



## Penerapan *Convolutional Neural Network Deep Learning* dalam Pendeteksian Citra Biji Jagung Kering

Arum TiaraSari<sup>1</sup>, Emy Haryatmi<sup>2</sup>

<sup>1,2</sup>Magister Teknik Elektro, Pascasarjana Magister Teknologi dan Rekayasa, Universitas Gunadarma

<sup>1</sup>arumtiara4@gmail.com, <sup>2</sup>emy\_h@staff.gunadarma.ac.id\*

### Abstract

*Corn kernels detection can be implemented in industry area. This can be implemented in the selection and packaging the corn kernels before it is distributed. This technique can be implemented in the selection and packaging machine to detect corn kernels accurately. Corn kernel images was used before it is implemented in real-time. The objective of this research was corn kernel detection using Convolutional Neural Network (CNN) deep learning. This technique consists of 3 main stages, the first preprocessing or normalizing the input of corn kernels image data by wrapping and cropping, both modeling and training the system, and testing. The experiment used CNN method to classify images of dry corn kernels and to determine the accuracy value. This research used 20 dry corn kernels images as testing from 80 dry corn kernels images which used in training dataset. The accuracy of detection was dependent from the size of image and position when the image was taken. The accuracy is around 80% - 100% by using 7 convolutional layers and the average of accuracy for testing data was 0,90296. The convolutional layer which implemented in CNN has the strength to detect features in the input image.*

*Keywords: convolution neural network, deep learning, dry corn, image, detection*

### Abstrak

Pendeteksian biji jagung kering dapat diimplementasikan pada dunia industri. Khususnya ketika pemilahan dan pembungkusan biji jagung kering dilakukan sebelum dipasarkan. Saat ini pemilahan dan pembungkusan belum mengimplementasikan deteksi biji jagung kering sehingga terkadang di dalam kemasan biji jagung kering sering terdapat biji lainnya. Metode pendeteksian ini dapat diintegrasikan dengan mesin pemilah dan pembungkus di industri biji-bijian salah satunya untuk mendeteksi biji jagung kering. Untuk mendapatkan proses pendeteksian yang akurat, citra biji jagung kering digunakan sebagai data pada metode *deep learning* sebelum implementasi secara *real-time*. Tujuan dari penelitian ini adalah mendeteksi citra biji jagung kering dengan menerapkan metode *Convolutional Neural Network (CNN) deep learning*. Teknik ini terdiri dari 3 tahap utama, pertama *preprocessing* atau menormalkan data input citra biji jagung dengan melakukan *wrapping* dan *cropping*. Kedua, pembentukan model dan pelatihan sistem, yang terakhir adalah melakukan untuk pengujian sistem. Penelitian menggunakan CNN untuk mengenali citra biji jagung kering dan menentukan nilai akurasinya. Pada penelitian ini digunakan 20 citra biji jagung yang digunakan sebagai *testing data* dari 80 citra biji jagung yang digunakan pada *training dataset*. Nilai akurasi pendeteksian biji jagung kering dipengaruhi oleh ukuran citra dan posisi pengambilan citra dari kamera *smartphone*. Penggunaan 7 *convolutional layer* memberikan nilai akurasi berkisar antara 80% - 100% sehingga nilai rata-rata akurasi *testing data* sebesar 0,90296. Penggunaan *convolutional layer* mampu mendeteksi kekuatan bentuk dari suatu citra.

Kata kunci: *convolution neural network, deep learning, biji jagung, citra, deteksi*

### 1. Pendahuluan

Deteksi objek merupakan salah satu penelitian yang sedang dikembangkan hingga saat ini. Salah satu teknik deteksi objek yang banyak digunakan adalah dengan mengimplementasikan metode *deep learning*. Penggunaan *deep learning* dapat berdasarkan pada beberapa faktor seperti penggunaan data *training* yang

cukup banyak untuk dapat mempelajari karakteristik dari data *training*, menjadikan perkembangan parallel komputer untuk performa yang cukup tinggi dan disain struktur jaringan dan strategi *training* yang berkembang signifikan[1]. Convolutional Neural Network (CNN) merupakan salah satu model dari metode *deep learning*. Setiap lapisan pada CNN dinamakan dengan *feature map*. *Feature map* dari lapisan internal manapun

