

Evaluasi *Optimizer* pada *Residual Network* untuk Klasifikasi Klon Teh Seri GMB Berbasis Citra Daun

KOREDIANTO USMAN¹, NOR KUMALASARI CAECAR PRATIWI¹, NUR IBRAHIM¹, HERI SYAHRIAN², VITRIA PUSPITASARI RAHADI²

¹Fakultas Teknik Elektro, Universitas Telkom, Bandung, Indonesia

²Pusat Penelitian Teh dan Kina Gambung, Bandung, Indonesia

Email: caecarnkcp@telkomuniversity.ac.id

Received 12 Maret 2021 | Revised 18 Mei 2021 | Accepted 15 Juni 2021

ABSTRAK

Komoditas teh berperan strategis terhadap pertumbuhan perekonomian Indonesia, salah satunya dari teh klon Gambung (GMB). Klon GMB memiliki beberapa karakter khas, dengan tingkat kemiripan morfologi yang sangat tinggi. Hal ini berdampak pada proses pengenalan klon GMB dilakukan melalui pengamatan visual oleh tenaga ahli sangat rentan terhadap kesalahan identifikasi. Sehingga, dalam penelitian ini dirancang suatu sistem identifikasi terhadap 11 klon teh seri GMB (GMB-1 hingga GMB-11) dengan menggunakan arsitektur ResNet101. Evaluasi sistem akan dilakukan dengan membandingkan tujuh algoritma optimizer yang berbeda, yaitu; Adam, SGD, RMSProp, AdaGrad, AdaMax, AdaDelta dan Nadam. Hasil pengujian menunjukkan bahwa Adam dan SGD memberikan nilai rata-rata presisi, recall dan F1-score terbaik. Selain itu, Adam memberikan nilai akurasi yang cenderung stabil sejak iterasi pertama. Metode yang diusulkan memberikan tingkat presisi, recall, F1-score sebesar 96% dan akurasi terbaik sebesar 97%.

Kata kunci: klasifikasi daun teh, seri Gambung (GMB), CNN, ResNet101

ABSTRACT

Gambung (GMB) tea is one of the tea commodities that plays a key role in Indonesia's economic development. GMB clones have a number of distinguishing characteristics, including a high degree of morphological similarities. This has an impact on the process of identifying GMB clones through visual observation by experts who are subject to mistakes. In this study, ResNet101 architecture was used to create an identification scheme for 11 tea clones from the GMB series (GMB-1 to GMB-11). System evaluation will be carried out by comparing seven different optimizer; Adam, SGD, RMSProp, AdaGrad, AdaMax, AdaDelta, and Nadam. The test results indicate that Adam and SGD have the highest average accuracy, recall, and f1-score values. Adam also has an accuracy value that has remained consistent since the first iteration. The proposed method provides highest precision, recall, F1-score of 96% and accuracy of 97%.

Keywords: tea leaves classification, GMB series, CNN, ResNet101

1. PENDAHULUAN

Teh menjadi salah satu komoditas ekspor utama bagi Indonesia. Hasil teh Indonesia setidaknya telah diekspor ke sekitar 78 negara dunia. Jumlah penyerapan tenaga kerja perkebunan teh menduduki posisi tertinggi jika dibandingkan komoditas agrobisnis lainnya, mencapai dua juta orang di Indonesia (**Basorudin, dkk, 2019**). Pada tahun 2014 tercatat total luas area perkebunan teh mencapai 121.030 ha yang tersebar di Provinsi Jawa Barat, Jawa Tengah, Sumatera Utara, Sumatera Barat, Jambi, dan beberapa wilayah Indonesia lainnya. Berdasarkan status kepemilikan usaha, perkebunan teh dibedakan menjadi perkebunan besar negara (PBN), perkebunan besar swasta (PBS) dan perkebunan rakyat (PR). Dari total wilayah perkebunan teh, PR menduduki posisi dengan area terluas, mencapai 42,82% dari keseluruhan areal perkebunan teh Indonesia, PBN menduduki posisi kedua dengan cakupan sebesar 33,74%, sedangkan sisanya dipegang oleh PBS hanya 23,44% (**Indarti, 2015**). Tahapan penting untuk mencapai produksi teh yang berkelanjutan (*sustainable tea production*) ialah proses pemilihan bahan tanam yang sesuai. Terhitung sejak tahun 1998, PPTK Gambung, sebagai Pusat Penelitian Teh dan Kina telah memasarkan klon unggul varietas assamika, yaitu GMB-1 sampai dengan GMB-11, dimana klon GMB 7 merupakan klon terunggul jika dilihat dari pencapaian produktivitasnya (**Haq & Karyudi, 2013**). Klon seri GMB memiliki tingkat kemiripan morfologi yang tinggi, hal ini dikarenakan banyaknya kombinasi persilangan dari tetua yang sama sebagai induk dari klon unggul seri GMB tersebut. Karakter morfologi yang dapat membedakan antar jenis klon unggul seri GMB tersebut adalah karakter daunnya. Hingga saat ini karakterisasi dan identifikasi klon-klon unggul seri GMB tersebut dilakukan secara manual oleh tenaga ahli yang terlatih dalam membedakan karakter morfologi daun tersebut secara visual. Proses identifikasi secara visual, selain proses sangat bergantung pada keberasaan tenaga ahli, juga sangat beresiko tinggi terhadap kesalahan pembacaan jenis klon dan akan merugikan dalam rentang waktu yang panjang.

