

# Klasifikasi Kualitas Teh Hitam Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Citra Digital

Classification quality of black tea using digital image-based CNN method

Aprilia Nur Komariyah<sup>1\*</sup>, Bagas Rohmatulloh<sup>2</sup>, Yusuf Hendrawan<sup>1</sup>, Sandra Malin Sutan<sup>1</sup>, Dimas Firmanda Al Riza<sup>1</sup>, Mochamad Bagus Hermanto<sup>1</sup>

<sup>1</sup>Departemen Teknik Pertanian dan Biosistem Universitas Brawijaya, Malang, Indonesia

<sup>2</sup>PT Perkebunan Nusantara XIV, Makassar, Indonesia

Email\*: [aprilianurq@gmail.com](mailto:aprilianurq@gmail.com)

Received:

28 June 2023

Revised:

10 August 2023

Accepted:

10 September 2023

Published:

27 September 2023

DOI:

10.29303/jrpb.v11i2.542

ISSN 2301-8119

e-ISSN 2443-1354

Tersedia online di

<http://jrpb.unram.ac.id/>

**Abstract:** As a tropical country, the production of black tea in Indonesia is very huge. Because of its quality, black tea in Indonesia has been exported to many countries. To meet the required quality standards, black tea is classified into three grades, we mention it as grade A, grade B, and grade C. However, the industries have suffered from lack of standard of quality control because they are still using manual methods. The purpose of this study was to classify three quality levels of black tea automatically using a convolutional neural network (CNN) based on deep learning. Two types of pre-trained networks were used in this study such as AlexNet and ResNet50. From the sensitivity analysis results showed very high accuracy in the training and validation process. Three best CNN models i.e AlexNet with Adam solver and learning rate 0.00005; AlexNet with RMSProp solver and learning rate 0.0001; ResNet50 with SGDM solver and learning rate 0.00005 were able to achieve training and validation accuracy up to 100%. The classification accuracy based on results from pre-trained AlexNet with Adam solver can classify Grade B and Grade C perfectly 100% without the slightest error. But, for Grade A the average accuracy was 99,7%. Meanwhile, from the confusion matrix result using AlexNet with RMSProp solver and learning rate 0.0001; ResNet50 with SGDM solver and learning rate 0.00005 can perfectly classified the black tea. From the results, it can be concluded that the CNN model can work effectively to classify black tea.

**Keywords:** AlexNet; black tea; classification; CNN; ResNet50

**Abstrak:** Sebagai negara tropis, produksi teh hitam di Indonesia sangat besar. Berdasarkan kualitasnya, teh hitam di Indonesia telah diekspor ke beberapa negara. Dalam rangka memenuhi permintaan standar kualitas yang dibutuhkan di tiap negara, teh hitam diklasifikasikan menjadi tiga jenis, diantaranya grade A, grade B, dan grade C. tetapi, pada kenyataannya industri memiliki permasalahan pada pemenuhan standar *quality control* karena kebanyakan industri masih menggunakan metode manual. Maka dari itu tujuan dari penelitian ini adalah untuk mengklasifikasi tiga jenis mutu teh secara otomatis dengan menggunakan *convolutional neural network* (CNN). Dua tipe *pre-trained network* digunakan yakni arsitektur AlexNet dan ResNet50. Berdasarkan analisis sensitivitas didapatkan nilai akurasi yang tinggi pada proses *training* dan validasi. Tiga model terbaik dari CNN didapatkan diantaranya AlexNet dengan solver Adam dan *learning rate* 0.00005; AlexNet dengan solver RMSProp dan *learning rate* 0.0001; ResNet50 dengan solver SGDM dan *learning rate* 0.00005 yang mana mendapatkan nilai akurasi training dan validasi hingga 100%. Selanjutnya didapatkan nilai akurasi klasifikasi dengan arsitektur AlexNet dengan solver Adam dan *learning rate* 0.00005 mampu mengklasifikasikan grade B dan grade

C tepat 100% tanpa adanya *error*. Tetapi untuk grade A terdapat kesalahan sehingga nilai akurasi menjadi 99.7%. Sedangkan untuk arsitektur AlexNet dengan solver RMSProp dan *learning rate* 0.0001 dan arsitektur ResNet50 dengan solver SGDM dan *learning rate* 0.00005 dapat mengklasifikasikan teh hitam tepat sesuai dengan kelasnya. Berdasarkan hasil tersebut dapat disimpulkan bahwa CNN mampu mengklasifikasikan teh hitam secara efektif.