merupakan citra *multi-channel* yang diinduksi, dimana *pixel* dapat dilihat sebagai suatu spesifik *feature*[2]. Setiap *neuron* dihubungkan dengan sedikit bagian dari *neuron* yang berdekatan yang berasal dari lapisan sebelumnya. Beberapa transformasi dilakukan pada *feature map* seperti *filtering (convolution)* dan *pooling*. Dengan adanya *interleave* antara *convolution* dan *pooling* maka inisial *feature* dibuat dimana dapat disesuaikan dalam pengawasan dengan menambahkan beberapa lapisan yang terhubung penuh sehingga dapat beradaptasi terhadap tugas visual yang berbeda. Berdasarkan tugas yang diberikan, lapisan terakhir menambahkan fungsi aktivasi yang berbeda untuk mendapatkan kondisi probabilitas yang lebih spesifik dari setiap *output neuron*[3].

Pendeteksian objek pada bidang pertanian sudah banyak digunakan. Beberapa penelitian implementasi *deep learning* pada bidang pertanian contohnya digunakan untuk mendeteksi biji kopi [4] untuk menentukan biji kopi terbaik yang dapat dikonsumsi dan mengembangkan sistem pemilihan biji kopi secara otomatis. Penggunaan teknologi *image processing* dan *data augmentation* dilakukan terhadap data yang digunakan. Selanjutnya digunakan metode *deep learning* yaitu CNN untuk menganalisis informasi dari citra kopi dan mengaplikasikan model *training* terhubung dengan IP *camera* sebagai pendeteksiannya. Penelitian ini berhasil memisahkan biji kopi bagus dan jelek dengan rata-rata *false-positive* sebesar 0,1007 dan persentasi deteksi keseluruhan sebesar 93%. Implementasi CNN dalam memprediksi hasil panen dilakukan oleh [5]. Prediksi hasil panen terhadap tanaman jagung dan kedelai digunakan dengan metode CNN-RNN dengan nilai RMSE sebesar 9% dan 8%. Metode ini mampu memprediksi hasil panen dengan tingkat akurasi yang cukup baik.

Penggunaan CNN dengan rata-rata spektrum dan spektrum *pixel-wise* untuk deteksi tiga varietas kacang kedelai telah dilakukan oleh [6]. Model CNN *pixel-wise* menghasilkan performa yang baik dalam memprediksi spektrum *pixel-wise* dan rata-rata spektrum. Dengan meningkatkan jumlah kedelai, maka performa semakin menjadi lebih baik dan akurasi klasifikasi dari setiap varietas lebih dari 90%. Penggunaan jumlah sampel sedikit untuk mengidentifikasi satu varietas kedelai memberikan hasil yang baik ketika model CNN *pixel-wise* diimplementasikan. Pemetaan prediksi juga dihasilkan untuk memperlihatkan hasil klasifikasi dari kedelai. Dengan menggunakan Model spektrum *pixel-wise* dari 60 kedelai memperlihatkan hasil yang sama dengan menggunakan 810 kedelai yang menggunakan rata-rata spektrum.

Penelitian yang dilakukan oleh [7] memanfaatkan *deep learning framework* untuk *transfer learning* prediksi biji jagung dan kedelai dengan menggunakan *feature extractor* yang menghasilkan model baru dinamakan

dengan YieldNet pada area terencil. Berdasarkan hasil pengujian, prediksi biji jagung dan kedelai secara bersamaan mendapatkan tingkat akurasi yang cukup tinggi dibandingkan jika pengujian dilakukan terhadap individual. Dengan memanfaatkan *transfer learning* biji jagung dan kedelai dengan menggunakan *feature extractor*, model ini mampu menurunkan jumlah dari *learning parameters*. Hal ini meringankan proses komputasi namun tetap mendapatkan tingkat akurasi yang tinggi.

Penelitian yang dilakukan oleh [8] membuat model dalam pendeteksian dan penghitungan biji jagung berdasarkan pendekatan *sliding window* CNN untuk deteksi kernel. Selanjutnya *non-maximum suppression (NMS)* digunakan untuk menghilangkan deteksi yang tumpang tindih. *Window* yang mengklasifikasikan kernel diteruskan ke model regresi CNN untuk mencari koordinat dari pusat citra kernel. Berdasarkan hasil pengujian, metode yang dibuat dapat mendeteksi biji jagung dengan baik dengan tingkat kesalahan deteksi yang rendah. Metode ini juga mampu mendeteksi biji jagung dalam tumpukan. Kekurangan dari penelitian ini adalah tidak menggunakan metode deteksi objek populer seperti R-CNN yang cepat dikarenakan dengan menggunakan metode ini membutuhkan citra yang banyak.

