

Deteksi Jenis Daun Teh Klon Seri GMB Menggunakan *Convolutional Neural Network* (CNN) dengan Arsitektur *GoogLeNet*

GMB Clone Tea Leaf Types Detection Using *Convolutional*neural Network (CNN) With *GoogLeNet* Architecture

Nur Ibrahim^{1*}, Syamsul Rizal¹, Heri Syahrian², Vitria Puspitasari Rahadi², dan Alvian Ihza Fahmi²

¹ Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

² Pusat Penelitian Teh dan Kina

* Korespondensi: nuribrahim@telkomuniversity.ac.id

Received: 22 September 2020

Accepted: 10 Juni 2022

Published: 13 Januari 2023

Jurnal Sains Teh dan Kina
Pusat Penelitian Teh dan Kina
Desa Mekarsari, Kec. Pasirjambu,
Kab. Bandung, Jawa Barat 40972
redaksijptk@gmail.com
+62 22 5928186

Abstract: *Assamica* variety is one of tea varieties in Indonesia. This variety has eleven clones known as the GMB series clone. This clone has been studied by the Research Institute for Tea and Cinchona (RITC) namely: GMB 1 to GMB 11. Unfortunately, few people can't identify these eleven clones using only the visual eye. Some of the factors are the GMB series structure and color that have many similarities. The GMB series has different production capacities, thereby affecting revenue profitability. Previously, the system design research was carried out to classify five of the eleven types this GMB series, but accuracy does not reach the main goal. In this research, Python programming language is used with the *Convolutional Neural Network* (CNN) method with the *GoogLeNet* architecture as digital image processing from the Gambung series tea leaf data. The outcome of this research is detecting and classifying eleven Gambung series tea leaves with CNN method and *GoogLeNet* architecture. System uses data augmentation, which is 2640 training data and 220 validation data. The system performance achieve 60.55% accuracy, 2.74 loss, and 63% precision using Adam Optimizer and learning rate 0.0001.

Keywords: *GMB series clones, Convolutional Neural Network (CNN), GoogLeNet*

Abstrak: Varietas *Assamica* merupakan salah satu dari berbagai macam varietas teh yang ada di Indonesia. Varietas ini diantaranya terdapat sebelas klon yang dikenal sebagai klon seri GMB. Klon ini sudah diteliti oleh Pusat Penelitian Teh dan Kina (PPTK), dengan penamaan GMB 1-11. Namun, tidak banyak orang yang dapat membedakan sebelas klon ini secara visual. Beberapa faktor penyebab sulitnya membedakan jenis klon seri GMB adalah struktur dan warna yang memiliki banyak kesamaan. Klon seri GMB memiliki kapasitas produksi yang berbeda, sehingga berpengaruh pada tingkat keuntungan penanamannya. Sebelumnya telah dilakukan penelitian perancangan sistem untuk mengklasifikasi lima dari sebelas jenis daun teh klon seri GMB tersebut, namun tingkat akurasi belum sesuai dengan harapan. Pada penelitian ini digunakan bahasa pemrograman Python dengan metode *Convolutional Neural Network* (CNN) dengan arsitektur *GoogLeNet* sebagai pengolahan citra digital dari data set daun teh klon seri GMB. Hasil yang didapatkan dari penelitian ini adalah sistem dengan kemampuan mengklasifikasikan sebelas daun teh klon seri GMB menggunakan metode CNN dengan arsitektur *GoogLeNet*. Sistem mengolah data hasil augmentasi, dengan data latih sebanyak 2640 dan data uji sebanyak 220. Sistem mencapai akurasi sebesar 60,55%, 2,74 loss, dan presisi sebesar 63% menggunakan Adam Optimizer dengan *learning rate* 0,0001.

