

Deteksi Hama Ulat Pada Tanaman Selada Berbasis *Aquaponic* Menggunakan CNN (*Convolutional Neural Network*)

Muhammad Ryan Syah Erwin¹, Aji Gautama Putrada², Muhammad Agus Triawan³

^{1,2,3} Universitas Telkom, Bandung
¹ryansyaherwin@students.telkomuniversity.ac.id,
²ajigps@telkomuniversity.ac.id,
matriawan@telkomuniversity.ac.id

Abstrak

Aquaponic merupakan suatu integrasi dari budidaya resirkulasi dengan hidroponik dalam satu sistem produksi. Biasanya pada tanaman *aquaponic* khususnya selada (*Lactuca sativa*) terdapat hama ulat. Hama ulat merupakan salah satu hama utama yang menyerang tanaman selada yang dapat merugikan petani *aquaponic*, semakin besar persentase serangan hama ulat maka produktivitas lahan akan lebih rendah. Tugas akhir ini bertujuan untuk mendeteksi ulat sehingga tanaman selada bisa terpantau dengan baik dan tidak mengalami gagal panen. Pada tugas akhir ini menggunakan metode klasifikasi CNN (*Convolutional Neural Network*) yang dapat mendeteksi adanya ulat atau tidak pada tanaman selada. CNN adalah sejenis jaringan saraf tiruan yang digunakan untuk data citra, biasanya digunakan untuk mendeteksi objek dalam sebuah citra. Pengambilan dataset pada tugas akhir ini menggunakan modul kamera Raspberry Pi, kemudian hasil gambar diubah dengan ukuran 128x128 pixel, lalu membangun model CNN dan mencari parameter terbaik. Hasil akhir pada tugas akhir ini berupa mendapatkan model dengan akurasi sebesar 89% dari 5110 dataset berupa gambar.

Kata kunci: *aquaponic*, CNN, tanaman selada, hama ulat

Abstract

Aquaponic is an integration of recirculating cultivation with hydroponics in one production system. Usually in aquaponic plants, especially lettuce (*Lactuca sativa*) there are caterpillar pests. Pests are one of the main pests that attack lettuce plants that can harm aquaponic farmers, increasing the percentage of pest attacks will lower land productivity. This final project aims to detect caterpillars so that lettuce plants can be monitored properly and do not experience crop failure. This final project uses the CNN (Convolutional Neural Network) classification method which can detect the presence of caterpillars or not on lettuce. CNN is an artificial neural network that is used for image data, usually used to detect objects in an image. Taking pictures in this final project uses a Raspberry Pi camera module, then the resulting image is converted to a size of 128x128 pixels, then builds a CNN model and looks for the best parameters. The final result in this final project is to get a model with an accuracy of 89% from 5110 datasets in the form of images.

Keywords: *aquaponic*, CNN, lettuce plant, caterpillar pest

1. Pendahuluan

1.1 Latar Belakang

Aquaponic merupakan sistem pertanian yang mengombinasikan *aquaculture* dengan *hydroponic* dalam lingkungan yang bersifat simbiotik. Dalam unit *aquaponic*, air dari tangki ikan mengalir melalui filter tempat tumbuhnya tanaman dan kemudian kembali lagi ke ikan. Terdapat beberapa filter dalam *aquaponic*, yang pertama menggunakan filter mekanis yang menghilangkan limbah padat, kemudian filter biologis yang memproses limbah terlarut. Filter biologis berfungsi menyediakan lokasi bagi bakteri untuk mengubah amonia yang beracun bagi ikan menjadi nitrat, proses ini disebut *potassium nitrate*. Saat air mengalir melalui tempat tumbuh tanaman, tanaman menyerap nutrisi ini dan akhirnya air kembali ke tangki ikan yang dimurnikan [1]. Ulat merupakan salah satu hama yang membahayakan bagi petani. Serangan ulat akan menurunkan hasil panen dan bahkan dapat menyebabkan gagal panen. Semakin besar persentase serangan hama ulat maka produktivitas lahan akan semakin rendah [2].

Petani *aquaponic* saat ini masih memiliki beberapa masalah diantaranya sulitnya untuk melakukan pengetesan suhu kolam, suhu udara, lebar daun, energi yang digunakan untuk instalasi *aquaponic*, dan juga dalam mengatasi hama ulat. Pada tugas akhir ini difokuskan untuk mendeteksi hama ulat pada tanaman selada. Hama ulat merupakan salah satu hama utama yang menyerang tanaman selada dan dapat merugikan petani *aquaponic*, semakin besar persentase serangan hama ulat maka produktivitas lahan akan lebih rendah. Tugas akhir ini difokuskan untuk mendeteksi adanya ulat pada tanaman selada menggunakan kamera terintegrasi berupa modul kamera Raspberry Pi dan metode CNN (*Convolutional Neural Network*) [3]. Oleh karena itu, melalui metode ini diharapkan dapat menekan persentase serangan hama ulat pada tanaman selada yang berujung pada penurunan produktivitas lahan dan gagal panen.