**Kata kunci:** AlexNet; CNN; klasifikasi; ResNet50; teh hitam

## PENDAHULUAN

### Latar Belakang

Teh merupakan salah satu komoditas pertanian sub sektor perkebunan yang memegang peranan cukup penting dalam perekonomian Indonesia. Industri teh berperan sebagai sumber pendapatan dan devisa, penyedia lapangan kerja, dan pengembangan wilayah. Berdasarkan laporan produksi teh di Indonesia yang bersumber dari Direktorat Jenderal Perkebunan, pada tahun 2020 Indonesia menghasilkan 144.063 Ton teh dengan kenaikan sebesar 10,96% dari tahun sebelumnya. Produksi teh ini didominasi oleh teh hitam ortodoks sebanyak 85% serta teh hitam CTC (*Crush Tear Curl*) sebanyak 15%. Besarnya jumlah produksi teh di Indonesia ini membuat Indonesia memiliki potensi untuk mengekspor teh ke seluruh belahan dunia. Hingga saat ini, produksi teh Indonesia telah diekspor ke 62 negara dimana mayoritas ekspor ditujukan ke Malaysia (13,12%), Rusia(12,63%) serta Australia (10,32%).

Potensi pengeksportan teh dari Indonesia ini didasarkan pada kebutuhan teh dunia yang sangat tinggi, mengingat teh merupakan bagian dari gaya hidup masyarakat di seluruh belahan dunia (Zakaryah, 2014). Namun demikian, berdasarkan data Kementerian Pertanian (2016), volume ekspor teh terus mengalami penurunan dari tahun 2011 hingga 2015 dengan rata-rata penurunan tiap tahun sebesar 8,89% per tahun. Hal ini diakibatkan karena adanya penurunan kualitas teh serta adanya penurunan produksi teh diakibatkan karena biaya produksi yang tinggi akibat tingginya harga tenaga kerja, pupuk serta obat (Nurohman, 2018). Maka dari itu, kolaborasi dan sinergi antara pemerintah dengan petani dibutuhkan untuk menunjang dan meningkatkan kualitas produksi teh sehingga mampu meningkatkan daya saing teh Indonesia di tingkat global. Salah satu upaya untuk meningkatkan produksi teh yakni dengan pengembangan inovasi mulai dari pengadaan bibit hingga pengawasan kualitas dan jaminan mutu teh yang siap dipasarkan dengan memanfaatkan perkembangan teknologi.

Seiring dengan perkembangan zaman, menuntut seluruh orang menggunakan metode digital (Ngafifi, 2014). Hal ini berlaku untuk semua sektor termasuk sektor pertanian. Dengan menggunakan metode digital, lebih memudahkan para pelaku usaha untuk melakukan usahanya dalam upaya peningkatan kualitas sehingga produknya mampu bersaing di pasar lokal maupun internasional. Penggunaan metode digital ini juga dapat diterapkan dalam upaya pemilahan teh ketika proses klasifikasi. Karena ukuran butiran teh merupakan parameter penting untuk penyortiran, hal itu dapat diatasi dengan analisis tekstur citra. Citra dari *grade* teh yang berbeda dengan berbagai ukuran butiran akan berbeda teksturnya. Dalam kasus seperti itu, metode analisis tekstur dapat berfungsi sebagai alat yang berguna dalam memperkirakan ukuran butiran teh dengan mengklasifikasikan tekstur ke dalam kelas yang sesuai. Ini akan membantu

dalam memantau proses penilaian sebelum pengemasan teh akhir dalam varietas yang beragam (Gill, 2013).