Kata Kunci: Klon Seri GMB, *Convolutional Neural Network* (CNN), *GoogLeNet*

1. Pendahuluan

Teh merupakan salah satu tanaman budidaya yang ada di Indonesia. Tanaman teh merupakan jenis dari tumbuhan subtropis yang cocok dengan iklim di Indonesia dan merupakan sumber antioksidan sehingga cukup digemari dikalangan masyarakat. Sebagian besar semua teh yang dibudidayakan di Indonesia merupakan varietas Assamica yang menurut Pusat Penelitian Teh dan Kina (PPTK) memiliki kadar antioksidan (katekin) cukup tinggi dengan angka 13,9% - 17,1% dari berat kering (Anjarsari, 2016). Sejak tahun 1988 telah ditetapkan bahwa terdapat lima klon teh seri GMB dari varietas Assamica yaitu, GMB 1, GMB 2, GMB 3, GMB 4, dan GMB 5. Klon seri GMB lainnya baru dikeluarkan pada Oktober tahun 1998. Penambahan klon seri GMB merupakan GMB 6, GMB 7, GMB 8, GMB 9, GMB 10 dan GMB 11 (Sriyadi *et al.*, 2012). Walaupun merupakan salah satu jenis klon teh unggulan, tetapi hanya sedikit ahli yang mampu membedakan jenis satu dengan yang lainnya. Beberapa faktor penyebabnya adalah klon teh seri GMB ini memiliki beberapa kesamaan karakteristik fisik pada daun atau pucuk yang besar dan lebar, serta permukaan daun yang sangat bergelombang. Studi tentang penelitian deteksi jenis klon juga pernah dilakukan. Hanya saja penelitian tersebut ditujukan untuk GMB 1, GMB 3, GMB 4, GMB 7, dan GMB 9 menggunakan *Gabor Wavelet and Support Vector Machine Methods* (Ibrahim *et al.*, 2019).

Dalam suatu perkembangan dan pengembangan perkebunan teh yang ada di Indonesia, banyak genotipe unggul yang telah di hasilkan, salah satunya dari Pusat Penelitian Teh dan Kina (PPTK) Gambung. Contoh genotipe yang dihasilkan adalah klon seri GMB. Pada tahun 1988, PPTK dan Menteri Pertanian mempublikasikan GMB 1 sampai GMB 5. Klon GMB 1 sampai GMB 5 mempunyai potensi produksi mencapai lebih dari 3.400 kg pucuk kering per tahunnya. Sebagai upaya untuk meningkatkan produktivitas perkebunan teh, PPTK kembali menghasilkan klon baru, yaitu klon GMB 6 sampai GMB 11.

Klon GMB 6 sampai GMB 11 mempunyai potensi produksi berbeda dari Seri GMB sebelumnya, yang bisa mencapai lebih dari 5.000 kg pucuk kering per hektar per tahunnya. Penanaman teh dapat dilakukan di dataran tinggi, sedang, dan rendah. Dataran rendah dapat di tanami oleh GMB 1, GMB 2, GMB 3, GMB 6, GMB 7, dan GMB 9. Dataran sedang yaitu GMB 3, GMB 4, GMB 5, GMB 6, GMB 7, dan GMB 9. Kemudian dataran tinggi GMB 1, GMB 2, GMB 3, GMB 4, GMB 5, GMB 8, GMB 10, dan GMB 11 (Indrawanto, 2010).

Neural Network atau dapat disebut jaringan syaraf merupakan permodelan yang menirukan cara kerja syaraf dalam otak manusia (Gupta dan Reddi, 2013). *Neural Network* menentukan produk dari interaksi ribuan sinyal pada tiap elemen jaringan. *Neural Network* terdiri dari *input layer*, *hidden layers*, dan *output layer*. *Neural network* dapat dibedakan menjadi dua jenis berdasarkan *input layer*. *Neural network* yang terdiri kurang dari dua *hidden layer* dapat disebut *Recurrent* atau *Feed-forward neural networks*, sedangkan apabila terdiri dari lebih dari dua *hidden layer* merupakan *Deep neural network*.


Deep learning merupakan cabang dari *Machine Learning* yang memanfaatkan beberapa *non-linear information layer* untuk mendapatkan ekstraksi ciri sehingga didapatkan klasifikasi dan analisis pola (Deng dan Yu, 2013). Algoritma *deep learning* dapat digunakan dalam pembelajaran *supervised learning* dan *unsupervised learning* pemrosesan sinyal informasi citra, suara dan sebagainya. *Supervised learning* merupakan proses *learning* dimana data set sudah dilatih dan hanya akan dilakukan pengelompokan saja. Sementara itu, *unsupervised learning* merupakan proses *learning* dimana tidak ada data set yang sudah di latih sebelumnya, sehingga dengan data yang baru akan dilakukan pengelompokan.