Penelitian dengan menggunakan CNN dalam bidang pertanian dilakukan oleh [9] untuk menghitung biji jagung secara *real-time* untuk memaksimalkan panen jagung. Metode yang dibuat dinamakan dengan *DeepCorn*. Pada metode ini juga diimplementasikan *semi-supervised learning*. Berdasarkan hasil pengujian, metode ini mampu memberikan jumlah dari biji jagung dalam berbagai arah. Pengklasifikasian biji jagung dengan menggunakan *deep learning* dilakukan oleh [10] dengan menggunakan arsitektur *Mask R-CNN* untuk mendeteksi jagung bagus, rusak dan tidak murni. Data set yang digunakan merupakan data dari jagung yang tidak terkena sentuhan dan digunakan sebagai segmentasi *training* dan klasifikasi. Hasil dari pengujian memperlihatkan bahwa akurasi deteksi sangat bagus.

Implementasi metode CNN dalam bidang pertanian juga dilakukan oleh [11] yaitu membuat sistem otomatisasi pendeteksian tomat dengan menggunakan CNN. Dalam penelitian ini menggunakan 3 layer untuk menghasilkan klasifikasi yang lebih baik. *Training dataset* yang digunakan sebanyak 80% dari total *dataset* yang tersedia dan *testing dataset* menggunakan 20%. Hasil yang didapatkan dari sistem ini memiliki tingkat akurasi sebesar 99,67%. Penggunaan CNN dalam bidang pertanian juga dilakukan oleh [12] dengan mengimplementasikannya pada kualitas jamur enoki. Total *dataset* yang digunakan adalah 23000 citra dimana ukuran setiap citra sebesar 1280x1024. Tingkat akurasi yang didapatkan dari penelitian ini sebesar 98,35%. Pengimplementasian CNN lainnya dalam penelitian

bidang pertanian juga dilakukan oleh [13] terhadap tanaman padi. Pendeteksian tanaman padi dilakukan secara *real-time* dari ketinggian 60 m – 100 m dengan masing-masing tingkat akurasi yang dihasilkan adalah 86,5% dan 87,8%. Untuk meningkatkan tingkat akurasi, digunakan *artificial height images* pada penelitian ini sehingga dengan ketinggian yang sama, sistem ini mampu mendeteksi tanaman padi dengan tingkat akurasi 99,6% untuk ketinggian 60 m dan 99,7% untuk ketinggian 100 m.

Penelitian lainnya yang mengimplementasikan metode CNN adalah [14]. Penelitian ini menggunakan beberapa metode *deep learning* seperti RetinaNet, *Faster R-CNN* dan *Cascade R-CNN* untuk memantau perkebunan tanaman kacang. Dari ketiga metode yang digunakan, metode *Cascade R-CNN* memberikan hasil terbaik dengan nilai rata-rata *precision* sebesar 89,6. Metode RetinaNet memberikan nilai rata-rata *precision* sebesar 83,3 dan metode *Faster R-CNN* memberikan nilai rata-rata *precision* sebesar 88,7. Penggunaan CNN untuk mendeteksi penyakit pada daun juga dapat digunakan seperti yang dilakukan oleh [15]. Pada penelitian ini, CNN dan adam *optimizer* digunakan untuk mendeteksi penyakit pada daun tanaman jagung. Jumlah penyakit daun pada tanaman jagung yang dideteksi sebanyak 4 penyakit. Tiga diantaranya berhasil dideteksi dengan tingkat akurasi hingga 98,78%.