1.2 Topik dan Batasannya

Pada tugas akhir ini akan memecahkan suatu rumusan masalah yaitu bagaimana mendeteksi hama ulat pada tanaman selada menggunakan CNN berbasis *aquaponic*. Agar pembahasan dalam tugas akhir ini tidak menyimpang, diperlukan batasan masalah sebagai berikut:

1. Tugas akhir ini menggunakan sistem *Aquaponic* (NFT) *Nutrient Film Technique*.
2. Tanaman yang digunakan adalah selada (*Lactuca Sativa*).
3. Tugas akhir ini menggunakan modul kamera Raspberry Pi v1.3 dan Raspberry Pi 3 Model B.
4. Pengambilan gambar dataset berjarak antara 16-21cm.
5. Format gambar dataset berekstensi "jpg".
6. Tugas akhir ini tidak mengukur kesuburan tanaman.
7. Raspberry pi yang digunakan hanya untuk pengambilan dataset.
8. Pengambilan gambar untuk data test tampak dari atas tanaman selada.

1.3 Tujuan

Tujuan pada tugas akhir ini untuk mendeteksi hama ulat pada tanaman selada menggunakan CNN berbasis *aquaponic*. Hasil dari tugas akhir ini berupa penggunaan CNN untuk mendeteksi keberadaan ulat pada tanaman selada. Pada tugas akhir ini diharapkan dapat mendeteksi ada tidaknya ulat pada tanaman selada.

1.4 Organisasi Tulisan

Adapun organisasi dalam penulisan tugas akhir ini meyisipkan beberapa bagian dalam penulisan ini. Bagian pertama mengenai studi terkait. Pada studi terkait terdapat penjelasan secara terperinci mengenai dasar penunjang dan teori yang digunakan pada tugas akhir ini. Bagian kedua yaitu sistem yang dibangun. Pada bagian ini akan dibahas mengenai apa saja sistem yang dibangun pada tugas akhir ini. Dalam perancangan alat terdapat penjelasan mengenai alat yang digunakan selama tugas akhir ini berjalan. Selain itu, terdapat juga skenario pengujian yang dilakukan.

Bagian ketiga adalah evaluasi dari hasil tugas akhir. Hasil tersebut meliputi hasil pengujian dan hasil analisis dari tugas akhir. Bagian keempat yaitu kesimpulan. Pada bagian ini menarik kesimpulan dari hasil pengujian dan analisis serta referensi.

2. Studi Terkait

2.1 State of the art

Sistem deteksi penyakit hama padi dengan cara CNN dilakukan oleh R Syaiful pada tahun 2019. Penelitian tersebut dikembangkan fitur pengolahan citra dengan modul CNN untuk mendeteksi hama pada padi. Modul CNN yang digunakan melakukan proses segmentasi ke dalam 20 kelas. Evaluasi pada model CNN mampu mengungguli akurasi dari MLP meskipun CNN membutuhkan waktu latih lebih lama. Hewan biasanya menyebabkan kerusakan pada tanaman padi yaitu tikus, ulat tanah, ulat grayak dan lalat bibit.

Md. Imran Hossain dkk juga pernah melakukan penelitian mengenali serangga menggunakan CNN. Penelitian tersebut bertujuan untuk mengidentifikasi hama sehingga produktivitas petani semakin baik. Dataset pada penelitian ini berupa gambar ukuran persegi dengan skala abu – abu. Pada penelitian ini menghasilkan akurasi sebesar 93,46%. Pendekatan ini akan membantu petani dalam mengenali hama serangga. Penelitian ini bertujuan menunjukkan kemungkinan dan menguji proyek yang berfokus kepada deteksi serangga yang dapat membantu petani [4].

Penelitian selanjutnya dilakukan oleh Vineet Panchbhaiyye pada tahun 2019. Tujuan dari penelitian yaitu mengidentifikasi hama secara akurat dengan melakukan CNN dan melakukan analisis efek ukuran dataset pada keakuratan CNN. Faktor untuk mencapai akurasi yang tinggi dalam pengklasifikasian yaitu ukuran dari kumpulan data, semakin besar kumpulan data, maka semakin akurat identifikasi yang dilakukan. Dengan lebih banyak data, maka model klasifikasi akan mencapai akurasi yang lebih tinggi [5].

Pada tugas akhir ini lebih memfokuskan untuk mendeteksi hama ulat pada tanaman selada yang berbasis *aquaponic* karena pada ketiga penelitian yang sudah dilakukan belum terdapat pada ruang lingkup *aquaponic*. Untuk metode yang digunakan sama yaitu CNN dengan model VGG16. Pengambilan dataset yang digunakan menggunakan kamera terintegrasi berupa modul kamera Raspberry Pi.

2.2 Aquaponic

Aquaponic merupakan integrasi dari budidaya resirkulasi dengan hidroponik dalam satu sistem produksi. air mengalir dari tangki ikan melalui filter ke tempat tumbuhnya tanaman dan kembali lagi ke ikan. Dalam filter, limbah pada ikan dikeluarkan dari air yang menggunakan filter mekanis yang menghilangkan limbah yang padat dan melalui *biofilter* yang memproses limbah yang terlarut. *Biofilter* berfungsi untuk menyediakan tempat untuk

bakteri untuk mengubah ammonia yang beracun bagi ikan menjadi nitrat untuk nutrisi bagi tanaman. Proses ini disebut nitrasi. Air mengalir melalui tempat tumbuhnya tanaman kemudian tanaman menyerap nutrisi dan akhirnya air kembali ke tangki ikan yang di bersihkan [6].