Convolutional Neural Network (CNN) merupakan metode *neural network* yang dikhususkan untuk data dimensi tinggi seperti gambar dan video (Khan *et al.*, 2018). Metode ini menggunakan operasi matematika dari sebuah operasi linear atau yang biasa disebut konvolusi. CNN terdiri dari beberapa layer dasar yang disebut *CNN layers*. Beberapa layer diantaranya yaitu *convolutional layer*, *pooling layer*, dan *fully-connected layer*. Ketiga layer tersebut memiliki fungsi yang berbeda-beda. *Convolutional Layer* terdiri dari *convolutional kernels* dalam bentuk filter yang sudah dikonvolusi dengan *citra input* (Gambar 1.). Perhitungan *convolutional layer* dapat dilihat dalam perhitungan berikut:

$$Y_i^{(l)} = f(\sum_{j=1}^{m_1^{(l-1)}} K_{ij}^{(l)} * Y_j^{(l-1)} + B_i^{(l)}) \dots\dots\dots (1)$$


dimana keterangan $Y_i^{(l)}$ sebagai *output*, $B_i^{(l)}$ matrix bias, $m_1^{(l-1)}$ *feature maps*, $K_{ij}^{(l)}$ merupakan filter dan $Y_j^{(l-1)}$ merupakan *output layer* sebelumnya (Zeng *et al.*, 2019). Tiap filter memiliki *weight* atau nilai dalam *grid* yang diperoleh pada proses pelatihan CNN. *Pooling layer* akan melakukan operasi *pooling* untuk mengolah matriks. Umumnya operasi *pooling* yang digunakan adalah *average pooling* dan *max pooling*. Pada *average pooling*, nilai yang akan diambil adalah nilai rata-rata dari nilai fitur citra, sedangkan *max pooling*, akan mengambil nilai tertinggi dari

nilai fitur citra. *Fully-Connected Layer* (FC Layer) merupakan layer pada akhir arsitektur yang digunakan dalam *multi layer perceptron*. Dimana layer ini akan menghubungkan semua *neuron* aktivasi layer sebelumnya.



Gambar 1. Arsitektur *Convolutional Neural Network*

GoogLeNet merupakan salah satu arsitektur CNN dengan rangkaian pembangun utamanya merupakan *Inception Module* atau biasa disebut *Inception Network* (Aswathy *et al.*, 2018) (Gambar 2.). Memiliki 22 *layers network*, jauh lebih sedikit dan akurat dari pada arsitektur lain-nya seperti Alexnet. *GoogLeNet* lebih kompleks karena memiliki network yang bercabang. Konsep dasarnya adalah melakukan proses konvolusi ukuran paling detail (1×1) dalam ukuran paralel dan menggabungkan semua hasil konvolusi yang berbeda. Ukuran filter yang berbeda, akan menangani objek yang lebih baik sehingga semua filter dapat dipelajari.




Gambar 2. Konsep *Inception Layer* dan *Inception Layer Dimention Reduction*

Pada penelitian ini digunakan *Convolutional Neural Network* (CNN) sebagai pengolahan citra daun teh. Metode CNN merupakan salah satu metode dengan *Multi Layer Perceptron* (MLP) yang dikhususkan untuk mengolah data dua dimensi. Selain itu, pada penelitian ini digunakan *GoogLeNet* sebagai arsitektur dalam CNN.

2. Metode Penelitian

2.1. Desain Sistem

Dalam penelitian ini, sistem didesain untuk deteksi objek dengan data berupa foto. Dengan algoritma CNN, ekstraksi ciri dari objek diambil menggunakan arsitektur *GoogLeNet*. Secara garis besar, desain sistem dapat dilihat pada Gambar 3.




Gambar 3. Blok Diagram Sistem

2.2. Akusisi Data

Data set yang digunakan diambil menggunakan beberapa kamera smartphone yang berbeda. Data latih berjumlah sebanyak 100 foto dari masing-masing jenis seri GMB, atau dengan kata lain jumlah keseluruhan data set sebanyak 1100 foto. Pembagiannya berupa 80 % data latih dan 20 % data uji.