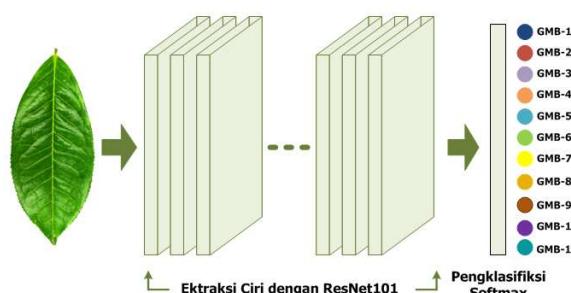
Beberapa peneliti terdahulu telah banyak melakukan perancangan sistem untuk identifikasi dan klasifikasi tanaman berbasis pengolahan citra morfologi daun. Penelitian untuk deteksi terhadap 14 spesies tanaman India yaitu Pipal, Nerium Asoka, Crown, Hibiscus, Mango, Betel, Jackfruit, Cannonball, Neem, Curryleaf, Moringa, Mint dan Lemon dengan metode prewitt, sobel dan laplacian sebagai algoritma *edge detection* serta KNN dan SVM sebagai *classifier*. Hasil penelitian menunjukkan bahwa dengan proses deteksi tepi dan *pre-training* yang tepat, model *Convolutional Neural Network* (CNN) yang diusulkan mampu mendeteksi spesies daun dengan lebih akurat (**Vilasini & Ramamoorthy, 2020**). Penelitian terhadap pengenalan 93 spesies dari lima genus Camellia berdasarkan karakter morfologi daun dilakukan menggunakan metode *Learning Vector Quantization Neural Network* (LVQ-ANN), *Dynamic Architecture for Artificial Neural Networks* (DAN2), dan *Support Vector Machines* (SVM). Hasil penelitian menunjukkan bahwa DAN2 dan SVM mampu melakukan klasifikasi dengan sangat baik, ditunjukkan oleh tingkat akurasi sistem mencapai 97,92% dan 91,11% (**Lu, dkk, 2012**). Sedangkan penelitian untuk klasifikasi klon teh berbasis pengolahan citra daun sangat sedikit ditemukan, beberapa diantaranya adalah penelitian yang berhasil melakukan klasifikasi terhadap lima jenis teh China, yaitu *Anji white tea*, *Biluochun*, *Dahongpao*, *Tieguanyin* dan *Yixing black tea*. *Dataset* yang digunakan berjumlah 125 citra daun, setiap kelas terdiri dari masing-masing 25 citra. Hasil penelitian menunjukkan bahwa sistem yang dirancang memberikan pendekatan yang efektif untuk proses identifikasi teh dengan tingkat kesesuaian varietas mencapai 86,4% (**Chen & Xianqing, 2019**). Penelitian yang secara spesifik membahas klasifikasi klon teh Seri GMB diantaranya adalah identifikasi terhadap tiga kategori klon seri GMB, yaitu GMB-3, GMB-9 dan GMB-11. Total *dataset* citra yang digunakan selama pengujian sistem adalah 1966 citra, yang terbagi menjadi 598 citra untuk GMB-3, 699 citra untuk GMB-9 dan 669 untuk GMB-11. Hasil pengujian diperoleh bahwa arsitektur VGGNet

menghasilkan akurasi sistem yang lebih baik jika dibandingkan arsitektur AlexNet. Namun, jika dilihat dari *loss*, AlexNet menghasilkan *loss* yang lebih stabil. AlexNet mampu melakukan klasifikasi tiga kelas teh seri GMB dengan nilai akurasi sebesar 95,38%, sedangkan akurasi untuk arsitektur VGGNet16 mencapai 96,15%. Selanjutnya adalah penelitian untuk klasifikasi teh seri GMB-1 sampai dengan GMB-11 dengan menggunakan model CNN sederhana (**Rizal, dkk, 2020**). Model CNN yang diusulkan terdiri dari tiga *hidden layers* serta satu *fully connected layer* dan aktivasi *softmax*. *Dataset* terdiri dari *data training* dan *data validasi* yang masing-masing berjumlah 1266 dan 423 citra. Setelah melakukan proses *training* dan *validasi*, diperoleh hasil performasi sistem dengan akurasi sebesar 86% dan *loss* 8,7%. Penelitian untuk mengklasifikasikan daun teh Seri GMB dan Non-GMB juga telah dirancang dengan menggunakan arsitektur CNN sederhana dengan dua *hidden layers* dan sebuah *fully connected layer*, menggunakan fungsi aktivasi *sigmoid* (**Ibrahim, dkk, 2020**). *Dataset* yang digunakan dalam penelitian ini sejumlah 212 citra latih dan 71 citra uji. Setelah dilakukan *epoch* sebanyak 50, diperoleh akurasi sebesar 100% dengan *loss* sebesar 0,0007. Penelitian untuk mengklasifikasikan 6 seri klon teh GMB (GMB-1, GMB-3, GMB-4, GMB-7, GMB-9 dan GMB-11) juga telah dilakukan dengan menggunakan arsitektur ResNet dan DenseNet (**Ramdan, dkk, 2020**). Hasil penelitian menunjukkan bahwa akurasi terbaik sebesar 93,28% diperoleh saat sistem menggunakan arsitektur *Residual Network* dengan Adam *optimizer* dan *learning rate* sebesar 1e-4.

Penelitian (**Ramdan, dkk, 2019**) melaporkan bahwa kinerja sistem yang dirancang sudah sangat baik, tetapi memiliki keterbatasan hanya mampu melakukan klasifikasi ke dalam tiga kelas dari total sebelas kelas yang ada pada teh seri GMB. Sedangkan sistem yang diusulkan oleh (**Rizal, dkk, 2020**) telah mampu melakukan identifikasi terhadap 1689 citra daun dan mengklasifikasikannya ke dalam sebelas kelas klon teh seri GMB, tetapi nilai akurasi yang diperoleh masih di bawah 90%. Sedangkan penelitian (**Ibrahim, dkk, 2020**) telah menghasilkan akurasi 100%, tetapi model terbatas hanya untuk klasifikasi klon GMB dan Non-GMB, dengan jumlah data yang terbatas. Penelitian (**Ramdan, dkk, 2020**) menunjukkan bahwa arsitektur ResNet mampu menghasilkan nilai akurasi yang cukup baik dalam melakukan klasifikasi enam seri klon teh GMB. Sehingga penelitian ini diusulkan untuk melengkapi kekurangan sistem yang telah dirancang pada terdahulunya. Sistem dirancang untuk mengenali sebelas kelas teh pada klon seri GMB dengan menggunakan Arsitektur Residual Network 101 (ResNet 101). Evaluasi akan berfokus pada perbandingan kinerja sistem terhadap penggunaan tujuh algoritma *optimizer* yang berbeda yaitu; Adam, SGD, RMSProp, AdaGrad, AdaMax, AdaDelta dan Nadam.

2. METODOLOGI PENELITIAN

Tujuan penelitian ini adalah merancang sebuah sistem yang mampu melakukan deteksi dan klasifikasi daun tanaman teh seri GMB-1 sampai dengan GMB-11.



Gambar 1. Blok Diagram Sistem

Gambar 1 adalah blok diagram sistem yang akan dirancang. Sistem akan menerima masukan berupa citra daun teh klon GMB, selanjutnya ResNet101 bertanggung jawab dalam proses ekstraksi ciri dan klasifikasi. Keluaran dari sistem ialah daun teh seri GMB yang sudah terklasifikasi menjadi salah satu dari sebelas kelas yang diuji, yaitu; GMB-1, GMB-2, GMB-3 hingga GMB-11.