Proses ini membuat ikan, tumbuhan, dan bakteri berkembang secara simbiosis dan bekerja sama untuk menciptakan lingkungan tumbuh yang bagus satu sama lain. *Aquaponic* lebih produktif dan secara ekonomi layak terutama pada lahan yang terbatas. Namun *aquaponic* rumit dan membutuhkan biaya yang lebih tinggi diperlukan untuk mengintegrasikan kedua sistem. *Aquaponic* menggabungkan dua sistem yang paling produktif di bidangnya masing-masing [7].

Kelebihan pada *aquaponic* ini yaitu produk yang dihasilkan dua dari satu sumber, sangat hemat air, tidak membutuhkan lahan yang luas, tidak menggunakan tanah, tidak menggunakan pupuk, hasilnya lebih optimal daripada biasanya, menghasilkan sedikit limbah, bisa digunakan pada lahan yang tidak dapat ditanami seperti gurun dan pulau berpasir, dan menghemat tenaga kerja karena sudah mencakup seluruhnya. *Aquaponic* juga mempunyai kekurangan seperti biaya awal yang mahal dibandingkan dengan produksi sayuran tanah, para petani harus memiliki pengetahuan tentang ikan, bakteri, dan tanaman. Kadang kebutuhan ikan dan tanaman tidak selalu cocok dengan sempurna, tidak direkomendasikan ditempat suhu yang terlalu panas. *Aquaponic* mempertimbangkan lingkungan, ekonomi dan sosial. Secara ekonomi sistem ini membutuhkan investasi di awal yang besar tetapi kemudian diikuti dengan biaya yang rendah dan hasil gabungan dari ikan dan tumbuhan. Secara lingkungan *aquaponic* mencegah lingkungan dari limbah, dan juga tidak menggunakan bahan kimia untuk pupuk [1].

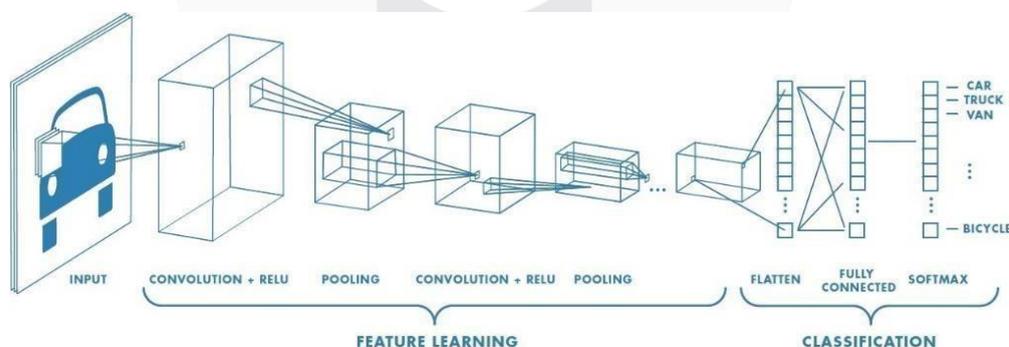
2.3 Selada dan Hama Ulat

Tanaman selada (*Lactuca sativa L*) termasuk kedalam flora sayuran yang cukup dikenal masyarakat. Sayuran tersebut mengandung zat yang lengkap dan dapat memenuhi kebutuhan gizi masyarakat. Daun tanaman selada umumnya memiliki ukuran panjang 20 – 25 cm dan lebar 15 cm.

Namun, budidaya selada selalu dibatasi oleh penyakit tanaman dan serangga pengganggu. Hama ulat grayak (*Spodoptera litura F.*) sering menyerang tanaman selada. Ulat grayak memakan daun tanaman sampai daunnya berlubang, kemudian merobeknya atau memotongnya menjadi beberapa bagian. Ulat grayak merupakan hama yang menyebabkan kerusakan serius [8].

2.4 Convolutional Neural Network (CNN)

CNN adalah sejenis jaringan saraf tiruan yang digunakan untuk data citra, biasanya digunakan untuk mendeteksi objek dalam sebuah citra. Pada bidang visi komputer ekstraksi fitur dan klasifikasi selalu menjadi arah penting pada tugas akhir. CNN menyediakan model pembelajaran dimana parameter yang dapat dilatih dengan metode penurunan gradien. CNN dapat mempelajari fitur gambar yang kompleks. Struktur CNN terutama terdiri dari lapisan input, lapisan konvolusi, pooling, lapisan penghubung penuh, dan lapisan keluaran [9]. Fungsi pooling layer yaitu mengurangi dimensi peta fitur dan menjaga skala invariant. Algoritma *back propagation* digunakan untuk mengatur parameter bobot jaringan syaraf. Parameter optimasi utama adalah parameter kernel *convolutional*, bobot lapisan penyatuan, bobot lapisan yang terhubung penuh dan parameter bias [3].



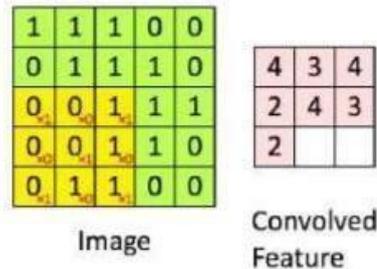
Gambar 1. Tahap pada *convolutional neural network*.
Sumber Gambar: <https://towardsdatascience.com/>

a. Input layer

Tahap ini memasukkan data awal berupa data gambar daun selada yang terdapat ulat ke dalam sistem agar gambar diproses oleh lapisan CNN berikutnya.

b. *Convolution Layer*

Lapisan *convolution* terdiri dari neuron yang disusun dengan membentuk filter yang panjang dan tinggi (*pixel*). *Layer* ini melakukan operasi konvolusi pada *output* dari *layer* sebelumnya Tujuan dari *layer* ini adalah untuk mengekstrak fitur dari citra daun selada dan secara linier mengubah data input berdasarkan informasi dalam data. Filter ini akan bergeser dari kiri atas ke kanan bawah. *Output* dari *convolution layer* ini berupa *feature map* [10].



