyperparameter yang dipakai untuk melatih *neural network* adalah sebagai berikut:

Tabel 5.2 *Hyperparameter* untuk arsitektur U-Net dan DeepLabV3+

| U-Net | | | |
|----------------------|-------------------|------------------------|-------------------------|
| | Yang et al (2018) | <i>Dataset</i> pribadi | <i>Dataset</i> gabungan |
| <i>Learning rate</i> | 4e-4 | 7e-4 | 5e-4 |
| <i>Batch size</i> | 8 | 8 | 8 |
| DeepLabV3+ | | | |
| | Yang et al (2018) | <i>Dataset</i> pribadi | <i>Dataset</i> gabungan |
| <i>Learning rate</i> | 5e-4 | 5e-4 | 5e-4 |
| <i>Batch size</i> | 8 | 8 | 8 |

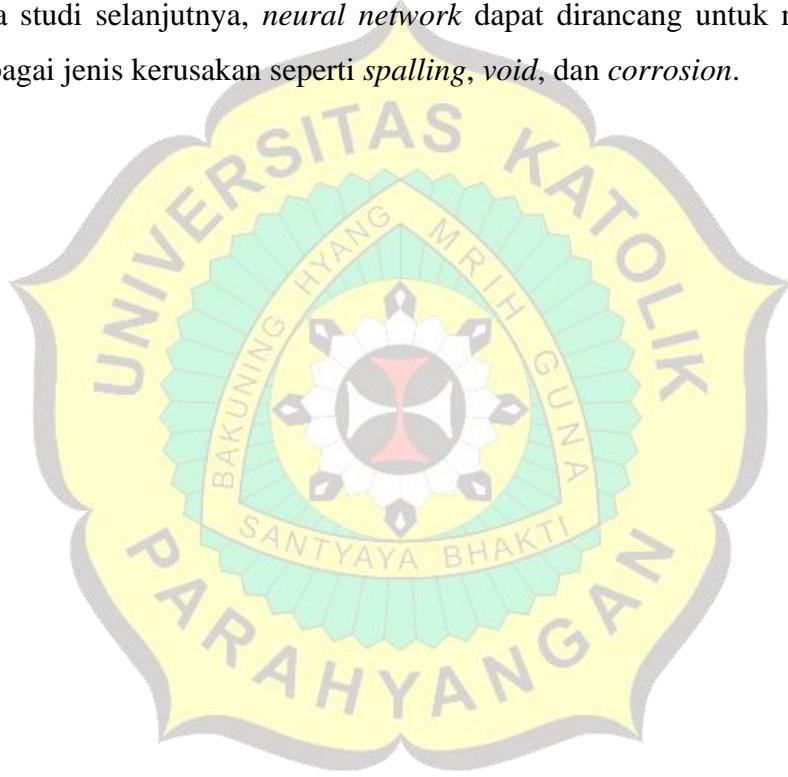
6. Metode pengukuran lebar dan panjang retak menggunakan *medial axis transform* memiliki hasil yang cukup akurat, namun diperlukan konversi dari satuan piksel ke satuan nyata untuk tahap inspeksi selanjutnya. Konversi dari satuan piksel ke satuan nyata dapat dilakukan dengan integrasi sensor jarak/*proximity sensor* dengan program *neural network*. Namun, karena keterbatasan waktu pengerjaan skripsi dan kebutuhan perangkat keras yang cukup mahal, proses konversi ini belum bisa dilakukan pada skripsi ini.

5.2 Saran

Saran penulis untuk skripsi ini adalah sebagai berikut:

1. *Dataset* pelatihan dengan kualitas dan variasi yang baik dapat ditambah untuk meningkatkan performa *neural network*,

2. Diperlukan proses pelatihan dan pemilihan hyperparameter yang tepat agar *neural network* dapat mengeluarkakan hasil yang diinginkan,
3. Studi perbandingan antara arsitektur U-Net dan DeepLabV3+ untuk mendeteksi retak dapat ditinjau lebih jauh. Kedua arsitektur dapat ditinjau lebih lanjut dari segi jumlah parameter, *backbone*, *optimizer*, *loss function*, dan fungsi aktivasi untuk dipelajari pengaruhnya satu sama lain,
4. Jika perangkat keras sensor jarak tersedia, konversi satuan piksel ke satuan nyata dapat ditinjau lebih lanjut,
5. Pada studi selanjutnya, *neural network* dapat dirancang untuk membedakan berbagai jenis kerusakan seperti *spalling*, *void*, dan *corrosion*.



DAFTAR PUSTAKA

- Atienza, R. (2020). *Advanced Deep Learning with Tensorflow 2 and Keras*. Birmingham: Packt.
- Chen, L. C., Papandreou, G., Schroff, F., dan Adam, H. (2017). Rethinking Atrous Convolution for Semantic Image Segmentation. arXiv:1706.05587v3.
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F., dan Adam, H. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *ECCV*, 801-818.
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolution. arXiv:1610.02357v3.
- Feynman, R., Leighton, R., dan Sands, M. (1963). *The Feynman, Lectures on Physics*. California: Addison-Wesley Publishing.
- Goodfellow, I., Bengio, Y., dan Courville, A. (2016). *Deep Learning*. Berlin: MIT Press.
- Hariharan, B., Arbelaez, P., Girshick, R., dan Malik, J. (2015). Hypercolumns for Object Segmentation and Fine-grained Localization. arXiv:1411.5752v2.
- Hoeser, T., dan Kuenzer, C. (2020). Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends. *MDPI, Remote Sensing*, 12,1667.
- Ioffe, S., dan Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. arXiv:1502.03167v3.
- Kingma, D., dan Ba, J. L. (2017). Adam: A Method for Stochastic Optimization. *ICLR*, ARxIV:1412.6980V9.
- Ronneberger, O., Fischer, P., dan Brox, T. (2015). U-Net: Convolutional Neural Networks for Biomedical Image Segmentation. arXiv:1505.04597v1.

- Shruti, J. (2020). A Survey of Loss Function for Semantic Segmentation. *IEEE*, arXiv:2006.14822v4.
- Sudre, C., Li, W., Vercauteren, T., Ourselin, S., dan Cardoso, J. (2017). Generalised Diced Overlap as a Deep Learning Loss Function for Highly Unbalanced Segmentations. arXiv:1707.03237v3.
- Varberg, D., Purcell, E., dan Rigdon, S. (2007). *Calculus, 9th ed.* New York: Pearson Education, Inc.
- Yang, X., Li, H., Luo, X., dan Huang, T. (2018). Automatic Pixel-Level Crack Detection and Measurement Using Fully Convolutional Network. *Computer-Aided Civil and Infrastructure Engineering* 33, 1090-1109.