Berbagai penelitian yang telah dilakukan mengenai deteksi atau klasifikasi biji jagung kering belum terlihat implementasinya pada dunia industri pemilahan dan pembungkusan biji jagung kering. Pemilahan dan pembungkusan biji jagung kering di dunia industri dirasa perlu mengimplementasikan metode pendeteksian biji jagung kering. Hal ini dikarenakan terkadang ditemukan biji lain selain biji jagung kering dalam satu kemasan biji jagung kering. Biji jagung kering sendiri banyak digunakan salah satunya sebagai bahan makanan seperti *popcorn*. Pentingnya pemilahan dan pembungkusan biji jagung kering dengan metode ini untuk menghindari adanya biji lain pada suatu kemasan biji jagung kering. Sebelum metode *deep learning* diimplementasikan secara langsung pada mesin pemilah dan pembungkus biji jagung kering, perlu dilakukan penelitian terhadap pendeteksian citra biji jagung kering terlebih dahulu dan melihat tingkat akurasi dari deteksi tersebut. Berdasarkan hal tersebut, tujuan dari penelitian ini adalah implementasi *Convolutional Neural Network (CNN) deep learning* untuk mendeteksi citra biji jagung kering berdasarkan citra biji jagung kering.

## 2. Metode Penelitian

Tahapan penelitian yang dilakukan terdiri dari 3 tahap, yaitu pengumpulan data, *preprocessing* dan pemilihan citra dan pemrosesan serta implementasi metode CNN.

### 2.1 Pengumpulan Data

Tahap pertama adalah pengumpulan data dan prosesnya dapat dilihat pada gambar 1. Dalam melakukan pendeteksian biji jagung, *dataset* citra biji jagung dibutuhkan. Data citra biji jagung diambil dari kamera *smart phone* sebanyak 100 foto dalam format jpg dan dikumpulkan pada satu folder khusus.




Gambar 1. Pengumpulan Data

Data yang telah didapatkan selanjutnya dikonversi menjadi data citra biji jagung dengan ukuran yang bervariasi. Seluruh citra biji jagung tersebut digunakan dalam proses *training* dan *testing*.

### 2.2 Preprocessing dan Pemilihan Citra Biji Jagung

Tahap selanjutnya adalah *preprocessing* dan pemilahan citra biji jagung seperti terlihat pada gambar 2.



Gambar 2. Preprocessing dan Pemilihan Citra Biji Jagung

Seluruh citra yang telah didapatkan dari kamera *smart phone* dianalisis satu persatu untuk memastikan bahwa citra yang digunakan adalah citra biji jagung. Citra biji jagung sebanyak 100 citra dimasukkan dalam satu folder khusus. Selanjutnya menetapkan persentase banyaknya citra yang digunakan sebagai *training data* dan *testing data*. *Training data* yang digunakan sebesar 80% dari total citra biji jagung dan *testing data* yang digunakan adalah 20%. Selanjutnya dilakukan pemilihan citra secara acak sebanyak 80 citra untuk *training data* dan 20 citra untuk *testing data*. Data citra yang digunakan sebagai training data diberi pelabelan angka 1 sampai dengan 80. Contoh pelabelan dapat dilihat pada gambar 3.


Supaya data dapat diinputkan ke dalam *library*, sebelum membuat model, perlu dilakukan perubahan ke dalam skema *one hot encoding*. Hal ini dilakukan untuk mengubah fitur kategori ke format yang berfungsi lebih baik dalam pengklasifikasian. Selanjutnya, data diolah menjadi model CNN.

### 2.3 Proses dan Metode CNN

Proses inti dari penelitian ini yang terdiri dari training dataset, CNN training, CNN model, testing data dan evaluasi dari citra dapat dilihat pada gambar 4.



Gambar 3. Contoh Pelabelan Citra Biji Jagung



Gambar 4. Proses dan Metode CNN Pada Citra Biji Jagung Kering

### 2.3.1 Training Dataset


Pendeteksian biji jagung membutuhkan *dataset* citra biji jagung sebagai *dataset* pelatihan. Pelatihan dataset diambil dengan mengambil foto sendiri dari kamera *smart phone*. Citra untuk pelatihan *dataset* menggunakan format citra jpg. Total citra yang digunakan adalah 80 citra biji jagung dimana keseluruhan citra biji jagung kering ini digunakan sebagai data training. Ukuran citra diubah berdasarkan *format* algoritma klasifikasi CNN untuk menghasilkan citra yang lebih baik. *Dataset* pelatihan diberi label yang sesuai sebagai bagian dari nama berkas. Contoh citra biji jagung kering ditunjukkan pada gambar 5.