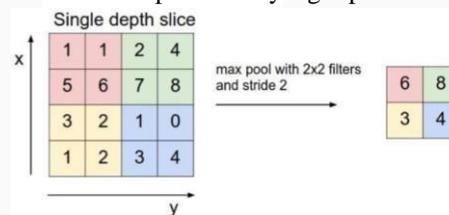
Gambar 2. Ilustrasi pada *convolution layer*
Sumber Gambar: <https://towardsdatascience.com/>

c. Fungsi Aktivasi ReLU (*Rectified Linear Unit*)

Fungsi aktivasi ReLU dilakukan setelah melakukan proses *convolution layer*. Nilai pada *feature map* akan di lakukan seleksi dimana nilai *negative* akan dijadikan 0.

d. *Pooling layer*

Lapisan pada *pooling* terdiri dari filter dengan ukuran dan langkah tertentu, dan filter bergerak melintasi seluruh area peta fitur. *Pooling* yang umum digunakan adalah *maximum pooling* dan *average pooling*. Tujuannya yaitu mengurangi dimensi peta fitur (*downsampling*) sehingga mempercepat perhitungan, karena sedikit parameter yang diperbaharui dan *over-fitting*.



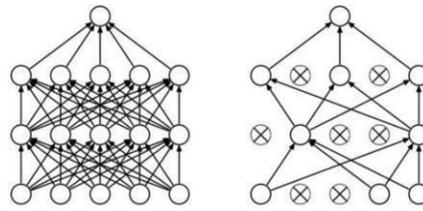
Gambar 3. Ilustrasi pada *pooling layer*
Sumber Gambar: <https://medium.com/>

e. *Fully Connected Layer*

Peta fitur yang dihasilkan oleh ekstraksi fitur masih berbentuk array multi dimensi sehingga peta fitur harus dibentuk menjadi *vector* agar dapat digunakan sebagai input dari *fully-connected layer*. Ada node yang saling berhubungan antara node depan dan belakang atau bisa disebut juga dengan *forward propagation* dan *back propagation*. Node-node ini berfungsi sebagai pengklasifikasian object berdasarkan probabilitas yang bergantung kepada setiap epoch nya.

f. *Dropout Regularization*

Dropout adalah teknik regularisasi jaringan syaraf yang secara acak memilih beberapa neuron dan tidak menggunakan neuron tersebut selama pelatihan. *Dropout* sendiri berfungsi sebagai pencegahan terjadinya *overfitting* dan juga mempercepat proses belajar.



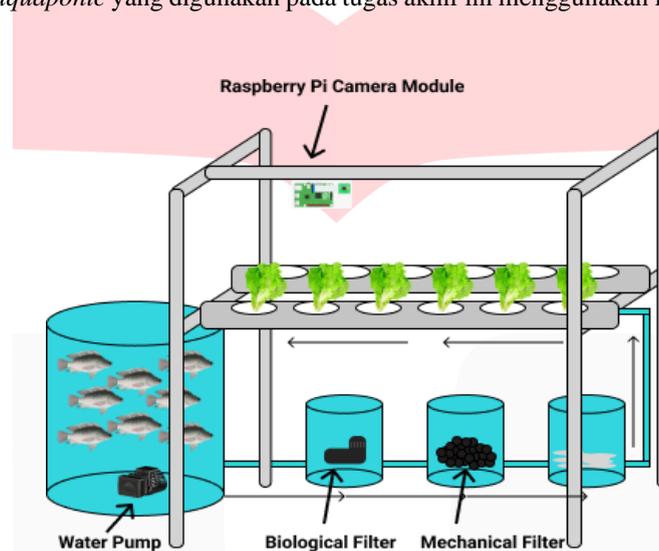
Gambar 4. Ilustrasi dropout regularization

Sumber Gambar: [https:// medium.com/](https://medium.com/)

3. Sistem yang Dibangun

3.1 Perancangan Sistem Deteksi Hama Pada Aquaponic

Aquaponic adalah sistem yang terus menerus memanfaatkan air dari budidaya ikan ke tanaman dan dari tanaman ke ikan. Sistem *aquaponic* yang digunakan pada tugas akhir ini menggunakan model (NFT) *Nutrient Film Technique*.

Gambar 5. Perancangan sistem deteksi hama dalam *aquaponic*

Model pada NFT ini memiliki 12 lubang tanam dengan panjang 1 meter menggunakan media tanam *rockwool*. Proses kerja dari sistem ini yaitu air yang ada pada bak pemeliharaan ikan ukuran 80 liter disalurkan ke dalam filter biologis menggunakan pipa PVC 1 inci. Filter biologis menggunakan jenis *swirl* dengan prinsip arah putaran air [1]. Setelah air masuk ke dalam filter biologis, air diteruskan ke dalam filter mekanis dengan menggunakan media *bioball* dan *japmat*. Selanjutnya air dialirkan ke dalam bak penampung nutrisi untuk dipompakan ke tanaman. Wadah yang digunakan sebagai filter dan bak penampung menggunakan ukuran 20 liter. Rangka tanaman menggunakan pipa PVC $\frac{3}{4}$ inci, sedangkan wadah tanaman menggunakan *netpot* yang diletakkan pada *gully trapezium*.