*Deep learning* sebagai bagian dari *machine learning* merupakan salah satu cakupan yang di dalamnya terdapat berbagai sistem operasi berbasis *Artificial Intelligence*. Dua diantara sistem operasi ini ialah *Convolutional Neural Network* (CNN) CNN dapat bekerja untuk menerima input berupa citra yang nantinya akan diolah sehingga mampu membedakan suatu citra dengan citra yang lainnya. Penelitian sebelumnya dilakukan penggunaan *deep learning* untuk teh diantaranya Klasifikasi Teh Hitam secara Non-Destruktif berdasarkan Analisis Tekstur (Gill, 2013). Klasifikasi Teh Hitam dengan Probabilistics Neural Network (PNN) (Sari, 2021). Klasifikasi Teh Hitam dengan menggunakan Hidung dan Lidah Elektronik (Roy, 2014). Klasifikasi Teh dengan CNN berbasis Multi-Channel LED-Induced Fluorescence (Lin, 2019). Tetapi belum ada penelitian terkait klasifikasi teh hitam berdasarkan kualitas dengan menggunakan metode CNN berbasis citra digital. Menurut Anton. et.al (2021), metode CNN memiliki keunggulan yakni mampu memberikan akurasi terbaik dalam proses klasifikasi. Selain itu, Alzubaidi et.al (2021) menyebutkan bahwa CNN memiliki fitur pembagian bobot yang mana hal tersebut dapat menghindari adanya *overfitting*. Maka dari itu, pada penelitian ini akan dilakukan proses klasifikasi teh hitam dengan menggunakan metode CNN.

## Tujuan

Atas dasar latar belakang pada poin sebelumnya, maka dalam penelitian ini dilakukan pengolahan data dengan tujuan untuk memperoleh kemampuan dalam proses klasifikasi berbasis *machine learning* pada teh hitam menggunakan arsitektur pengolahan citra *Convolutional Neural Network* (CNN) agar diperoleh penilaian dengan tingkat konsistensi yang tinggi, efisien, efektif dan berkelanjutan

## METODE PENELITIAN

### Alat dan Bahan

Alat yang digunakan dalam penelitian ini diantaranya kamera digital SONY/ DSC-H200-20.1Mp, black box yang terbuat dari *styrofoam* serta software Matlab yang digunakan untuk pengolahan data. sedangkan bahan yang digunakan ialah teh hitam yang diperoleh dari pabrik teh Wonosari Kab. Malang sebanyak tiga kualitas yang mana masing-masing kualitas terdiri dari 700 citra sampel yang digunakan sebagai data training-validasi. Bahan lainnya yang digunakan yakni teh komersial yang dijual di masyarakat dengan merk dagang Teh Villa (sebagai kualitas grade A) Awi Black Tea (sebagai kualitas grade B), dan teh naga (sebagai kualitas grade C) yang mana masing-masing kualitas terdiri dari 300 citra sampel yang nantinya digunakan sebagai data *testing*.