Gambar 5. Gambar Biji Jagung Kering

### 2.3.2 CNN Training


Setelah diberikan label maka citra akan diolah dengan model CNN yang digunakan dimana merupakan pelatihan dengan 7 lapisan yang tersembunyi (*convolutional layer*). Kerja dari 7 lapisan tersebut adalah sebagai berikut: 6 lapisan jaringan, dengan arsitektur yang sama setiap lapisan jaringannya diikuti dengan elemen *non-linear* ReLU dan sebuah MaxPooling 2 x 2. Kriteria untuk memilih angka pada lapisan jaringan berhubungan dengan konvergen dari tingkat kesalahan selama proses pembelajaran. Dalam kasus ini, dibutuhkan 5 atau 6 iterasi (dengan menaikkan angka lapisan jaringan) untuk menemukan kalkulasi. Arsitektur pelatihan CNN yang digunakan pada penelitian ini dapat dilihat pada gambar 6. Penurunan gradien stokastik digunakan untuk pelatihan CNN menggunakan kumpulan data acak yang kecil dan sama untuk setiap fase belajar berulang.



Gambar 6. Arsitektur kerja pelatihan CNN

### 2.3.3 CNN Generated Model

Setelah tahap pelatihan dilakukan, model yang dihasilkan oleh CNN disimpan untuk memuat data yang telah dipertimbangkan. Model CNN kemudian dapat digunakan kapan saja dengan data percobaan untuk mengevaluasi keakuratan model. Arsitektur CNN yang lengkap untuk klasifikasi biji jagung menambah satu lapisan jaringan koneksi penuh ke arsitektur pelatihan yang dapat dilihat pada gambar 7. Sebagai pengklasifikasi akhir, digunakan fungsi *Softmax*.



Gambar 7. Arsitektur lengkap CNN untuk klasifikasi

### 2.3.4 Testing Data

Setelah model CNN dihasilkan, maka selanjutnya adalah melakukan *testing* terhadap model tersebut dengan cara menguji/meng-evaluasi model yang telah *training*kan. Pengujian menggunakan 20 data citra biji jagung. Penelitian ini menggunakan parameter pengaturan training yang sama yaitu nilai maksimum *epoch* adalah

100 dan ukuran *mini batch* adalah 5. Pengaturan parameter layer convolution2d Layer menggunakan ukuran panjang dan lebar *filter* 2 dan angka filter 10 serta maxPooling2dLayer dengan ukuran *pool* 2 dan *Stride* 2. Data percobaan merupakan set dari citra biji jagung Data ini merupakan masukan bagi model yang dihasilkan CNN untuk memprediksi tingkat akurasi pada citra yang kemungkinan merupakan kemiripan citra dari biji jagung.


2.4 Evaluation of Image Classified

Tahap terakhir adalah mengevaluasi citra yang telah diklasifikasi melalui hasil tingkat akurasinya dan kesesuaian citra biji jagung. Pengujian dilakukan untuk membandingkan nilai akurasi dengan konsentrasi penambahan jumlah lapisan pada arsitektur CNN. Penambahan ini tidak merubah nilai parameter yang telah ditentukan sebelumnya seperti nilai *epoch* dan *learning rate*. Nilai akurasi yang didapatkan dari penjumlahan nilai akurasi setiap convolutional layer. Convolutional layer yang digunakan dalam penelitian ini adalah 7 layer sehingga nilai akurasi didapatkan setelah layer ke 7 yang merupakan rata-rata dari nilai akurasi ada setiap layernya.

Untuk studi ini, data percobaan merupakan masukan untuk model yang dihasilkan sehingga dapat mengidentifikasi citra biji jagung sebagai keluaran. Aplikasi yang digunakan dalam penelitian ini adalah kerangka kerja dari TensorFlow. TensorBoard merupakan histogram dari TensorFlow dan alat untuk visualisasi grafik yang mempermudah untuk pemahaman dari parameter model dan variasi dari waktu ke waktu.

3. Hasil dan Pembahasan

Grafik hasil *training* yang telah didapatkan dari model CNN dapat dilihat pada gambar 8 dan 9.



Gambar 8. Grafik Akurasi Proses Learning

Pada gambar 8 dimana sumbu x sebagai *Epoch* sedangkan sumbu y sebagai nilai akurasinya. Di mana nilai akurasi untuk data validasi cenderung stabil sehingga model ini baik dan optimal. menunjukkan perbedaan akurasi antara hasil training dan validasi.

Sedangkan nilai akurasi train sebesar 0.9 dan mulai *epoch* ke 0 cenderung stabil dan terus meningkat.