Terdapat alat yang digunakan untuk pengambilan dataset berupa gambar tanaman selada untuk dianalisis ada tidaknya ulat pada tanaman selada. Alat yang digunakan untuk pengambilan dataset gambar menggunakan Raspberry Pi 3 Model B dan modul kamera Raspberry Pi v1.3 5 MP dengan SD Card 16 GB sebagai penyimpanan data. Modul kamera kemudian disambungkan dengan Raspberry Pi untuk melakukan pengambilan gambar tanaman selada.

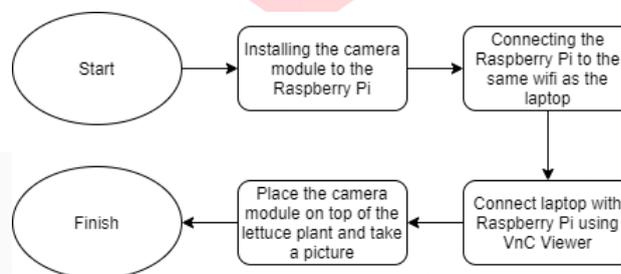
3.2 Mekanisme Pengambilan Dataset

Pada tahap ini merupakan awal untuk melakukan pengambilan dataset yang nantinya akan dibagi menjadi dua yaitu data latih dan data uji.



Gambar 6. Pengambilan Dataset berupa Gambar

Pada tugas akhir ini menggunakan dataset yang diambil secara manual dengan menggunakan kamera modul Raspberry Pi dan Raspberry Pi berupa gambar ulat pada daun selada. Modul kamera Raspberri diletakkan diatas tanaman selada dengan jarak pengambilan gambar dari kamera ke daun berkisar 16 - 21 cm dengan menggunakan *tripod* untuk mendapatkan gambar yang maksimal. Dataset yang diambil secara manual berjumlah 5110 gambar.

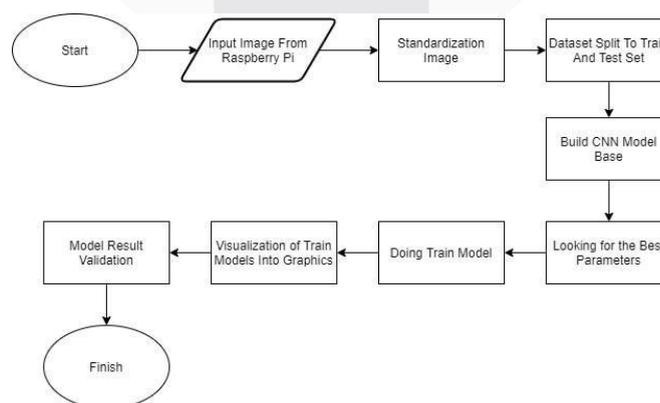


Gambar 7. Alur Pengambilan Dataset

Pengambilan dataset diawali dengan pemasangan modul kamera ke Raspberry Pi, kemudian menyambungkan Raspberry Pi pada *wifi* yang sama dengan laptop. Raspberry Pi disambungkan dengan laptop menggunakan *VnC Viewer* untuk melakukan kontrol terhadap Raspberry Pi. Kemudian meletakkan modul kamera menggunakan *tripod* dengan jarak 16-21 cm diatas tanaman selada dan mulai mengambil gambar.

3.3 Skenario Pengujian

Pengujian yang akan dilakukan pada tugas akhir ini akan mendeteksi ada tidaknya ulat pada tanaman selada. Data tersebut akan diambil dari Raspberry Pi berupa gambar yang akan di proses untuk melakukan data latih dan data uji.



Gambar 8. Alur Skenario Pengujian

Flowchart pada gambar 8 menjelaskan langkah – langkah dari tugas akhir ini. Langkah pertama adalah memasukkan dataset gambar dan menormalisasikan gambar menjadi ukuran 128x128. Langkah selanjutnya dataset gambar dibagi menjadi data latih sebanyak 3832 dan data uji sebanyak 1278. Kemudian membangun model CNN dan mencari parameter terbaik dari model CNN. Model yang digunakan pada CNN yaitu model VGG 16 yang *import* pada library [9]. Setelah mendapatkan parameter terbaik dari model CNN tersebut, maka selanjutnya melakukan train model dan memvisualisasikan train model tersebut kedalam grafik. Langkah terakhir melakukan validasi hasil model CNN yang telah dilakukan. Pada hasil validasi model CNN didapatkan akurasi 89%.

3.4 Laporan Klasifikasi

Parameter pada performansi sistem diperlukan untuk proses *training* yang menghasilkan nilai performansi yang berbeda-beda. Dari hasil tersebut akan ditinjau mana performansi yang paling baik. Berikut parameter yang digunakan [11]:

1. *Accuracy* merupakan salah satu metrik yang digunakan untuk mengevaluasi klasifikasi, untuk klasifikasi *binary*, dapat dihitung menggunakan rumus:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

TP = *True Positives* yang artinya jika terdapat ulat sesuai klasifikasinya sistem akan mendeteksi ulat tersebut.