2.1 Akuisisi Citra

Data yang digunakan sebagai masukan sistem diperoleh dari Pusat Penelitian Teh dan Kina (PPTK) Gambung, Jawa Barat. Total citra keseluruhan sebanyak 3300 citra, dengan masing-masing kelas terdiri dari 300 citra. Setiap citra berukuran 3120×4160 piksel, diambil dengan kamera *smartphone* dengan resolusi 13 MP. *Smartphone* tersebut kami sematkan pada sebuah *casing box* tertutup seperti tampak pada Gambar 2 di bawah. Penggunaan *casing box* berfungsi untuk mengurangi pengaruh dari pencahayaan lingkungan sekitar dan untuk keseragaman latar belakang citra.



Gambar 2. Kotak GT-Id (*Gamboeng Tea Identification*)

Dari total keseluruhan data, 80% (2640 citra) digunakan sebagai data latih dan sisanya (660 citra) digunakan sebagai data uji. Dengan demikian, setiap kelas dari GMB-1 hingga GMB-11 menggunakan data latih masing-masing sejumlah 240 citra, dan data uji masing-masing sejumlah 60 citra. Gambar 3 berikut ini merupakan *sample* daun tanaman teh seri GMB-1 sampai dengan GMB-11 :



Gambar 3. Daun Teh Seri GMB

Klon teh seri GMB-1 hingga GMB-11 memiliki karakter diantaranya: pucuk daun yang lebar dan besar, terdapat gelombang pada permukaan daun, selain itu permukaan daunnya juga mengandung lapisan lilin yang sangat jelas terlihat, jumlah tulang daun antara 8-13 pasang, persentase pucuk peko tinggi, warna daun bervariasi antara hijau agak tua hingga hijau terang, hijau kekuningan, hijau agak muda, hijau sedikit gelap. Klon seri GMB 1, GMB 3, GMB 4, GMB 7, GMB 9, and GMB 11 merupakan seri Gambung yang memiliki karakteristik fisik yang paling mirip satu sama lain. Berdasarkan data dari Pusat Penelitian dan Pengembangan

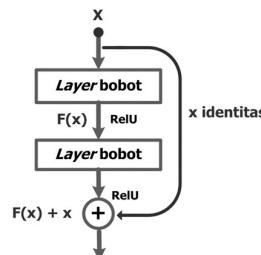
Perkebunan Indonesia, daun teh seri GMB memiliki ciri-ciri sebagai berikut:

Tabel 1. Morfologi Daun Teh Seri GMB

Seri Daun Teh	Ciri-ciri Morfologi
GMB-1	Warna daun hijau muda, ujung daun runcing, tulang daun 18-26 buah atau 9-13 pasang, tepi daun bergerigi besar, tajam tidak beraturan, muka daun bergelombang licin.
GMB-2	Warna daun hijau muda, ujung daun meruncing, tulang daun 20-28 buah atau 10-14 pasang, tepi daun bergerigi agak tumpul dan beraturan, muka daun bergelombang hampir rata.
GMB-3	Warna daun hijau agak tua, ujung daun meruncing, tulang daun 18-26 buah atau 9-13 pasang, tepi daun bergerigi besar dan beraturan, muka daun bergelombang hampir rata.
GMB-4	Warna daun hijau muda, ujung daun meruncing, tulang daun 18-26 buah atau 9-13 pasang, tepi daun bergerigi besar dan beraturan, tepi daun bergerigi tajam, jarang dan beraturan, muka daun bergelombang agak licin.
GMB-5	Warna daun hijau agak kusam, ujung daun meruncing, tulang daun 16-24 buah atau 8-12 pasang, muka daun bergelombang agak rata.
GMB-6	Warna daun hijau agak tua, ujung daun meruncing, tulang daun 22-26 buah atau 11-13 pasang, tepi daun bergerigi tajam, jarang dan beraturan, muka daun bergelombang sangat jelas.
GMB-7	Warna daun hijau terang, ujung daun meruncing, tulang daun 18-24 buah atau 9-12 pasang, tepi daun bergerigi kecil beraturan, muka daun bergelombang agak mengkilat
GMB-8	Memiliki warna daun hijau agak tua, ujung daun meruncing, tulang daun 18-24 buah atau 9-12 pasang, tepi daun bergerigi tajam dan beraturan, muka daun bergelombang kurang jelas
GMB-9	Memiliki warna daun hijau kekuningan, ujung daun meruncing, tulang daun 16-24 buah atau 8-12 pasang, tepi daun bergerigi tajam dan beraturan, muka daun bergelombang
GMB-10	Memiliki warna daun hijau sedikit gelap, ujung daun meruncing, tulang daun 16-26 buah atau 9-13 pasang, tepi daun bergerigi besar, tajam dan beraturan, muka daun bergelombang.
GMB-11	-

2.2 Perancangan Sistem

Pada penelitian kali ini, sistem dirancang untuk mengklasifikasi klon teh seri Gambung (GMB) berbasis citra daun. Sistem dibangun dengan menggunakan pemodelan *Residual Network* (ResNet). ResNet pertama kali diperkenalkan oleh (**He, dkk, 2016**) untuk aplikasi pengenalan citra (*image recognition*). Ide utama dari arsitektur ResNet adalah pemetaan nilai residu yang mudah untuk dioptimasi. ResNet menggunakan koneksi pintas yang akan membentuk *residual block* (**Zhang, dkk, 2018**). Koneksi pintas memungkinkan lapisan sebelumnya dimasukkan langsung ke lapisan yang lebih dalam (**Gulli, dkk, 2019**). Hadirnya koneksi pintas untuk menjawab permasalahan yang sering muncul pada arsitektur CNN dimana nilai akurasi akan mengalami saturasi kemudian menurun dengan cepat ketika jaringan mulai untuk konvergen, seiring bertambahnya kedalaman jaringan (**Hariyani, dkk, 2020**). *Residual block* berfungsi untuk meningkatkan nilai akurasi jaringan seiring dengan meningkatnya kedalaman lapisan yang digunakan (**Wu, dkk, 2019**). Gambar 4 di bawah ini mengilustrasikan *skip connection* pada ResNet.

