

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Berdasarkan Penelitian sebelumnya beberapa literatur review.

Tabel 2.1 Penelitian terdahulu

No.	Penulis	Judul	Metode	Hasil
1	Risman Hadi, Ramaditia Dwiyanaputra, Pahrul Irfan	Implementasi LeNet-5 dan MobileNet-V2 untuk Klasifikasi Kematangan Buah Cabai Berbasis Computer Vision	Lenet-5 dan MobileNet- V2	Model Lenet-5 menunjukkan performa yang lebih stabil dalam klasifikasi kematangan cabai dengan akurasi 99%, sementara MobileNet-V2 mencapai 100% namun mengalami overfitting pada epoch ke-100. Grafik Lenet-5 menunjukkan kestabilan akurasi validasi sejak awal, sedangkan MobileNet-V2 cenderung tidak seimbang antara training dan validasi.

2	Najihah Mohd Hussin, Muhammad Noorazlan Shah Zainudin, Wira Hidayat Mohd Saad, Muhammad Raihaan Kamarudin, Sufri Muhammad, Muhd Shah Jehan Abd Razak	Chili fruits maturity estimation using various convolutional neural network architecture neural network architecture	AlexNet, Inception ResNet v2, ResNet-50	AlexNet dengan optimizer ADAM dan learning rate 0.0001 mencapai akurasi tertinggi sebesar 97,88%, sedangkan dengan SGDM hanya mencapai 85,89%. Inception ResNet v2 dan ResNet-50 juga menunjukkan akurasi tinggi dengan kedua optimizer, meskipun sedikit di bawah AlexNet. Secara keseluruhan, seluruh arsitektur mencapai akurasi di atas 95% dan training loss di bawah 0,1 saat menggunakan ADAM dengan learning rate rendah.
3	Gamma Wira Wibowo1, Edy Mulyanto	Classification of Avocado Ripeness	CNN dengan 15 lapisan	Setelah sepuluh kali pengujian, penelitian ini mencapai akurasi

		Levels Using CNN Method	90%. Dari 18 pengujian klasifikasi, hanya dua prediksi yang salah. Menunjukkan perbedaan visual alpukat mentah, matang, dan busuk, terutama pada nilai piksel warna. Pengujian pada alpukat Badami menunjukkan enam percobaan akurat sesuai tingkat kematangan buah yang diberikan.
--	--	-------------------------	---

2.2 Cabai

Cabai atau paprika (*Genus Capsicum*) merupakan tanaman herba dalam famili *Solanceae*[21]. Tumbuhan ini berasal dari beberapa daerah Amerika Tengah dan Amerika Selatan dan kini tersebar luas ke berbagai benua seperti Eropa, Afrika, Asia. Dalam genus *Capsicum* terdapat beberapa spesies utama yang dibudidayakan, antara lain *C. annuum* (cabai besar), *C. chinense*, *C. frutescens* (cabai rawit), *C. baccatum*, dan *C. Pubescens*[22].

Cabai merupakan salah satu komoditas hortikultura yang unggul di Indonesia. Sebagai sayuran dari kelompok *Capsicum*, cabai salah satu tanaman yang banyak dibudidayakan di Indonesia[23]. Memiliki permintaan yang banyak terhadap permintaan domestik yang terus meningkat, menjadikan cabai sumber pendapatan penting bagi petani hortikultura dan bumbu utama dalam berbagai masakan khas Indonesia[24].

2.3 Kematangan Cabai

Kematangan cabai dapat didefinisikan sebagai tahap perkembangan buah yang ditandai perubahan warna dari hijau ke merah, tekstur juga mengalami perubahan yang awalnya keras lama kelamaan menjadi lunak. Peningkatan vitamin C secara signifikan pada cabai sangat matang menunjukkan korelasi antara kematangan dengan kualitas nutrisi. Parameter warna diukur melalui analisa ruang warna YCbCr, di mana nilai Cb (110–127) dan Cr (135–166) menjadi indikator utama untuk mengklasifikasikan tingkat kematangan menjadi setengah matang, matang, dan sangat matang[25].