TN = *True Negative* yang artinya jika tidak terdapat ulat sesuai klasifikasinya sistem akan mendeteksi tidak ada ulat.

FP = *False Positive* yang artinya jika tidak terdapat ulat sesuai klasifikasinya namun sistem mendeteksi adanya ulat.

FN = *False Negative* yang artinya jika terdapat ulat sesuai klasifikasinya namun sistem mendeteksi tidak adanya ulat.

2. *Precision* merupakan proporsi pada proses identifikasi *True Positive* dan *False Positive* yang benar, dapat dihitung menggunakan rumus:

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

TP = *True Positives* yang artinya jika terdapat ulat sesuai klasifikasinya sistem akan mendeteksi ulat tersebut.

FP = *False Positive* yang artinya jika tidak terdapat ulat sesuai klasifikasinya namun sistem mendeteksi adanya ulat.

3. *Recall* merupakan identifikasi aktual *True Positive* dan *False Positive* dengan benar, dapat dihitung menggunakan rumus:

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

TP = *True Positives* yang artinya jika terdapat ulat sesuai klasifikasinya sistem akan mendeteksi ulat tersebut.

FN = *False Negative* yang artinya jika terdapat ulat sesuai klasifikasinya namun sistem mendeteksi tidak adanya ulat.

4. *F1 Score* merupakan nilai perbandingan antara nilai sensitivitas dan nilai presisi. Nilai *F1 score* ini dapat menggantikan nilai akurasi jika perbandingan antara nilai FP dan FN terlalu jauh, dapat dihitung menggunakan rumus:

$$F1Score = \frac{2 \times (Precision \times Specificity)}{Precision + Specificity} \times 100\% \quad (4)$$

Specificity merupakan ratio untuk mengukur kemampuan menghindari suatu kesalahan positif dan mengukur proporsi negative actual yang diidentifikasi dengan benar.

4. Evaluasi

4.1 Hasil Pengujian

Berdasarkan hasil pengujian yang telah dilakukan yaitu mendeteksi ada tidaknya ulat pada daun selada dimana terdapat dua kelas yaitu ulat terdeteksi dan ulat tidak terdeteksi. Berikut hasil pengujian dibawah ini:



Gambar 9. Hasil Pengujian Deteksi

Pada gambar 9 terdapat hasil pengujian terdeteksi ada tidaknya ulat dengan *prediction value* sebesar 77% untuk ulat terdeteksi dan 0% untuk ulat tidak terdeteksi. Untuk nilai *prediction value* diatas 50% akan menunjukkan ulat terdeteksi, sedangkan untuk nilai dibawah atau sama dengan 50% menunjukkan tidak ada ulat terdeteksi.

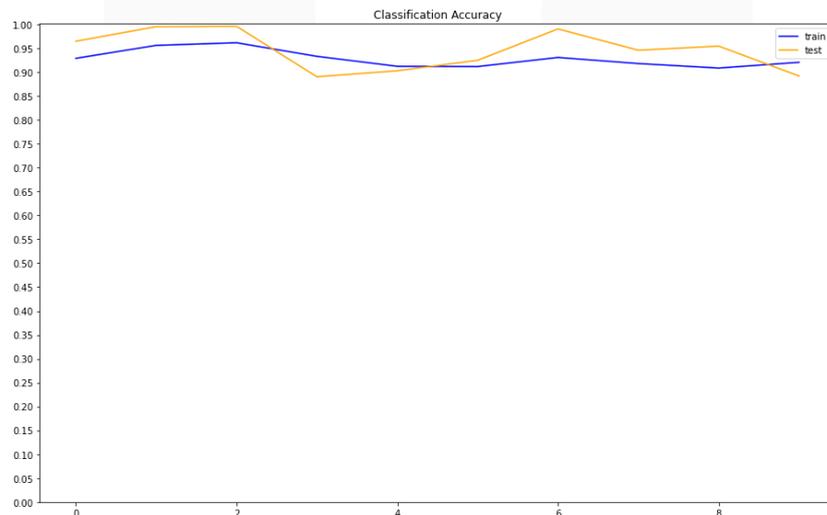
Tabel 1. *Classification Report*

	Precision	Recall	F1-Score
without_caterpillar	1.00	0.77	0.87
caterpillar	0.83	1.00	0.91
accuracy	89%		

Pada Tabel 1 menjelaskan tentang *classification report* yang digunakan untuk pengukuran kualitas prediksi dari algoritma klasifikasi. Lebih khusus lagi *True Positives*, *False Positives*, *True Negatives*, dan *False Negatives* digunakan untuk memprediksi metrik laporan klasifikasi.