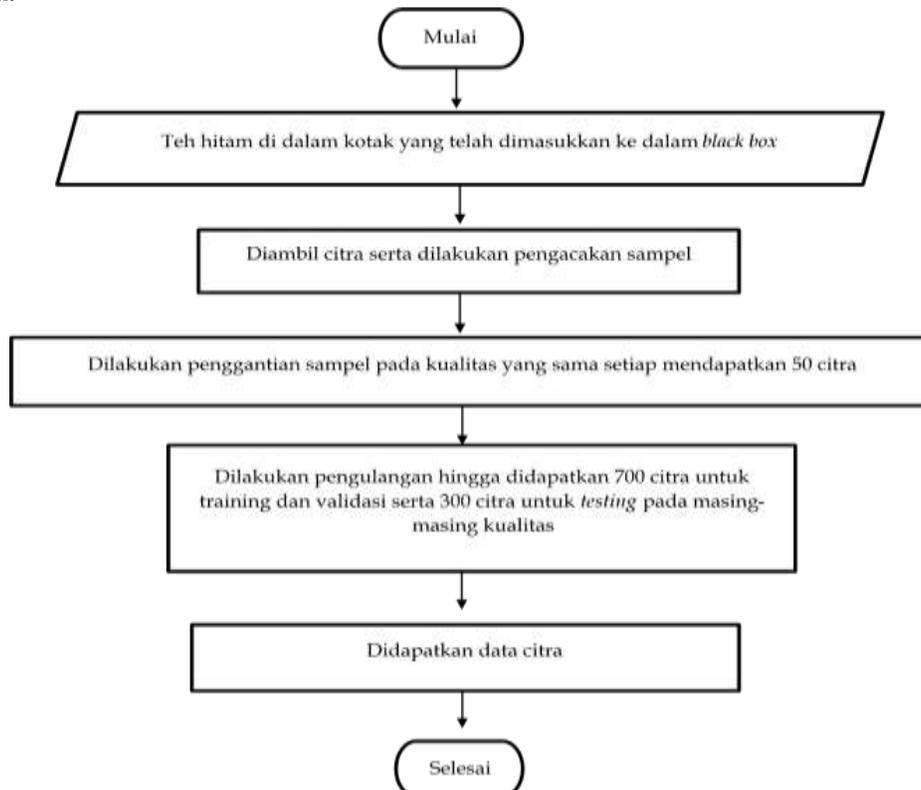
### Metode

#### 1. Pengambilan Citra Digital

Citra yang diambil merupakan citra sampel yang digunakan. Sebelum dilakukan pengambilan citra, dilakukan penyiapan alat dan bahan. Alat yang digunakan yakni kotak sampel, *black box* serta kamera digital SONY/ DSC-H200-20.1 Mp. Bahan sebanyak 50 gram yang telah ditentukan diletakkan ke dalam kotak sampel yang berasal dari *styrofoam* dengan ukuran panjang dan lebar 15 cm serta kedalaman 3 cm. Setelah bahan diletakkan ke dalam kotak sampel, selanjutnya bahan serta kotak sampel dimasukkan ke dalam *black box* yang terdiri dari 4 buah

bola lampu phillip dengan daya 3 watt telah dinyalakan terlebih dahulu. Setelah siap, dilakukan pengambilan citra sebanyak satu kali. Setelah diambil citra, dilakukan pengadukan sampel supaya objek berubah dari sebelumnya. Ketika proses pengadukan selesai, kembali diambil citra. Hal ini dilakukan secara berulang hingga mendapatkan 50 citra. Setelah didapatkan 50 citra, sampel diganti dengan grade yang masih sama dan dilakukan pengulangan kembali. Total citra yang harus diambil dari masing-masing grade adalah sebanyak 700 citra. Sehingga total pengambilan citra untuk seluruh sampel yakni 2100 citra yang nantinya akan digunakan sebagai data training sebanyak 70% (Wardana, 2021) dan data validasi sebanyak 30% (Hakim, 2021).

Selain pengambilan citra untuk data training dan validasi, juga diperlukan citra sebagai data *testing*. Prosedur pengambilan citra sama seperti sebelumnya. Hanya saja, jumlah citra yang diambil yakni 300 citra setiap sampel. Sehingga berdasarkan hal tersebut, akan didapatkan jumlah citra sebanyak 900 citra sebagai data *testing*. Maka dari itu, dapat disimpulkan bahwa jumlah citra yang diambil untuk digunakan sebagai data training dan validasi serta *testing* yakni sebanyak 3000 citra. Proses pengambilan citra digambarkan dengan diagram alir pada Gambar 1. Contoh pengambilan citra beserta penjelasan terkait jumlah citra yang digunakan ditunjukkan pada Tabel 1. Berdasarkan data hasil citra didapatkan citra yang memiliki kesamaan di setiap frame. Meskipun begitu, dalam penelitian ini tetap menggunakan metode CNN dikarenakan metode ini memberikan nilai akurasi yang tinggi. Jika dibandingkan dengan penelitian-penelitian yang telah dilakukan sebelumnya dengan metode yang berbeda belum didapatkan nilai akurasi yang tinggi. Sehingga dalam penelitian ini digunakan metode CNN dengan harapan agar akurasi yang didapatkan lebih baik dari penelitian-penelitian yang telah dilakukan sebelumnya.