Cabai rawit pada tahap mentah ditandai dengan warna hijau pada buahnya dan tekstur masih keras. Cabai pada fase ini umumnya belum mengalami proses kematangan, sehingga rasa pedasnya dan nutrisinya masih berkembang. Menurut Edowai *et al.*, pada tahap mentah cabai rawit disebut “tingkat kematangan muda (cabai rawit berwarna hijau)” yang dipanen pada hari tertentu[26].

Cabai rawit setengah matang berada di fase mentah dan matang penuh, buahnya mulai berwarna tidak seperti waktu kondisi mentah. Pada fase ini umumnya cabai berwarna hijau kekuningan atau hijau kemerahan, dan teksturnya mulai sedikit lunak. Edowai *et al.* mencatat bahwa pada tahap ini cabai rawit berstatus “setengah matang (cabai rawit berwarna hijau kemerahan)” yang menunjukkan perubahan warna dari hijau menuju kemerahan[26].

Pada tahap matang, cabai rawit ditandai oleh warna buah yang merah cerah dan teksturnya mulai lebih lunak dibandingkan fase sebelumnya. Warna merah pada cabai matang munjukan bahwa cabai tersebut sudah masuk fase siap panen. Edowai *et al.* menyebutkan bahwa cabai rawit pada fase matang berwarna merah, yaitu “matang (cabai rawit berwarna merah)”[26].

Tahap busuk adalah kondisi lanjutan pasca kematangan ketika buah cabai mulai membusuk atau mengalami kerusakan pada luarnya. Buah cabai busuk ditandai dengan perubahan warna menjadi kehitaman, dan tekstur lunak berair. Liantoni dan Annisa, dalam studi klasifikasi kematangan cabai rawit, menganggap fase busuk sebagai kategori tersendiri, di mana dataset penelitian mencatat adanya “7 cabai busuk”[27].

2.4 Penghapusan Latar Menggunakan GrabCut dan U²-Net

Penghapusan latar belakang (*background removal*) adalah salah satu tahap pada *pre-processing* citra, khususnya untuk meningkatkan akurasi dalam sistem klasifikasi berbasis *computer vision*. Latar belakang yang kompleks dapat menyebabkan noise atau informasi yang tidak relevan dalam proses ekstraksi fitur, sehingga dapat mengganggu performa model klasifikasi. Oleh karena itu, penghapusan latar bertujuan untuk mengekstraksi objek utama dari citra agar model hanya mempelajari fitur yang signifikan.

Grabcut merupakan algoritma segmentasi gambar yang berbasis teori graf yang populer karena performanya yang efektif dalam memisahkan objek *foreground* dari *background* dengan interaksi pengguna yang minimal. Metode ini diperkenalkan sebagai pengembangan dari algoritma *Graph Cuts* oleh Rother et al. Dan didasarkan pada teori *Markov Random Field* serta algoritma *max-flow/min-cut* untuk mengoptimalkan energi dengan baik[28]. Dalam algoritma ini, pengguna memberikan input berupa sebuah kotak yang dijadikan pembatas untuk menandai area *foreground*. GrabCut menggunakan *Gaussian Mixture Models (GMM)* untuk memodelkan distribusi pixel pada *foreground* dan *background*. GMM digunakan untuk membentuk *regional term*, sedangkan *boundary term* dihitung berdasarkan jarak *Euclidean* antar piksel bertetangga[28].

Proses segmentasi dilakukan secara iteratif dengan parameter GMM diperbarui dan fungsi energi diminimalkan menggunakan metode *min-cut/max-flow*. Pendekatan probabilistik dari GMM memungkinkan *GrabCut* melakukan estimasi piksel ke *foreground* atau *background* lebih akurat dibandingkan metode *thresholding* tradisional[28]. Menurut penelitian oleh Wang et al., meskipun unggul dalam banyak kasus, tetapi *GrabCut* memiliki keterbatasan terutama menangani gambar atau citra dengan batas objek yang kabur atau kompleksitas tinggi[28]. Selain itu, *GrabCut* juga tergantung pada inisialisasi yang tetap dari pengguna jika *input bounding box* tidak tepat akan menghasilkan segmentasi yang kurang optimal[28].