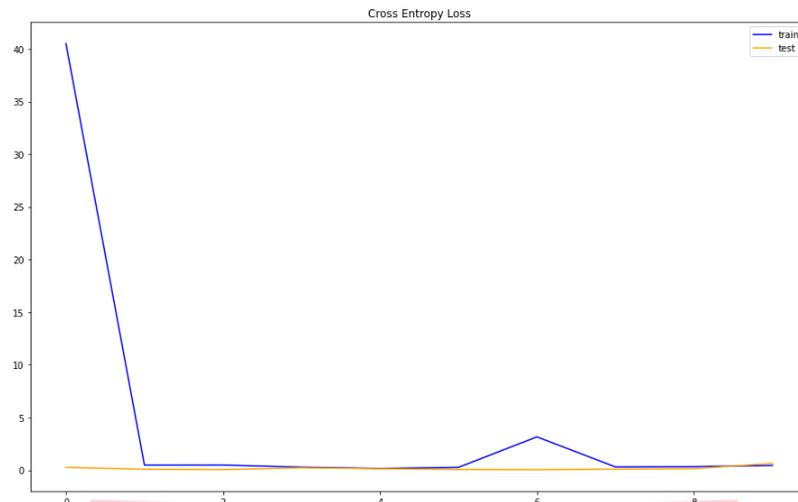
4.2 Analisis Hasil Pengujian

Berdasarkan hasil pengujian yang telah dilakukan menjelaskan tentang akurasi yang didapatkan antara data *train* dan data *test* yang telah dilakukan. Pada sumbu X terdapat nilai epoch yang bertujuan untuk memperlihatkan nilai model yang sudah dipelajari dan pada sumbu Y terdapat nilai akurasi.



Gambar 10. Grafik Hasil Akurasi

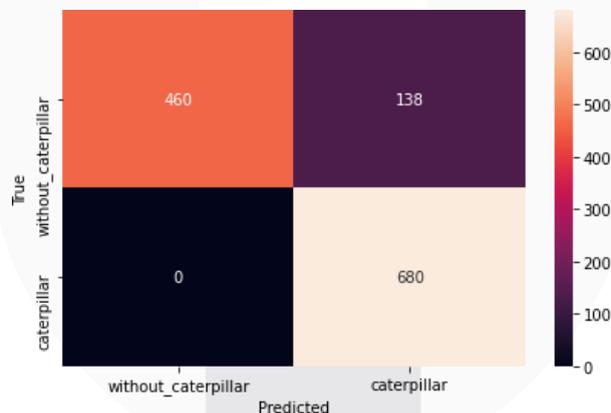
Hasil akurasi yang didapatkan pada tugas akhir ini sebesar 89% dengan jumlah dataset gambar sebanyak 5110 dengan data latih 3832 dan data uji 1278. Dapat dilihat dalam gambar 10 bahwa pada epoch terakhir menunjukkan akurasi pada data latih 89,72% dan untuk data uji sebesar 89,20%.



Gambar 11. Grafik *Cross Entropy Loss*

Pada gambar 11 diatas menjelaskan tentang *Cross Entropy Loss* yaitu dengan dibangunnya berdasarkan nilai *entropy* secara general yang mengkalkulasikan perbedaan diantara dua probabilitas dari distribusinya. Semakin kecil nilai *Cross Entropy Loss* akan semakin besar juga akurasi yang didapatkan dalam mendeteksi ulat. *Cross Entropy Loss* yang digunakan pada tugas akhir ini yaitu *binary cross entropy loss* karena hanya menggunakan dua kelas saja yaitu ulat terdeteksi dan ulat tidak terdeteksi. *Loss* yang didapatkan pada data latih sebesar 0,6798 dan untuk data uji sebesar 0,6421.

Untuk memberikan informasi perbandingan hasil klarifikasi yang dilakukan oleh sistem biasanya digunakan *confusion matrix*. *Confusion matrix* berbentuk tabel *matrix* yang menggambarkan kinerja pada klasifikasi data uji dan data latih. Kemudian hasil *confusion matrix* tersebut dipetakan dengan *heatmap*. *Heatmap* adalah visualisasi yang menampilkan data dengan representasi warna yang berbeda-beda. Semakin tinggi suatu angka, maka warnanya akan semakin terang dan semakin rendah suatu angka maka akan semakin gelap warnanya.



Gambar 12. Hasil Validasi Heatmap

Gambar 12 diatas menunjukkan *heatmap* hasil validasi yang digunakan pada model CNN. Pada sumbu X terdapat nilai prediksi ada tidaknya ulat, dan untuk sumbu Y terdapat nilai yang sebenarnya.

Tabel 2. Hasil Heatmap

Konsep	Hasil
True Positive (TP)	460
True Negative (TN)	680
False Positive (FP)	0
False Negative (FN)	138

Kategori pada tabel 2 diatas yaitu True Positive (TP) sebanyak 460 gambar yang benar terdeteksi ulat, *True Negative* (TN) sebanyak 680 yang tidak terdeteksi ulat, *False Positive* (FP) sebanyak 0 gambar yang salah dalam mendeteksi adanya ulat, dan *False Negative* (FN) sebanyak 138 gambar yang tidak terdeteksi ulat.

5. Kesimpulan

Dalam tugas akhir ini melakukan suatu sistem mendeteksi ada tidaknya ulat pada tanaman selada *aquaponic* menggunakan CNN telah terpenuhi dengan akurasi yang dihasilkan pada tugas akhir ini sebesar 89% dan *cross entropy loss* sebesar 0,6421. Jumlah dataset gambar yang digunakan pada tugas akhir ini berjumlah 5110 data dengan data latih 3832 dan data uji 1278. Untuk penelitian selanjutnya dapat mengambil gambar secara real time agar memudahkan petani untuk langsung mendeteksi ulat.