2.3. Preprocessing


Preprocessing merupakan proses sebelum citra daun teh tersebut diolah. Proses ini diperlukan untuk melakukan klasifikasi, seperti ekstraksi ciri dan pengambilan parameter lainnya. Pada tahap ini merupakan tahap pengolahan citra yang mempunyai tujuan sebagai penghasil citra yang lebih baik untuk diproses ke tahap berikutnya. Proses *preprocessing* kali ini dilakukan dua tahapan yaitu *resize* dan augmentasi data. *Resize* merupakan mengubah ukuran citra gambar sehingga proses ukuran dapat disesuaikan dengan arsitektur yang digunakan (Gambar 4.). Sementara itu, augmentasi merupakan proses memodifikasi data yang sudah ada menjadi data yang dianggap baru oleh computer tanpa mengubah esensi dari data awal (Fawzi *et al.*, 2016) (Gambar 5.). Proses augmentasi dilakukan hanya terhadap data latih. Setelah proses augmentasi, data latih menjadi 2640 data dan data uji tetap sama yaitu 220 data.



Gambar 4. Proses *preprocessing* dengan *resize* data set

2.4. Pelatihan Model


Pada penelitian ini, arsitektur yang digunakan merupakan arsitektur *GoogLeNet* yang memiliki 22 layer. Citra akan dijadikan *input featur map* yang memiliki besar (224, 224) dan nilai *weight* masing-masing. Setelah citra input diubah menjadi *input featur map*, dilakukannya pengolahan pada *convolutional layer* yang berisi *convolutional* dan *max pool*. Citra gambar akan direduksi dengan ukuran terkecil yang memungkinkan dapat dipelajari sehingga mempercepat proses *learning system* sebelum diolah pada *FC layer* menggunakan *GoogLeNet*.



Gambar 5. *Preprocessing* dengan Augmentasi (Data Augmentasi)

2.5. Proses *Training* dan *Testing*

Proses utama dalam penelitian ini diawali dengan proses *training data*. Pada proses *training data*, mempunyai tujuan untuk pembentukan model yang akan digunakan untuk pengujian data *testing* parameter yang dilihat pada pengukuran tingkat keberhasilan model ini adalah nilai akurasi, presisi, dan loss. Berikut adalah diagram sistem dari *proses training data* dan *testing data* yang dapat dilihat pada Gambar 6.



Gambar 6. Diagram Sistem Proses *Training* dan *Testing*


2.6. Perancangan Pengujian

Proses pengujian akan dibagi menjadi dua bagian, yaitu pengujian menggunakan data asli dan data augmentasi. Pada tiap jenis pengujian, akan diukur performansi system dengan menggunakan beberapa parameter seperti *epoch*, *learning rate*, dan *optimizer*. Berikut keterangan parameter yang akan diuji: 1) *Epoch* 100; 2) *Learning rate* 0,01; 0,001 dan 0,0001; serta 3) *Optimizer* Adam dan SGD.

3. Hasil dan Pembahasan


3.1. Hasil data Asli

Proses pelatihan pertama menggunakan *Adam Optimizer*. Sistem berhasil mengklasifikasikan seri Gambung dengan cukup baik. Grafik akurasi sistem dapat dilihat pada Gambar 7 yang menunjukkan bahwa sistem dengan *Adam Optimizer* dan *learning rate* 0.0001 mendapat akurasi tertinggi. Akurasi yang didapat sebesar 58,18% dengan *loss validasi* 3,49 dan presisi 59%.



Gambar 7. Grafik Akurasi Hasil Data Asli Adam Optimizer

Proses pelatihan kedua menggunakan *SGD Optimizer*. Sistem berhasil mengklasifikasikan seri Gambung dengan cukup baik. Grafik akurasi sistem dapat dilihat pada Gambar 8 yang menunjukkan bahwa sistem dengan *learning rate* 0,001 mendapatkan akurasi tertinggi. Akurasi yang didapat sebesar 49,09% dengan *loss validasi* 4,04 dan presisi 54%.




Gambar 8. Grafik Akurasi Hasil Data Asli SGD Optimizer

3.1. Hasil data Augmentasi


Proses pelatihan pertama menggunakan data augmentasi dilakukan dengan *Adam Optimizer*. Sistem mendapatkan performa lebih baik dari pada penggunaan data asli. Grafik akurasi sistem dapat dilihat pada Gambar 9 yang menunjukkan bahwa sistem dengan *learning rate* 0,0001 memperoleh nilai akurasi tertinggi. Akurasi yang didapat sebesar 60,55% dengan *loss validasi* 1,78 dan presisi 63%.