U²-Net merupakan arsitektur *neural network* yang dirancang untuk mendeteksi objek menonjol (*Salient Object Detection, SOD*). Model ini diperkenalkan oleh Qin

et al. Sebagai solusi terhadap keterbatasan metode deteksi salien berbasis backbone klasifikasi gambar seperti VGG yang kurang mampu menangkap detail lokal dan kontras global[19]. U²-Net dirancang dengan struktur nested U-Net, yaitu arsitektur dua tingkat yang berbentuk U dalam U yang memanfaatkan *Residual U-blocks* (RSU) yang digunakan untuk mengekstraksi fitur lokal dan global dari berbagai skala[19]. U²-Net dilatih menggunakan dataset DUTS-TR, bagian dari dataset DUTS, yang berisi 10.553 citra dan banyak digunakan dalam penelitian *salient object detection*. Melalui augmentasi *flipping horizontal*, jumlah data pelatihan meningkat menjadi 21.100 citra[19]. Keunggulan arsitektur ini terletak pada efisiensi dan fleksibilitasnya, meskipun arsitektur dapat mempertahankan resolusi yang tinggi dan memiliki *overhead* komputasi yang rendah karena sebagian operasi dilakukan pada fitur yang sudah telah didownsampling[19]. Menurut penelitian Qin et al., meskipun desain RSU memungkinkan untuk melakukan fitur multi-skala, kompleksitas struktur nested dapat menimbulkan tantangan implementasi di lingkungan nyata terutama pada perangkat yang memiliki sumber daya yang terbatas[19].

2.5 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis *neural network* tiruan yang sangat efektif dalam menyelesaikan beberapa tugas tentang pengolahan sebuah citra, seperti klasifikasi atau deteksi objek. Menurut Yamashita et al., CNN dirancang secara otomatis dan adaptif untuk mempelajari sebuah hierarki spesial dan fitur-fitur melalui proses dengan memanfaatkan lapisan-lapisan utama seperti *convolution layer*, *pooling layer*, dan *fully connected layer*[29]. Kemampuan CNN dalam mengekstraksi fitur dari citra sangat menjadikannya metode unggulan yang banyak diterapkan di beberapa bidang, termasuk radiologi dan pertanian digital[29].

CNN telah diterapkan dalam penelitian tentang klasifikasi tingkat kematangan cabai. Penelitian oleh Hendrawan et al., menggunakan empat arsitektur CNN *pre-trained*, yaitu *GoogLeNet*, *ResNet50*, *SqueezeNet*, dan *AlexNet*, untuk mengklasifikasikan cabai besar hijau berdasarkan tingkat kematangannya. Model *GoogLeNet* yang dioptimasi dengan menggunakan SGDm dengan nilai *learning Rate* sebesar 0.00005 berhasil memperoleh akurasi tertinggi sebesar 94,89% pada

tahap pelatihan dan validasi. Sementara itu, arsitektur SqueezeNet yang dilatih menggunakan algoritma RMSProp dengan learning rate 0.0001 mencatatkan akurasi sebesar 91,27% saat diuji pada data uji[13].

Kelebihan CNN pada kemampuannya dalam mengekstraksi fitur secara otomatis tanpa teknik manual dan efisiensinya dalam mengenali pola visual yang kompleks. CNN juga memiliki performa tinggi dalam beberapa uji coba pada klasifikasi visual serta dapat diintegrasikan dengan kamera digital untuk deteksi realtime. Namun, menurut Hendrawan et al. (2021), CNN memiliki beberapa kelemahan, antara lain membutuhkan jumlah data pelatihan yang besar, memerlukan sumber daya komputasi yang tinggi, serta membutuhkan waktu pelatihan yang relatif lama. Sebagai ilustrasi, dalam penelitian tersebut, pelatihan menggunakan arsitektur ResNet50 memakan waktu rata-rata 358 menit, GoogLeNet sekitar 154 menit, sedangkan AlexNet hanya membutuhkan waktu sekitar 78 menit[13].

2.6 Evaluasi Model

Evaluasi model merupakan tahapan penting dalam proses klasifikasi citra untuk menilai sejauh mana model mampu mengidentifikasi kelas dengan akurasi yang tinggi. Menurut Yamashita et. al.[29], evaluasi dilakukan seperti menggunakan metrik seperti akurasi, precision, recall, dan F1-score untuk memberikan gambaran menyeluruh terhadap performa model klasifikasi.