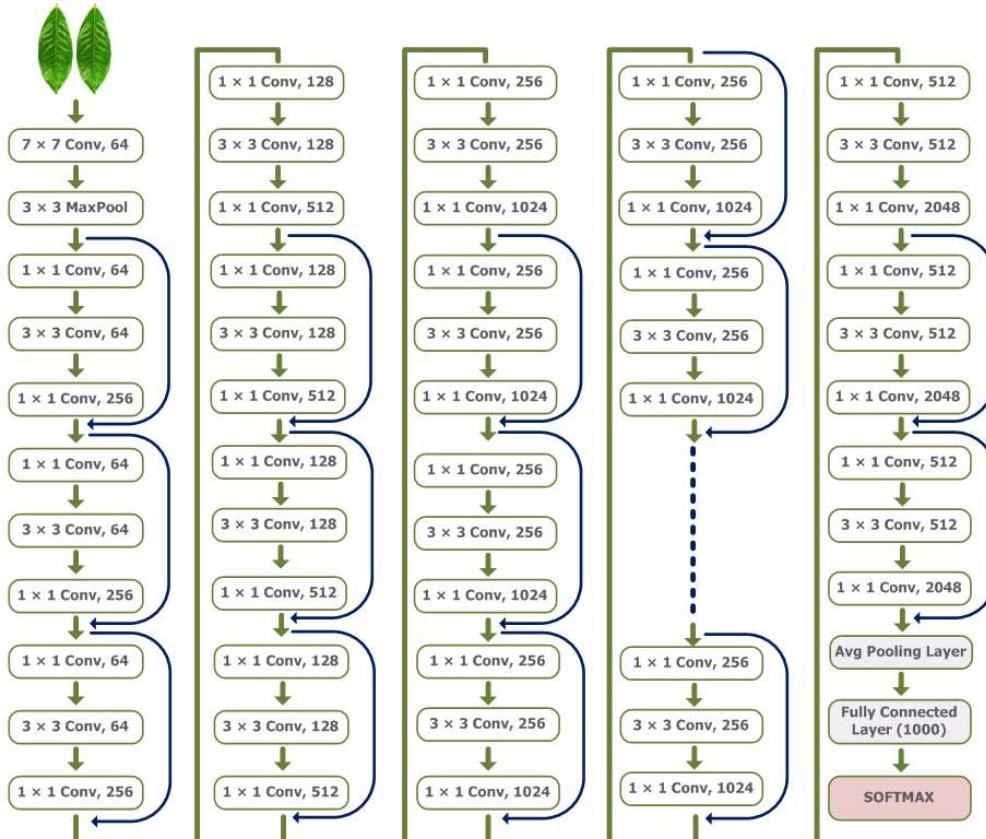


Gambar 4. Ilustrasi Koneksi Pintas pada Arsitektur ResNet

Seperti pada arsitektur *Convolutional Neural Network* (CNN) pada umumnya, arsitektur ResNet juga terdiri dari beberapa jenis *layer*, yaitu diantaranya *convolutional layer*, *pooling layer*, fungsi aktivasi, dan *fully connected layer* (**Indolia, dkk, 2018**). Lapis konvolusi akan melakukan ekstraksi ciri dengan cara melakukan operasi matematis konvolusi antara matriks masukan dengan sebuah *filter*. *Pooling layer* digunakan untuk *down-sampling* atau

mengurangi proses kompleksitas untuk lapisan berikutnya. Pengurangan kompleksitas dilakukan dengan cara membandingkan piksel-piksel yang bertetangga dan menjadikannya satu nilai saja. Nilai yang terpilih ditetapkan sebagai nilai rata-rata (*average pooling*) atau maksimum (*max pooling*). Arsitektur *ResNet* yang digunakan dalam penelitian ini ialah ResNet-101, secara total memiliki 101 susunan *layer* seperti dijabarkan pada Tabel 2 dan Gambar 5 di bawah ini. Selain ResNet-101, terdapat beberapa tipe arsitektur *residual network* lain, seperti ResNet-18, ResNet-34, ResNet-50, dan ResNet-152. Pada bagian akhir dari arsitektur *Residual Network* menggunakan fungsi aktivasi *softmax*, persamaan fungsi aktivasi dapat dituliskan menjadi Persamaan (1).

$$\text{Softmax}(z_j) = \frac{\exp(z_j)}{\sum z_i} \quad (1)$$



Gambar 5. Blok Diagram Arsitektur ResNet-101

Tabel 2. Susunan Lapis pada Arsitektur ResNet-101

Nama Lapisan	Susunan Lapisan
Conv1	$7 \times 7, 64, Stride 2$
Conv2_x	3×3 Max Pooling, Stride 2 $\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
Conv3_x	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
Conv4_x	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$
Conv5_x	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
<i>Average Pooling, Fully Connected 1000, Aktivasi Softmax</i>	

Dalam rangka memperkecil *error* atau selisih antara prediksi dan target, arsitektur CNN akan terus dilatih untuk memperbarui bobot dan bias, *optimizers* berperan penting dalam proses ini. Dalam *machine learning* terdapat tiga metode utama *optimizers*, yaitu *deterministic gradient*, *stochastic*, dan perpaduan keduanya (**Soydaner, 2020**). *Stochastic Gradient Descent* (SGD) akan melatih *neural network* dengan melakukan perhitungan estimasi gradien menggunakan fungsi *loss*. Nilai parameter θ akan diperbarui pada iterasi pada selang waktu t . Pembaruan bobot menjadi Persamaan (2).

$$\theta_{t+1} = \theta_t - \eta d_t \quad (2)$$

dimana d_t merepresentasikan gradien dari fungsi objektif berdasarkan θ pada interval waktu t dan η adalah *learning rate*. AdaGrad adalah teknik pengoptimalan adaptif yang menyesuaikan besarnya *learning rate* untuk memperbarui semua parameter. Pembaruan bobot menjadi Persamaan (3).

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{D_t + \varepsilon}} d_t \quad (3)$$

dimana D_t adalah matriks diagonal, yang setiap elemen diagonalnya berisi penjumlahan estimasi gradien terhadap θ pada interval waktu t , sedangkan ε adalah bilangan kecil untuk menghindari hasil pembagian dengan nol. Adadelta merupakan modifikasi Adagrad yang bertujuan mengurangi *learning rate* yang terus menurun secara monoton. Adagrad mengakumulasikan semua gradien kuadrat sebelumnya untuk memperbarui *learning rate*, sedangkan Adadelta menggunakan jendela s yang berukuran tetap.

$$\theta_{t+1} = \theta_t - \Delta\theta_t \quad (4)$$

Dimana besarnya $\Delta\theta_t = -\frac{\eta}{\sqrt{R[d^2]_t + \varepsilon}} d_t$ dan $R[d^2]_t = \gamma R[d^2]_{t-1} + (1 - \gamma)d_t$.