Gambar 1. Diagram Alir Proses Pengambilan Citra Digital

**Tabel 1.** Contoh Citra Teh Hitam Berdasarkan Kualitasnya

| Proses                | Jenis Teh | Citra   | Keterangan   | Jumlah Citra |
|-----------------------|-----------|---|--|--------------|
| Training-<br>validasi | Grade A   |    | Teh BP 1 yang diperoleh dari Kebun Teh Wonosari  | 700          |
|                       | Grade B   |    | Teh Fann yang diperoleh dari Kebun Teh Wonosari  | 700          |
|                       | Grade C   |    | Tea Waste yang diperoleh dari Kebun Teh Wonosari   | 700          |
| Testing               | Grade A   |    | Teh yang diproduksi oleh PT Karya Mas Makmur dengan merek dagang Teh Villa                       | 300          |
|                       | Grade B   |   | Teh dari produksi PTPN IV Bah Butong Sidamanik, Sumatera Utara dengan merek dagang Awi Black Tea | 300          |
|                       | Grade C   |  | Teh Naga   | 300          |

## 2. Pre-processing Citra Digital

Setelah dilakukan pengambilan citra digital, selanjutnya dilakukan *pre-processing* citra digital. Hal ini bertujuan untuk menyeragamkan citra satu dengan citra lainnya. Pre-processing dilakukan dengan memotong objek citra yang tidak diperlukan sehingga hanya menyisakan bagian objek citra yang diperlukan untuk proses CNN. Selanjutnya dilakukan penyesuaian ukuran sesuai dengan ketentuan yang telah dipilih sebelumnya yakni ukuran 224x224x3 pixel. Penyesuaian ukuran ini dilakukan dengan memasukkan code sebagai berikut

```
% Resize teh images to match teh network input layer.
augimdsTrain = augmentedImageDatastore([224 224 3],imdsTrain);
augimdsValidation = augmentedImageDatastore([224 224 3],imdsValidation);
datacobatrain1=augmentedImageDatastore([224 224 3],datacoba1);
```

```
datacobatrain2=augmentedImageDatastore([224 224 3],datacoba2);  
datacobatrain3=augmentedImageDatastore([224 224 3],datacoba3)
```

### 3. Pengujian dengan Metode CNN

Metode yang digunakan yakni metode CNN. Pemilihan metode ini mengacu kepada penelitian yang dilakukan oleh Hendrawan (2021). Pada metode ini digunakan dua *optimizer* yakni AlexNet (Irfansyah, 2021) dan Resnet50 (Celano, 2021). Pemilihan optimizer AlexNet didasarkan karena AlexNet merupakan salah satu optimizer yang memiliki arsitektur hampir mirip dengan LeNet tetapi lebih dalam dengan tambahan filter pada setiap layernya. Sedangkan pemilihan optimizer Resnet dikarenakan optimizer ini memiliki fitur *skip connection* dan fitur *batch normalization*. Sehingga dalam penelitian ini membandingkan kedua optimizer tersebut apakah mampu untuk mengklasifikasikan citra yang diberikan. Dari masing-masing optimizer tersebut digunakan 3 solver yakni SGDm (Setiawan, 2021), Adam (Rochmawati, 2021) serta RMSProp (Wikarta, 2020). Dari masing-masing solver digunakan initial rate masing-masing 0,00005 (Hendrawan, 2022) serta 0,0001 (Jepkoech, 2021) dengan jumlah epoch sebanyak 20. Pada metode CNN dilakukan penginputan data citra. Data citra yang telah diinput kemudian diproses untuk dilakukan training-validasi. Proses training-validasi menggunakan metode *cross validation* (Naufal, 2021) yang mana 70% data digunakan sebagai data training dan 30% data digunakan sebagai data validasi. Setelah didapatkan hasil, selanjutnya dilakukan proses *testing* untuk menguji akurasi metode yang digunakan.