Berdasarkan hasil dari Gambar 7 hingga Gambar 10, terlihat bahwa peformansi maksimal dari sistem identifikasi teh klon seri GMB dengan arsitektur *GoogLeNet* adalah 60,55%. Hal ini disebabkan jumlah layer dari arsitektur *GoogLeNet* belum optimal dalam melakukan ekstraksi ciri dan klasifikasi dari sebelas jenis citra daun teh seri klon GMB. Selain itu, faktor eksternal seperti kondisi pencahayaan saat pengambilan data menggunakan kamera *smartphone* juga mempengaruhi sistem dalam mempelajari dan mengklasifikasikan sebelas jenis daun teh seri klon GMB.

Berdasarkan hasil penelitian yang telah dilakukan, maka beberapa saran untuk penelitian selanjutnya adalah dapat digunakan beberapa arsitektur CNN yang *state-of-the-art*, dan dilakukan penambahan jumlah dataset dengan kondisi yang seragam untuk membantu sistem dalam mengidentifikasi dengan lebih baik.



Gambar 9. Grafik Hasil Data Augmentasi *Adam Optimizer*



Gambar 10. Grafik Hasil Data Augmentasi *SGD Optimizer*

4. Kesimpulan

Telah dirancang sebuah sistem klasifikasi sebelas daun teh seri Gambung menggunakan CNN dengan arsitektur *GoogLeNet* dan dioptimasi sedemikian rupa sehingga didapatkan peformansi terbaik dengan tingkat akurasi 60,55%. Performansi tersebut didapatkan dengan menggunakan *Adam Optimizer*, *learning rate* 0,0001, dan dilakukan proses augmentasi data.

Referensi

- Ahmad, F.; Hamid, F. S.; Waheed A.; Zaman Q. U.; Aslam S.; Shah B. H.; Islam S.; Sarwar S.; Ali I. Growth performance of tea (*Camellia sinensis* L.) cultivars at nursery stage. *Journal Agricultural Research* 2015, Volume 53 (3), 365-374.
- Anjarsari, I. R. D. Katekin teh Indonesia : Prospek dan Manfaatnya. *Kultivasi* 2016, Volume 15 (2), 99-106.
- Aswathy, P.; Siddhartha, Mishra, D. Deep GoogLeNet Features for Visual Object Tracking. *Proc.2018 13th Int. Conf. Ind. Inf. Syst. ICIIS 2018 - Proc.* 2018, 978, 60–66.
- Deng, L. dan Yu, D. Deep learning: Methods and applications. *Found. Trends Signal Process* 2013, Volume 7 (3-4), 197-387.
- Fawzi, A.; Samulowitz, H.; Turaga, D.; Frossard, P. Adaptive data augmentation for image classification. *Proc. - Int. Conf. Image Process. ICIP* 2016, 3688–3692.
- Gupta, M. S.; Reddi, V. J. *Synthesis Lectures on Computer Architecture*, 2013.
- Ibrahim, N.; Novamizanti, L.; Ruhiat, R. L. *Classification Of GMB 1, GMB 3, GMB 4, GMB 7, GMB 9 Series Tea Clone Image Using Gabor Wavelet And Support Vector Machine Methods*. Univ. Telkom, S1 Teknik Telekomunikasi: Bandung, Indonesia, 2019.
- Indrawanto, C. Budidaya dan Pasca Panen Tebu. *ESKA media* 2010, Volume 13 (8), 15–20.
- Khan, S.; Rahmani, H.; Shah, S. A. A.; Bennamoun, M. A Guide to Convolutional Neural Networks for Computer Vision. *Synth. Lect. Comput. Vis.* 2018, Volume 8 (1), 201-207.
- Sriyadi, B.; Suprihatini, R.; Khomaeni, H. S. *The development of high yielding tea clones to increase Indonesian tea production In Global Tea Breeding*. Springer: Berlin, Germany, 2012; pp. 299-308.
- Zeng, Z.; Gong, Q.; Zhang, J. CNN model design of gesture recognition based on tensorflow framework. *Proc. 2019 IEEE 3rd Inf. Technol. Networking, Electron. Autom. Control Conf. ITNEC* 2019, 1062–1067.