Aturan pembaruan bobot pada *optimizer* RMSprop dilakukan dengan membagi *learning rate* dengan akar kuadrat dari rata-rata gradien kuadrat yang menurun secara eksponensial $R[d^2]_t$.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{R[d^2]_t + \varepsilon}} d_t \quad (5)$$

Optimizer Adam akan menyimpan nilai rata-rata eksponensial dari gradien masa lalu (a_t) yang mewakili momen pertama (rata-rata) dan gradien kuadrat masa lalu (u_t) yang mewakili momen kedua (variansi).

$$a_t = \beta_1 a_{t-1} + (1 + \beta_1) d_t \quad (6)$$

$$u_t = \beta_2 u_{t-1} + (1 + \beta_2) d_t^2 \quad (7)$$

Nilai a_t dan u_t bias ke arah nol ketika *decay rate* sangat kecil (β_1 dan β_2 mendekati nol), untuk mengatasinya, momen pertama dan momen kedua akan dihitung dengan mempertimbangkan dengan *bias-corrected*.

$$\hat{a}_t = \frac{a_t}{1 - \beta_1^t} \quad (8)$$

$$\hat{u}_t = \frac{u_t}{1 - \beta_2^t} \quad (9)$$

Sehingga, pembaruan bobot pada *optimizer* Adam menjad i:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{u}_t + \varepsilon}} \hat{a}_t \quad (10)$$

Aturan pembaruan bobot pada *optimizer* AdaMax didefinisikan dengan mengganti nilai $\sqrt{\hat{u}_t + \varepsilon}$ pada *optimizer* Adam dengan parameter v_t yang nilainya sebesar:

$$v_t = \beta_2 u_{t-1} + (1 + \beta_2) d_t = \max(\beta_2 \cdot u_{t-1}, d_t) \quad (11)$$

Sehingga, pembaruan bobot pada *optimizer* AdaMax menjadi :

$$\theta_{t+1} = \theta_t - \frac{\eta}{v_t} \hat{a}_t \quad (12)$$

Nadam (*Nesterov-accelerated adaptive moment estimation*) memodifikasi komponen momentum pada Adam dengan percepatan gradien Nesterov, dengan harapan mampu meningkatkan kecepatan konvergensi dan performansi model.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{u}_t + \varepsilon}} \left(\beta_1 \hat{a}_t + \frac{1 - \beta_1}{1 - \beta_1^t} d_t \right) \quad (13)$$

2.3 Parameter Pengujian

Parameter kinerja sistem yang akan ditinjau dalam penelitian ini adalah akurasi, presisi, *recall* dan f1-score. Nilai-nilai parameter tersebut tervisualisasi dalam tabel *confusion matrix*. Setiap elemen pada *confusion matrix* menunjukkan angka/jumlah prediksi yang dibuat oleh model dalam mengklasifikasikan data, bisa terprediksi benar atau salah. Tabel 3 di bawah ini menunjukkan *confusion matrix* untuk prediksi n kelas.

Tabel 3. Multiclass Confusion Matrix

		Predicted				
		Kelas 1	Kelas 2	Kelas 3	Kelas n
Actual	Kelas 1	x_{11}	x_{12}	x_{13}	x_{1n}
	Kelas 2	x_{21}	x_{22}	x_{23}	x_{2n}
	⋮	⋮	⋮	⋮	⋮	⋮
	Kelas n	x_{n1}	x_{n2}	x_{n3}	x_{nn}

Dari *confusion matrix* dapat dicari besarnya nilai *Total of False Negative* (TFN), *Total of False Positive* (TFP), *Total of True Negative* (TTN) dan *Total of True Positive* (TTP) untuk setiap kelas ke- i (**Manriquez, 2016**):

$$TFN_i = \sum_{\substack{j=1 \\ j \neq i}}^n x_{ij} \quad (14)$$

$$TFP_i = \sum_{\substack{j=1 \\ j \neq i}}^n x_{ji} \quad (15)$$

$$TTN_i = \sum_{\substack{j=1 \\ j \neq i}}^n \sum_{\substack{k=1 \\ k \neq i}}^n x_{jk} \quad (16)$$

$$TTP_{all} = \sum_{j=1}^n x_{jj} \quad (17)$$

Dari persamaan-persamaan di atas, dapat dicari besarnya nilai akurasi, presisi, *recall* dan f1-score sistem.

$$\text{Presisi} = \frac{\text{TP}_{all}}{\text{TP}_{all} + \text{FP}_i} \quad (18)$$

$$\text{Recall} = \frac{\text{TP}_{all}}{\text{TP}_{all} + \text{FN}_i} \quad (19)$$

$$f1 - Score = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (20)$$

$$\text{Akurasi} = \frac{\text{TP}_{all}}{\text{Total Data Uji}} \quad (21)$$

Akurasi ialah besarnya perbandingan jumlah data (citra) yang diprediksi secara benar terhadap keseluruhan data yang ada. Sedangkan *recall* (bisa juga disebut *sensitivity* atau *true positive rate*) adalah ukuran untuk yang menyatakan seberapa banyak positif benar yang diprediksi dari semua data positif dalam *dataset*. Presisi dihitung sebagai parameter yang menyatakan jumlah prediksi positif yang benar dibagi dengan jumlah total prediksi positif. Nilai f1-score digunakan untuk melihat perbandingan antara *recall* dan presisi, menyatakan besarnya rata-rata *harmonic* antara keduanya.

3. HASIL DAN PEMBAHASAN

Proses evaluasi dan pembahasan terhadap kinerja sistem akan dilakukan dengan membandingkan setidaknya tujuh algoritma *optimizer* yang berbeda, yaitu; Adam, SGD, RMSProp, AdaGrad, AdaMax, AdaDelta dan Nadam. *Confusion matrix* untuk setiap *optimizer* ditunjukkan oleh Tabel 4 di bawah ini. Besarnya nilai akurasi, presisi, *recall*, dan f1-score dapat dihitung dari *confusion* matrik dengan menggunakan Persamaan (18) sampai dengan Persamaan (21).

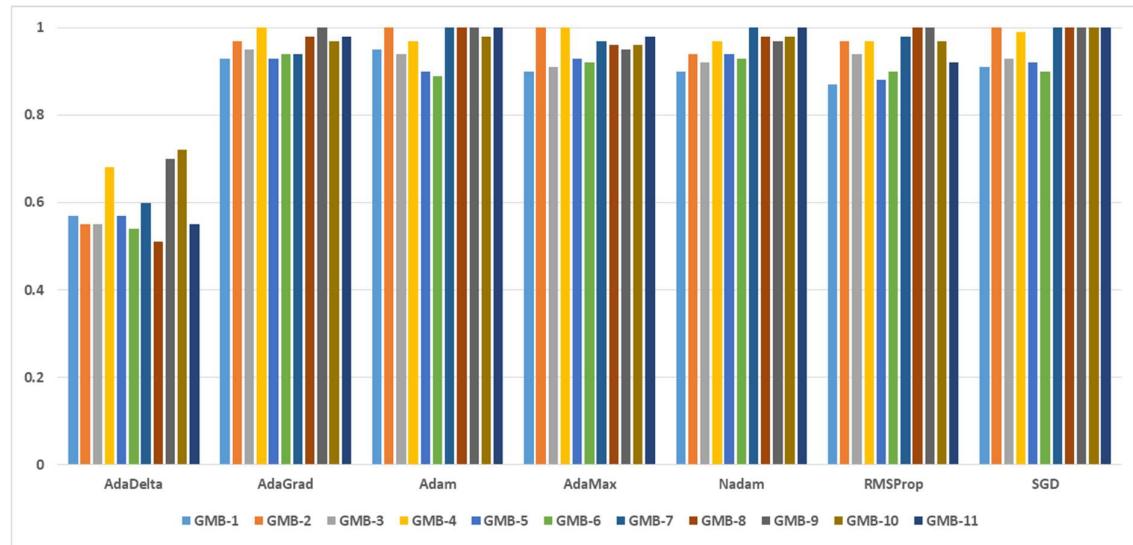
Tabel 4. Confusion Matrix untuk Setiap Optimizer