## HASIL DAN PEMBAHASAN

Hasil dari proses training dan validasi ditunjukkan pada Tabel 2. Pada penelitian ini digunakan beberapa arsitektur diantaranya digunakan AlexNet dan ResNet50. Untuk analisis sensitivitas digunakan *learning rate* sebesar 0.00005 dan 0.0001 serta *optimizer* SGDm, Adam serta RMSProp. Berdasarkan hasil tersebut didapatkan nilai akurasi yang bervariasi dengan nilai akurasi yang tertinggi sebesar 100% dan terendah sebesar 88.57%. Selain itu didapatkan bahwa nilai *learning rate* 0.0001 menghasilkan rata-rata akurasi dengan nilai yang tinggi sebesar 99.84% jika dibandingkan dengan *learning rate* 0.00005 yang memiliki nilai rata-rata akurasi sebesar 98.01%. Hal ini sesuai dengan penelitian yang dilakukan oleh Hendrawan (2021) yang menyatakan bahwa nilai *learning rate* 0.0001 menghasilkan nilai akurasi yang lebih baik dibandingkan dengan *learning rate* 0.00005 dan 0.0005. Sedangkan untuk arsitektur ResNet50 memberikan nilai rata-rata akurasi yang tinggi sebesar 99.84% jika dibandingkan dengan AlexNet yang memiliki nilai rata-rata akurasi sebesar 98.02%. Hasil tersebut menunjukkan bahwa arsitektur ResNet50 merupakan arsitektur terbaik jika dibandingkan dengan arsitektur AlexNet karena menghasilkan nilai akurasi yang paling tinggi. Hal ini dikarenakan arsitektur ResNet 50 memiliki kelebihan yakni adanya penurunan tingkat *error* dibanding arsitektur lainnya serta adanya pengenalan terhadap konsep pembelajaran residual sehingga dapat menghasilkan nilai akurasi yang tinggi (Saleem, 2022). Tetapi hasil akurasi ini berbanding terbalik dengan waktu rata-rata yang dihasilkan dimana arsitektur ResNet50 membutuhkan waktu training yang lebih lama yakni selama 42 menit 27 detik jika dibandingkan dengan arsitektur AlexNet yang hanya membutuhkan rata-rata selama 13 menit 30 detik. Hal ini dikarenakan ResNet50 memiliki kelemahan yakni adanya adaptasi hyperparameter yang berlebihan untuk menyelesaikan suatu proses akibat adanya penumpukan modul (Saleem, 2022). Hasil dari penelitian ini sesuai dengan hasil penelitian yang dilakukan oleh Hendrawan (2021).

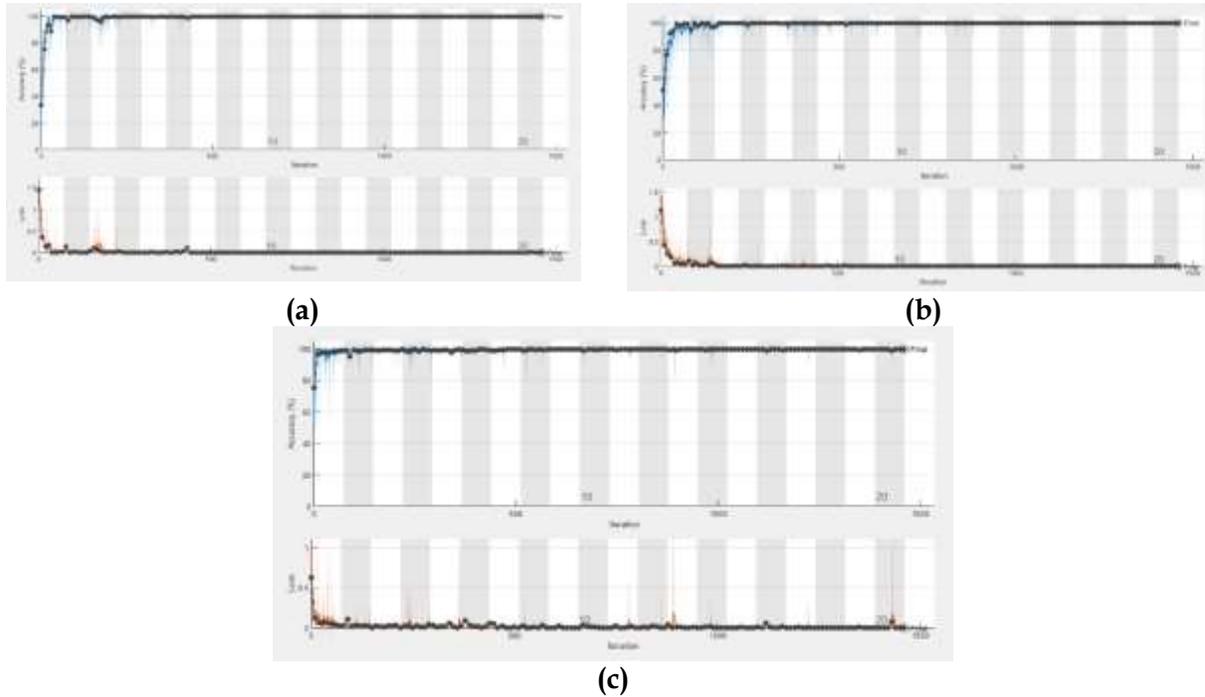
Berdasarkan hasil training-validasi didapatkan beberapa arsitektur dengan nilai akurasi mencapai 100% diantaranya AlexNet dengan solver Adam dan *learning rate* 0.00005; AlexNet dengan solver RMSProp dan *learning rate* 0.0001; serta ResNet50 dengan solver SGDm dan *learning rate* 0.00005. Proses training-validasi dari ketiga arsitektur dengan nilai akurasi terbaik dapat dilihat pada Gambar 2. Pada gambar tersebut dapat dilihat bahwa ketiga arsitektur memiliki pola yang sama dimana pada setiap arsitektur yang digunakan, pada proses training, nilai akurasi akan meningkat setiap peningkatan iterasi yang diproses hingga konvergen mendekati nilai akurasi 100%. Sedangkan, nilai loss akan semakin turun setiap peningkatan iterasi hingga konvergen mendekati nilai 0. Hasil penelitian ini sesuai dengan penelitian yang dilakukan oleh Hendrawan (2021) yang mana pada penelitiannya, nilai akurasi akan semakin naik seiring penambahan iterasi sedangkan nilai loss akan semakin menurun seiring penambahan jumlah iterasi. Dalam penelitian ini, jumlah iterasi yang digunakan ialah 1460 iterasi dengan epoch sebanyak 20, sehingga jumlah iterasi per epoch sebanyak 73 iterasi. Berdasarkan grafik tersebut di atas juga dapat dilihat bahwa pada proses validasi nilai akurasi dan juga loss mengikuti nilai training yang mana untuk nilai akurasi akan semakin meningkat hingga konvergen pada setiap penambahan iterasi serta nilai loss akan menurun hingga konvergen seiring dengan adanya penambahan iterasi