Referensi

- [1] H. Nishiyama, A. Nagata, Y. Matsuo, and R. Matsuo, *Light avoidance by a non-ocular photosensing system in the terrestrial slug Limax valentianus*, vol. 222, no. 14, 2019.
- [2] R. A. Nurlaili, U. G. Mada, and S. C. Permatasari, "Identifikasi Serangga Selada Hidroponik Sebagai Langkah Awal Penyediaan Sayur Sehat," *BIOTROPIC J. Trop. Biol.*, vol. 4, no. 2, pp. 89–97, 2020, doi: 10.29080/biotropic.2020.4.2.89-97.
- [3] W. Zhiqiang and L. Jun, "A review of object detection based on convolutional neural network," *Chinese Control Conf. CCC*, pp. 11104–11109, 2017, doi: 10.23919/ChiCC.2017.8029130.
- [4] M. I. Hossain, B. Paul, A. Sattar, and M. M. Islam, "A Convolutional Neural Network Approach to Recognize the Insect: A Perspective in Bangladesh," *Proc. 2019 8th Int. Conf. Syst. Model. Adv. Res. Trends, SMART 2019*, pp. 384–389, 2020, doi: 10.1109/SMART46866.2019.9117442.
- [5] V. Panchbhaiyye and T. Ogunfunmi, "GHTC 2018: IEEE Global Humanitarian Technology Conference: 2018 conference proceedings: DoubleTree By Hilton San Jose, California, USA, October 18 - 21, 2018," *2018 IEEE Glob. Humanit. Technol. Conf.*, pp. 1–2, 2018.
- [6] A. Cohen, S. Malone, Z. Morris, M. Weissburg, and B. Bras, "Combined Fish and Lettuce Cultivation: An Aquaponics Life Cycle Assessment," *Procedia CIRP*, vol. 69, no. May, pp. 551–556, 2018, doi: 10.1016/j.procir.2017.11.029.
- [7] M. A. Romli, S. Daud, R. A. A. Raof, Z. A. Ahmad, and N. Mahrom, "Aquaponic Growbed Water Level Control Using Fog Architecture," *J. Phys. Conf. Ser.*, vol. 1018, no. 1, 2018, doi: 10.1088/1742-6596/1018/1/012014.
- [8] A. Rusdy, "Efektivitas Ekstrak Nimba Dalam Pengendalian Ulat Grayak (*Spodoptera litura* F.) Pada Tanaman Selada," *J. Floratek*, vol. 4, pp. 41–54, 2009.
- [9] S. Albawi, T. A. M. Mohammed, and S. Alzawi, "Layers of a Convolutional Neural Network," *Ieee*, 2017.
- [10] W. S. Eka Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," *J. Tek. ITS*, vol. 5, no. 1, 2016, doi: 10.12962/j23373539.v5i1.15696.
- [11] Xia JF, Zhao XM, Song J, and Huang DS, "APIS: accurate prediction of hot spots in protein interfaces by combining protrusion index with solvent accessibility," *BMC Bioinformatics*, vol. 11, p. 174, 2010, [Online]. Available: <http://www.biomedcentral.com/1471-2105/11/174>.
- [12] D. Allen Pattillo and D. Allen, "An Overview of Aquaponic Systems: Hydroponic Components Part of the Agriculture Commons," *NCRAC Tech. Bull. North Cent. Reg. Aquac. Cent.*, vol. 19, pp. 1–10, 2017, [Online]. Available: http://lib.dr.iastate.edu/ncrac_techbulletins/19.
- [13] S. Borase, J. Shaikh, and A. Deshpande, "Convolution Neural Networks in Image Processing," vol. 7, no. 7, pp. 604–608, 2020.
- [14] R. Jose, "A Convolutional Neural Network (CNN) Approach to detect face using Tensorflow and Keras," *J. Emerg. Technol. Innov. Res.*, vol. 6, no. 5, pp. 97–103, 2019.
- [15] R. Keshari, M. Vatsa, R. Singh, and A. Noore, "Learning Structure and Strength of CNN Filters for Small Sample Size Training," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 9349–9358, 2018, doi: 10.1109/CVPR.2018.00974.
- [16] K. O. Lauw *et al.*, "Identifikasi Jenis Anjing Berdasarkan Gambar Menggunakan Convolutional Neural Network Berbasis Android," *J. Infra*, vol. 8, no. 2, pp. 37–43, 2020.
- [17] A. Arora, "Leaf Disease Identification using CNN and Raspberry Pi," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 7, no. 11, pp. 415–422, 2019, doi: 10.22214/ijraset.2019.11066.
- [18] I. A. Dahlan, F. Hamami, S. H. Supangkat, and F. Hidayat, "Big Data Implementation of Smart Rapid Transit using CCTV Surveillance," *Proceeding - 2019 Int. Conf. ICT Smart Soc. Innov. Transform. Towar. Smart Reg. ICISS 2019*, pp. 1–5, 2019, doi: 10.1109/ICISS48059.2019.8969830.
- [19] C. Liu and S. Liu, "Tiny Electronic Component Detection Based on Deep Learning," *Proc. 2018 IEEE 3rd Int. Conf. Cloud Comput. Internet Things, CCIOT 2018*, vol. 020002, no. December, pp. 341–345, 2018, doi: 10.1109/CCIOT45285.2018.9032521.
- [20] M. H. Gauswami and K. R. Trivedi, "Implementation of machine learning for gender detection using CNN on raspberry Pi platform," *Proc. 2nd Int. Conf. Inven. Syst. Control. ICISC 2018*, no. Icisc, pp. 608–613, 2018, doi: 10.1109/ICISC.2018.8398872.