		Predicted										
		GMB-1	GMB-2	GMB-3	GMB-4	GMB-5	GMB-6	GMB-7	GMB-8	GMB-9	GMB-10	GMB-11
Actual	Adam Optimizer	59	0	0	0	0	0	0	0	0	0	0
	SGD Optimizer	0	60	0	0	0	0	0	0	0	0	0
	RMSProp Optimizer	6	0	51	0	0	0	0	0	0	0	0
	Adam Optimizer	0	0	0	52	0	0	0	0	0	0	0
	SGD Optimizer	0	0	0	0	58	0	0	0	0	0	0
	RMSProp Optimizer	0	0	0	0	11	53	0	0	0	0	0
	Adam Optimizer	0	0	0	0	0	0	60	0	0	0	0
	SGD Optimizer	0	0	0	0	0	0	0	57	0	0	0
	RMSProp Optimizer	0	0	0	0	0	0	0	0	67	0	0
	Adam Optimizer	0	0	0	3	0	0	0	0	0	69	0
	SGD Optimizer	0	0	0	0	0	0	0	0	0	0	52
	RMSProp Optimizer	0	0	0	0	0	0	0	0	0	0	0
Actual	Adam Optimizer	61	0	0	0	0	3	0	0	0	0	0
	SGD Optimizer	0	54	0	0	0	0	0	0	0	0	0
	RMSProp Optimizer	8	0	56	0	0	0	0	0	0	0	0
	Adam Optimizer	1	0	0	62	0	0	0	0	0	0	0
	SGD Optimizer	0	0	0	0	52	0	0	0	0	0	0
	RMSProp Optimizer	0	0	0	0	9	52	0	0	0	0	0
	Adam Optimizer	0	0	0	0	0	0	50	0	0	0	0
	SGD Optimizer	0	0	0	0	0	0	0	57	0	0	0
	RMSProp Optimizer	0	0	0	0	0	0	0	0	66	0	0
	Adam Optimizer	0	0	0	3	0	0	0	0	0	68	0
	SGD Optimizer	0	0	0	0	0	0	0	0	0	0	61

	GMB-6	0	0	0	0	12	56	0	0	0	0
	GMB-7	0	0	0	0	0	63	0	0	0	0
	GMB-8	0	0	0	0	0	0	66	0	0	0
	GMB-9	0	0	0	0	0	0	0	56	0	0
	GMB-10	0	0	0	0	0	0	0	0	53	0
	GMB-11	0	0	0	0	3	0	3	0	0	55
AdaGrad Optimizer		Predicted									
<i>Actual</i>	GMB-1	69	3	0	0	3	0	0	0	0	0
	GMB-2	0	57	0	0	0	0	0	0	0	0
	GMB-3	5	0	49	0	0	0	0	0	0	0
	GMB-4	0	0	0	51	0	0	0	0	0	0
	GMB-5	0	0	0	0	56	3	0	0	0	0
	GMB-6	0	0	0	0	2	63	0	0	0	0
	GMB-7	0	0	0	0	3	0	51	0	0	0
	GMB-8	3	0	0	0	0	0	0	74	0	0
	GMB-9	0	0	0	0	0	0	0	0	54	0
	GMB-10	0	0	0	0	0	0	3	0	0	52
	GMB-11	0	0	0	0	0	0	0	0	0	59
AdaMax Optimizer		Predicted									
<i>Actual</i>	GMB-1	36	0	8	0	0	0	0	0	0	0
	GMB-2	0	66	0	0	0	0	0	0	0	0
	GMB-3	0	0	55	0	0	0	0	0	0	0
	GMB-4	0	0	0	61	0	0	0	0	0	0
	GMB-5	0	0	0	0	52	2	0	0	0	0
	GMB-6	0	0	0	0	5	59	0	0	0	0
	GMB-7	0	0	0	0	0	0	58	0	0	0
	GMB-8	0	0	0	0	1	3	0	55	1	0
	GMB-9	0	0	0	0	0	0	3	0	77	0
	GMB-10	0	0	0	0	0	0	0	0	4	50
	GMB-11	0	0	3	0	0	0	0	0	0	61
AdaDelta Optimizer		Predicted									
<i>Actual</i>	GMB-1	33	6	3	4	2	3	3	0	2	0
	GMB-2	6	36	1	0	4	11	0	3	1	2
	GMB-3	7	2	28	3	2	10	1	0	1	2
	GMB-4	6	5	1	43	2	2	2	1	0	1
	GMB-5	0	2	2	2	35	7	0	4	2	3
	GMB-6	0	5	1	4	3	39	3	0	3	0
	GMB-7	0	1	1	2	4	2	31	1	1	5
	GMB-8	4	2	1	1	6	5	2	28	0	13
	GMB-9	2	3	2	0	2	4	3	0	44	0
	GMB-10	1	0	1	0	1	0	2	2	2	47
	GMB-11	0	3	4	3	4	4	5	6	1	30
Nadam Optimizer		Predicted									
<i>Actual</i>	GMB-1	57	0	2	0	0	0	0	3	0	0
	GMB-2	0	48	0	0	0	3	0	0	0	0
	GMB-3	7	0	49	0	0	0	0	0	0	0
	GMB-4	0	3	0	58	0	0	0	0	0	0
	GMB-5	0	0	0	0	59	8	0	0	0	0
	GMB-6	0	0	0	0	0	68	0	0	0	0
	GMB-7	0	0	0	0	0	0	57	0	0	0
	GMB-8	0	0	0	0	0	0	0	61	0	0
	GMB-9	0	0	0	0	0	0	0	0	47	0
	GMB-10	0	0	0	0	0	0	0	3	0	62
	GMB-11	0	0	0	0	0	0	0	0	0	65