Gambar 9. Grafik Loss Proses Learning

Gambar 9 merupakan grafik *loss* dari proses *learning* dimana sumbu x sebagai *Epoch* sedangkan sumbu y sebagai *Loss* dengan nilai akurasinya. Nilai kesalahan untuk data training dimulai pada kisaran 2,0 pada *epoch* 0 sedangkan data validasi cenderung turun secara signifikan.

Nilai akurasi dari proses *training* dan *testing* menggunakan metode CNN dari citra yang telah ditentukan sebelumnya dapat dilihat pada Tabel 1.

Tabel 1. Tabel Hasil Akurasi Klasifikasi Training dan Testing Data

Data	Jumlah Data	Akurasi (%)
Training	80	94
Testing	20	90

Nilai akurasi yang didapatkan dari training data sebesar 94% dan nilai akurasi dari testing data sebesar 90%. Citra yang digunakan pada proses testing serta masing-masing akurasinya dapat dilihat pada Tabel 2. Citra yang ditampilkan dalam tabel tersebut tidak memiliki kriteria khusus.

Tabel 2. Tabel Hasil Pengujian Biji Jagung Kering

Citra (jpg)	Ukuran (pixel)	Akurasi	Akurasi (%)
	225x225	0,9927	99,72
jagung1			
	299x168	0,9780	97,80
jagung4			
	298x169	0,9984	99,84
jagung5			

	271x186	0,9987	99,87		500x500	0,9912	99,12
jagung10				jagung79			
	338x149	0,100	100		252x198	0,8867	88,67
jagung15				jagung81			
	357x141	0,9030	90,30		255X255	0,9050	90,50
jagung16				jagung85			
	200x200	0,9968	99,68		627x627	0,9238	92,38
jagung19				jagung87			
	3024x4032	0,8559	85,59		500x333	0,9830	98,30
jagung30				jagung88			
	4032x3024	0,8906	89,06		275x183	0,9962	99,62
jagung31				jagung98			
	650x433	0,9005	90,05		633x415	0,9991	99,91
jagung73				jagung96			
	1300x1221	0,8041	80,41				
jagung74							
	488x402	0,9871	98,71				
jagung77							
	287x338	0,9639	96,39				
jagung78							

Tabel 2 memperlihatkan bahwa ukuran gambar dan posisi pengambilan citra mempengaruhi nilai akurasi yang didapatkan. Sebagai contoh, citra jagung74.jpg memiliki nilai akurasi yang paling kecil yaitu 80,41% dengan ukuran 1300x1221 sedangkan citra jagung15.jpg memiliki nilai akurasi yang paling tinggi yaitu 100% dengan ukuran 338x149. Contoh citra biji jagung yang berada dalam suatu wadah dan dikelilingi oleh biji jagung kering terlihat pada citra jagung88.jpg memiliki tingkat akurasi sebesar 98,30% dengan ukuran 500x333. Contoh citra biji jagung yang diambil dari hamparan biji jagung seperti pada citra jagung98. jpg menghasilkan tingkat akurasi sebesar 99,62% dengan ukuran citra sebesar 275x183. Dari 20 citra biji jagung yang digunakan sebagai *testing data* seperti terdapat pada tabel 2 memperlihatkan tingkat akurasi yang pendeteksian citra biji jagung diatas 80%. Rata-rata nilai akurasi yang dihasilkan dari pendeteksian citra biji jagung kering

dengan menggunakan *testing data* adalah 0,90296. Hal ini membuktikan bahwa sistem yang dibuat mampu mendeteksi biji jagung kering yang diambil dari berbagai sisi dan berbagai bentuk ukuran yang berasal dari citra kamera *smartphone*.