2.6.1 Akurasi

Akurasi merupakan salah satu metrik evaluasi yang paling umum digunakan tugas klasifikasi citra. Metrik ini mengukur proporsi jumlah prediksi yang benar pada kelas positif (*True Positive*) dan kelas negatif (*True Negative*). Nilai akurasi yang tinggi menunjukkan bahwa model memiliki performa yang baik secara keseluruhan, meskipun dalam beberapa kasus seperti data tidak seimbang, akurasi saja tidak cukup menggambarkan performa model secara adil.

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

Dimana :

- TP = True Positive
- TN = True Negative
- FP = False Positive
- FN = False Negative

Dalam kasus klasifikasi multikelas, nilai akurasi diperoleh dengan menjumlahkan seluruh prediksi yang benar dari semua kelas dan membaginya dengan total jumlah data uji. Kamilaris dan Prenafeta-Boldú[10] menjelaskan bahwa akurasi merupakan metrik evaluasi utama yang banyak digunakan dalam klasifikasi citra pertanian menggunakan CNN.

2.6.2 Precision

Precision merupakan metrik evaluasi yang digunakan untuk mengukur seberapa tepat model dalam memprediksi kelas positif. Metrik ini menjadi sangat penting ketika kesalahan prediksi positif palsu (*false positive*) harus diminimalkan, misalnya dalam klasifikasi kematangan cabai busuk yang tidak boleh salah dikenali sebagai matang. *Precision* menghitung proporsi data yang benar-benar relevan di antara seluruh data yang diprediksi sebagai positif oleh model.

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

Dimana :

- TP = True Positive
- FP = False positive

Menurut Upadhyay et al.[30], *precision* menjadi aspek krusial dalam sistem deteksi penyakit tanaman berbasis *deep learning* karena mendukung deteksi yang cepat, akurat, dan responsif secara real-time.

2.6.3 Recall

Recall merupakan metrik evaluasi yang digunakan untuk mengukur

kemampuan model dalam mendeteksi seluruh data yang benar-benar positif. *Recall* dihitung sebagai rasio antara jumlah prediksi positif yang benar (*True Positive*) terhadap total jumlah data positif yang sebenarnya, yaitu kombinasi antara *True Positive (TP)* dan *False Negative (FN)*.

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

Dimana :

- TP = True Positive
- FN = False Negative

Recall menjadi sangat penting pada konteks klasifikasi yang sensitif terhadap kesalahan pengenalan, seperti deteksi penyakit atau kualitas hasil pertanian, di mana melewatkan satu objek positif dapat berakibat serius. Dalam klasifikasi citra pertanian, *recall* membantu memastikan bahwa seluruh buah atau tanaman yang termasuk dalam kelas target berhasil dikenali oleh sistem. Menurut Kamilaris dan Prenafeta-Boldú [10], penggunaan metrik seperti *recall* sangat umum dalam tugas klasifikasi citra pertanian karena dapat memberikan gambaran sejauh mana model mampu menangkap semua kejadian positif, terutama saat menghadapi data yang tidak seimbang. Upadhyay et al. [30] juga menegaskan pentingnya *recall* untuk mendeteksi seluruh kasus penyakit tanaman guna mencegah kesalahan klasifikasi yang dapat merugikan petani dalam pengambilan keputusan.

2.6.4 F1-score

F1-score merupakan metrik evaluasi yang menggabungkan *precision* dan *recall* dalam satu nilai harmonis, khususnya berguna saat distribusi kelas tidak seimbang. Metrik ini dihitung sebagai rata-rata harmonik dari *precision* dan *recall*, sehingga memberikan penilaian yang seimbang antara kemampuan model dalam menghindari *false positive* (melalui *precision*) dan *false negative* (melalui *recall*).

$$f1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

F1-score bernilai tinggi jika precision dan recall sama-sama tinggi. Namun jika salah satu rendah, maka nilai F1-score juga akan menurun drastis. F1-score disebut sebagai metrik penting yang sering digunakan dalam sistem klasifikasi berbasis deep learning di sektor pertanian, karena mampu memberikan evaluasi performa yang lebih adil ketika data antar kelas tidak seimbang[30].