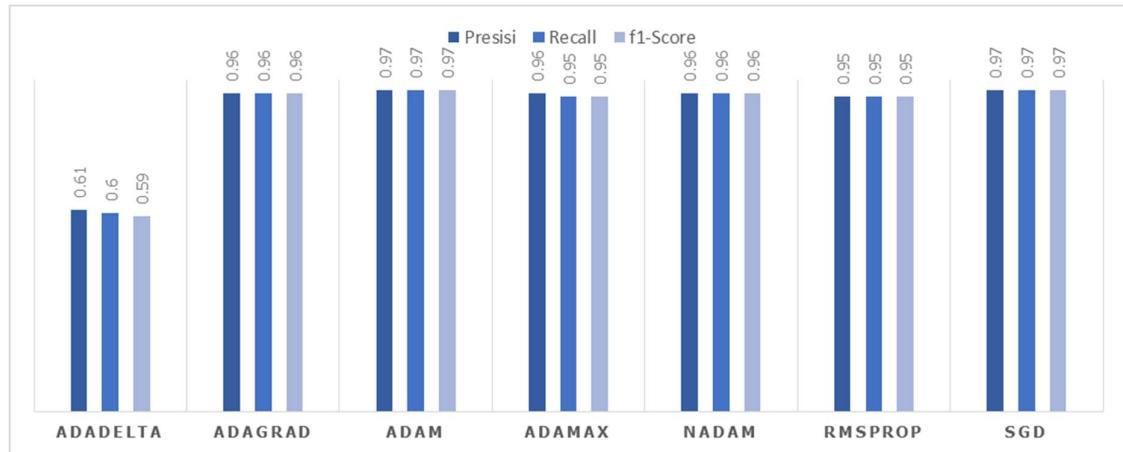
Jika kita perhatikan dengan seksama data pada Tabel 4, secara keseluruhan daun teh yang aktualnya ialah GMB-3, terdapat beberapa yang terprediksi sebagai GMB-1. Hal ini dikarenakan ciri morfologi daun teh kedua seri tersebut sangat dekat. Ciri morfologinya ialah daunnya memiliki kesamaan warna (hijau muda), bentuk ujung daun meruncing, tepian daun bergerigi besar, tajam tidak beraturan. Letak perbedaannya hanya pada tekstur muka daun, dimana GMB-1 bergelombang licin sedangkan muka daun GMB-3 agak bergelombang hampir rata. Kesamaan morfologi ini disebabkan seri tersebut berasal dari persilangan tetua KP4 × PS1 untuk GMB-1 dan persilangan PS 1 × Cin143 untuk GMB-3. Selain itu, terdapat daun yang secara aktual ialah seri GMB-6 tetapi terprediksi sebagai GMB-5. Hal ini juga dikarenakan tingkat kesamaan morfologi kedua seri daun juga sangat dekat. GMB-5 memiliki warna daun hijau agak kusam, sedangkan GMB-6 berwarna hijau tua. Ujung daun sama-sama meruncing

dengan muka daun bergelombang, yang menjadi pembeda lain ialah terdapatnya gerigi tepian daun pada GMB-5, dan gerigi ini tidak ditemukan di GMB-6. GMB-5 berasal dari persilangan tetua PS 1 × Mal-2 sedangkan GMB-6 berasal dari persilangan PS 1 × PS-324. Performansi sistem untuk kondisi seperti ini, dimana pada beberapa kelas jumlah data *False Negatif* (FN) dan *False Positif* (FP) yang tidak seimbang (*asymmetric*), maka kita bisa melihat nilai f1-score sebagai acuan performansi sistem.



Gambar 6. f1-score Setiap Kelas untuk Masing-masing Optimizer

Dari Gambar 6, terlihat bahwa GMB-1, GMB-3, GMB-5 dan GMB-6 memiliki nilai f1-score yang cenderung lebih rendah jika dibandingkan kelas lainnya. Nilai presisi, recall, dan f1-score untuk masing-masing optimizer dapat terlihat pada Gambar 7.



Gambar 7. Nilai Rata-Rata Presisi, Recall dan f1-score untuk Setiap Optimizer

Hasil pengujian menunjukkan bahwa Adam dan SGD memberikan nilai rata-rata presisi, recall dan f1-score terbaik. Hal ini mengindikasikan bahwa *optimizer* Adam dan SGD mampu melakukan prediksi data dengan tepat untuk kesebelas kelas pada daun teh seri GMB. Sedangkan AdaDelta memberikan nilai rata-rata presisi yang rendah, dapat dikatakan bahwa AdaDelta memiliki kemampuan yang rendah untuk mengenali setiap kelas pada citra daun teh, ada banyak citra/data yang diprediksi tidak sesuai dengan citra aslinya (kondisi aktual). Gambar 8 menunjukkan akurasi dari sistem yang dirancang, baik akurasi saat proses pelatihan

model maupun saat pengujian/validasi. Adam dikenal populer pada sistem berbasis *deep learning* dikarenakan Adam mampu mencapai hasil yang optimal (konvergen) dengan cepat. Hasil empiris menunjukkan bahwa Adam bekerja lebih baik dibandingkan dengan *stochastic optimization method* lainnya. Adam merupakan *optimizer* yang mengadaptasi prosedur kerja *stochastic gradient descent* klasik. Adam menggabungkan prinsip kerja *Adaptive Gradient Algorithm* (AdaGrad) dan *Root Mean Square Propagation* (RMSProp). Dari total *epoch* sebesar 100, diperoleh bahwa *optimizer* AdaGrad dan SGD memberikan nilai akurasi yang cenderung stabil sejak iterasi pertama, hal ini bisa terlihat pada Gambar 8 di bawah ini:



Gambar 8. Akurasi Latih dan Akurasi Validasi untuk Optimizer yang Berbeda

Sampai dengan *training* berakhir, nilai akurasi untuk *optimizer* AdaGrad ialah sebesar 98% untuk proses pelatihan dan 96% untuk validasi. Hal ini mengindikasikan bahwa AdaGrad mampu memprediksi *dataset* dengan akurat, model tidak mengalami *overfitting* maupun *underfitting*. Sedangkan *optimizer* AdaDelta memberikan nilai akurasi yang paling buruk, yaitu hanya sebesar 60% untuk pelatihan dan 52% untuk validasi. Hal ini juga didukung oleh *confussion matrix* *optimizer* AdaDelta, dimana algoritma ini banyak sekali melakukan kesalahan prediksi untuk setiap kelasnya. *Optimizer* Adam menunjukkan nilai akurasi validasi yang sedikit lebih tinggi yaitu sebesar 97%, tetapi jika dilihat secara keseluruhan akurasi sistem sangat fluktuatif.