#### 4. Kesimpulan

Pendeteksian biji jagung kering dengan menggunakan CNN berhasil dilakukan. *Dataset* pada *training* yang digunakan sebanyak 80 data citra biji jagung kering. Pengujian menggunakan 20 citra biji jagung kering dimana seluruh citra diambil dari kamera *smartphone* dengan jumlah *epoch* sebanyak 100. Nilai akurasi pendeteksian biji jagung kering dipengaruhi oleh ukuran citra dan posisi pengambilan citra dari kamera *smartphone*. Dengan menggunakan 7 *convolutional layer* nilai akurasi yang dihasilkan berkisar antara 80% - 100%. Rata-rata nilai akurasi yang dihasilkan dari *testing data* adalah 0,90296. Penggunaan *convolutional layer* mampu mendeteksi kekuatan bentuk dari suatu citra. Jika dibandingkan dengan penelitian lain dalam mendeteksi biji jagung kering dimana menggunakan metode yang lebih baik yaitu Mask R-CNN tanpa menggunakan modul klasifikasi, hasil yang didapatkan dalam penelitian ini lebih baik. Hal ini membuktikan bahwa sistem berhasil mendeteksi biji jagung kering. Penelitian ini dapat dikembangkan dengan mengimplementasikan pendeteksian secara *real-time*, penghitungan jumlah biji jagung kering dan penentuan biji jagung kering kualitas baik sehingga dapat diimplementasikan dalam dunia industri pemilahan dan pembungkusan biji jagung kering.

#### Daftar Rujukan

- [1] Z. Zhao, P. Zheng, S. Xu, and X. Wu, "Object Detection With Deep Learning: A Review," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, Nov. 2019.
- [2] A. Khan, A. Sohail, U. Zahoora, and A. S. Qureshi, "A Survey of The Recent Architectures of Deep Convolutional Neural Networks," *Artif. Intell. Rev.*, vol. 53, no. 8, pp. 5455–5516, Apr. 2020.
- [3] B. B. Traoré, B. K. Fogueu, and F. Tangara, "Deep Convolution Neural Network for Image Recognition," *Ecol. Informatics, Elsevier*, vol. 48, pp. 257–268, Nov. 2018.
- [4] Y.-C. Tsai, "Smart Agriculture: Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network," *IET Smart Cities*, vol. 2, no. 4, pp. 167–172(5), Dec. 2020.
- [5] S. Khaki, L. Wang, and S. V. Archontoulis, "A CNN-RNN Framework for Crop Yield Prediction," *Front. Plant Sci.*, vol. 10, no. January, pp. 1–14, Jan. 2020.
- [6] S. Zhu *et al.*, "Identification of Soybean Varieties Using Hyperspectral Imaging Coupled with Convolutional Neural Network," *Sensors*, vol. 19, no. 19, pp. 1–15, Sept. 2019.
- [7] S. Khaki, H. Pham, and L. Wang, "YieldNet: A Convolutional Neural Network for Simultaneous Corn and Soybean Yield Prediction Based on Remote Sensing Data," *bioRxiv*, pp. 1–13, Jan. 2020.
- [8] S. Khaki, H. Pham, Y. Han, A. Kuhl, W. Kent, and L. Wang, "Convolutional Neural Networks for Image-Based Corn Kernel Detection and Counting," *Sensors*, vol. 20, no. 9, pp. 1–16, May. 2020.
- [9] S. Khaki, H. Pham, Y. Han, A. Kuhl, W. Kent, and L. Wang, "DeepCorn: A Semi-Supervised Deep Learning Method for High-Throughput Image-Based Corn Kernel Counting and Yield Estimation," *Knowledge-Based Syst.*, vol. 218, pp. 1–15, Apr. 2021.
- [10] H. O. Velesaca, R. Mira, P. L. Suárez, C. X. Larrea, and A. D. Sappa, "Deep Learning based Corn Kernel Classification," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2020, pp. 294–302.
- [11] P. Das and J. P. S. Yadav, "Automated Tomato Maturity Grading System using CNN," in *2020 International Conference on Smart Electronics and Communication (ICOSEC)*, 2020, pp. 136–142.
- [12] J. Dong and L. Zheng, "Quality Classification of Enoki Mushroom Caps Based on CNN," in *2019 IEEE 4th International Conference on Image, Vision and Computing (ICIVC)*, 2019, pp. 450–454.
- [13] K. Murata, A. Ito, Y. Takahashi, and H. Hatano, "A Study on Growth Stage Classification of Paddy Rice by CNN using NDVI Images," in *2019 Cybersecurity and Cyberforensics Conference (CCC)*, 2019, pp. 85–90.
- [14] M. T. Pratama *et al.*, "Deep Learning-based Object Detection for Crop Monitoring in Soybean Fields," in *2020 International Joint Conference on Neural Networks (IJCNN)*, 2020, pp. 1–7.
- [15] K. P. Panigrahi, A. K. Sahoo, and H. Das, "A CNN Approach for Corn Leaves Disease Detection to support Digital Agricultural System," in *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)(48184)*, 2020, pp. 678–683.