**Tabel 2.** Performansi CNN untuk Mengklasifikasikan Teh Hitam berdasarkan Kualitas

| Architecture | Solver         | Initial<br><i>learning rate</i> | epoch     | miniba<br>cth size | max<br>iteration | Accuracy<br>(%) | Training<br>Time (min) |
|--------------|----------------|---------------------------------|-----------|--------------------|------------------|-----------------|------------------------|
| Alexnet      | RMSProp        | 0.00005                         | 20        | 20                 | 1460             | 99.84           | 12 min 31 sec          |
|              | <b>Adam</b>    | <b>0.00005</b>                  | <b>20</b> | <b>20</b>          | <b>1460</b>      | <b>100</b>      | <b>13 min 21 sec</b>   |
|              | SGDm           | 0.00005                         | 20        | 20                 | 1460             | 88.57           | 12 min 31 sec          |
|              | <b>RMSProp</b> | <b>0.0001</b>                   | <b>20</b> | <b>20</b>          | <b>1460</b>      | <b>100</b>      | <b>12 min 43 sec</b>   |
|              | Adam           | 0.0001                          | 20        | 20                 | 1460             | 99.84           | 14 min 16 sec          |
|              | SGDm           | 0.0001                          | 20        | 20                 | 1460             | 99.88           | 12 min 59 sec          |
| Resnet50     | RMSProp        | 0.00005                         | 20        | 20                 | 1460             | 99.84           | 37 min 04 sec          |
|              | Adam           | 0.00005                         | 20        | 20                 | 1460             | 99.84           | 43 min 00 sec          |
|              | <b>SGDm</b>    | <b>0.00005</b>                  | <b>20</b> | <b>20</b>          | <b>1460</b>      | <b>100</b>      | <b>41 min 34 sec</b>   |
|              | RMSProp        | 0.0001                          | 20        | 20                 | 1460             | 99.84           | 40 min 56 sec          |
|              | Adam           | 0.0001                          | 20        | 20                 | 1460             | 99.68           | 51 min 31 sec          |
|              | SGDm           | 0.0001                          | 20        | 20                 | 1460             | 99.84           | 49 min 13 sec          |