4. KESIMPULAN

Penelitian memberikan kesimpulan bahwa model CNN dengan arsitektur ResNet101 dapat melakukan deteksi dan klasifikasi klon teh Seri GMB-1 sampai dengan GMB-11 dengan baik. Proses evaluasi kinerja sistem dilakukan dengan membandingkan setidaknya tujuh algoritma *optimizer* yang berbeda, yaitu; Adam, SGD, RMSProp, AdaGrad, AdaMax, AdaDelta dan Nadam. Hasil pengujian menunjukkan bahwa Adam dan SGD memberikan nilai rata-rata *precision*, *recall* dan f1-score terbaik. Sedangkan AdaDelta memberikan nilai rata-rata presisi yang rendah. Hal serupa juga terjadi untuk parameter performansi akurasi yang terbaik diberikan oleh *optimizer* Adam, dan yang terburuk diberikan oleh *AdaDelta*. Adam memberikan nilai akurasi yang cenderung stabil sejak iterasi pertama. Hasil pengujian sistem menunjukkan bahwa metode yang diusulkan memberikan nilai *precision*, *recall*, f1-score masing-masing sebesar 96% dengan akurasi 97%.

UCAPAN TERIMA KASIH

Ucapan terimakasih yang mendalam kami sampaikan kepada Direktorat Pengembangan Teknologi Industri - Deputi Bidang Penguatan Riset dan Pengembangan di bawah Kementerian Riset dan Teknologi/Badan Riset dan Inovasi Nasional (RISTEK-BRIN) yang telah mendanai dan mendukung penuh kegiatan penelitian ini. Penelitian ini mendapatkan bantuan pendanaan melalui program Insentif Riset Sinas (INSINAS) berdasarkan SK Nomor 6/E1/KPT/2020 tanggal 20 Januari 2020 dan diperpanjang untuk pelaksanaan tahun kedua melalui SK Nomor 15/E1/KPT/2021 tanggal 19 April 2021.

DAFTAR RUJUKAN

- Basorudin, M., Rizqi, A., & Murdaningrum, S., & Maharani, W. (2019). Kajian Persebaran Komoditas Teh: Pengembangan Kawasan Perkebunan Teh Di Provinsi Jawa Barat Tahun 2015. *Jurnal Sosial Ekonomi Pertanian*, 15(3), 205. <https://doi.org/10.20956/jsep.v15i3.6792>
- Chen, Y., & Chen, X. (2019). Tea Leaves Identification Based on Gray-Level Co-Occurrence Matrix and K-Nearest Neighbors Algorithm. *AIP Conference Proceedings*, (pp. 2073).
- Gulli, A., Kapoor, A., & Pal, S. (2019). *Deep Learning with TensorFlow 2 and Keras: Regression, ConvNets, GANs, RNNs, NLP, and More with TensorFlow 2 and the Keras API* (2nd ed.). Birmingham, UK: Packt Publishing Ltd.

- Haq, M. S., & Karyudi. (2013). Upaya Peningkatan Produksi Teh (Camelia Sinesi (L.) O. Kuntze) Melalui Penerapan Kultur Teknis. *Warta PPTK*, 24(1), 71–84.
- Hariyani, Y. S., Hadiyoso, S., & Siadari, T. S. (2020). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 8(2), 443–453.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition Kaiming. *IEEE Conference on Computer Vision and Pattern Recognition*, (pp. 770–778). <https://doi.org/10.1002/chin.200650130>
- Ibrahim, N., Fu'adah, Y. N., Pratiwi, N. C., Rizal, S., & Usman, K. (2020). Computer Aided System for Gambung Tea Identification using Convolutional Neural Network. *IOP Conference Series: Materials Science and Engineering*, 982(1), 0–10. <https://doi.org/10.1088/1757-899X/982/1/012001>
- Indarti, D. (2015). Outlook Teh Komoditas Pertanian Subsektor Perkebunan. In *Sekretariat Jenderal Kementerian Pertanian, Pusat Data dan Sistem Informasi Pertanian* (Vol. 1). Retrieved from [http://epublikasi.setjen.pertanian.go.id/epublikasi/outlook/2015/Perkebunan/Outlook Teh 2015/files/assets/common/downloads/Outlook Teh 2015.pdf](http://epublikasi.setjen.pertanian.go.id/epublikasi/outlook/2015/Perkebunan/Outlook%20Teh%202015/files/assets/common/downloads/Outlook%20Teh%202015.pdf)
- Indolia, S., Kumar, A., Mishra, S. P., & Asopa, P. (2018). ScienceDirect Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science*, 132, 679–688. <https://doi.org/10.1016/j.procs.2018.05.069>
- Lu, H., Jiang, W., Ghiassi, M., Lee, S., & Nitin, M. (2012). Classification of Camellia (Theaceae) Species Using Leaf Architecture Variations and Pattern Recognition Techniques. *PloS One*, 7(1). <https://doi.org/10.1371/journal.pone.0029704>
- Manliguez, C. (2016). *Generalized Confusion Matrix for Multiple Classes*. (November), 2–4. <https://doi.org/10.13140/RG.2.2.31150.51523>
- Ramdan, A., Suryawati, E., Kusumo, B. S., Pardede, H. F., Mahendra, O., Dahlan, R., ... Syahrian, H. (2019). Deep CNNBased Detection for Tea Clone Identification. *Jurnal Elektronika Dan Telekomunikasi (JET)*, 19(2), 45–50. <https://doi.org/10.14203/jet.v19.45-50>
- Ramdan, A., Zilvan, V., Suryawati, E., Pardede, H. F., & Rahadi, V. P. (2020). Tea clone classification using deep CNN with residual and densely connections. *Jurnal Teknologi Dan Sistem Komputer*, 8(4), 289–296. <https://doi.org/10.14710/jtsiskom.2020.13768>
- Rizal, S., Pratiwi, N. K. C., Ibrahim, N., Vidya, H., Saidah, S., & Fuadah, Y. N. (2020). Tea Leaves GMB Series Classification Using Convolutional Neural Network. *Journal of Electrical and System Control Engineering*, 3(2), 0–5.

- Soydaner, D. (2020). A Comparison of Optimization Algorithms for Deep Learning. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(13). <https://doi.org/10.1142/S0218001420520138>
- Vilasini, M., & Ramamoorthy, P. (2020). CNN Approaches for Classification of Indian Leaf Species Using Smartphones. *Computers, Materials & Continua*, 62(3), 1445–1472. <https://doi.org/10.32604/cmc.2020.08857>
- Wu, H., Xin, M., Fang, W., Hu, H. M., & Hu, Z. (2019). Multi-Level Feature Network with Multi-Loss for Person Re-Identification. *IEEE Access*, 7, 91052–91062. <https://doi.org/10.1109/ACCESS.2019.2927052>
- Zhang, K., Sun, M., Han, T. X., Yuan, X., Guo, L., & Liu, T. (2018). Residual Networks of Residual Networks: Multilevel Residual Networks. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(8), 1303–1314. <https://doi.org/10.1109/TCSVT.2017.2654543>