Setelah didapatkan arsitektur yang terbaik pada proses training-validasi, selanjutnya dilakukan *testing* dengan menggunakan arsitektur tersebut. Hasil *testing* menggunakan *confusion matrix* dapat dilihat pada **Tabel 3**. Berdasarkan citra tersebut, citra (a) merupakan performansi data *testing* pada arsitektur AlexNet dengan menggunakan optimizer Adam dan *learning rate* 0.00005. Citra (b) merupakan performansi data *testing* pada arsitektur AlexNet dengan menggunakan optimizer RMSProp dan *learning rate* 0.0001. Citra (c) merupakan performansi data *testing* pada arsitektur ResNet50 dengan menggunakan optimizer SGDm dan *learning rate* 0.00005. *Confusion matrix* pada citra di atas memberikan penjelasan bahwa hampir seluruh arsitektur terbaik yang dipilih menghasilkan nilai akurasi untuk data *testing* sebesar 100% untuk memprediksi teh dengan kualitas grade A, grade B, dan grade C. Hanya terdapat satu arsitektur yang memiliki eror yakni AlexNet dengan menggunakan optimizer Adam dan *learning rate*

0.00005. Pada arsitektur tersebut, terdapat 0.3% *error* dalam memprediksi teh dengan kualitas B yang mana teh tersebut masuk ke dalam kelompok teh dengan kualitas A. Hal ini menjadikan akurasi prediksi untuk grade B menjadi 99.7%. Hampir keseluruhan *confusion matrix* pada arsitektur yang digunakan dalam penelitian ini menghasilkan akurasi sebesar 100%. Artinya model mampu mengklasifikasikan teh tepat sesuai dengan kelasnya. Tetapi, terdapat beberapa arsitektur yang menghasilkan akurasi kurang dari 100%. Ketidaksesuaian kelas klasifikasi ini kebanyakan terjadi pada grade A dan Grade B. Hal ini terjadi dikarenakan adanya sedikit kemiripan teh pada kategori Grade A dan Grade B



**Gambar 2.** Grafik Proses Training-Validasi. (a) AlexNet dengan solver Adam dan *learning rate* 0.00005; (b) AlexNet dengan solver RMSProp dan *learning rate* 0.0001; (c) ResNet50 dengan solver SGDm dan *learning rate* 0.00005

**Tabel 3** Nilai Persentasi Akurasi pada Arsitektur Terbaik

| Architecture  | Persentase Akurasi |         |         |
|---|--------------------|---------|---------|
|   | Grade A            | Grade B | Grade C |
| AlexNet dengan solver Adam dan <i>learning rate</i> 0.00005   | 99.7%              | 100%    | 100%    |
| AlexNet dengan solver RMSProp dan <i>learning rate</i> 0.0001 | 100%               | 100%    | 100%    |
| ResNet50 dengan solver SGDm dan <i>learning rate</i> 0.00005  | 100%               | 100%    | 100%    |

## KESIMPULAN

### Kesimpulan

Kualitas teh hitam dibagi menjadi tiga yakni grade A, grade B dan grade C. Pada penelitian ini digunakan CNN untuk melakukan klasifikasi dengan menggunakan arsitektur AlexNet dan ResNet50. Hasil penelitian menunjukkan bahwa akurasi dari proses training-validasi tertinggi

didapatkan oleh arsitektur AlexNet dengan solver Adam dan *learning rate* 0.00005; AlexNet dengan solver RMSProp dan *learning rate* 0.0001; ResNet50 dengan solver SGDM dan *learning rate* 0.00005 dengan akurasi mencapai 100%. Hasil *testing* berdasarkan arsitektur terbaik didapatkan bahwa arsitektur AlexNet dengan solver Adam dan *learning rate* 0.00005 mampu mengklasifikasikan grade B dan grade C sesuai dengan kelasnya tetapi terdapat sedikit eror pada grade sehingga akurasi *testing* didapatkan sebesar 99.7%. Sedangkan untuk arsitektur AlexNet dengan solver RMSProp dan *learning rate* 0.0001 dan ResNet50 dengan solver SGDM dan *learning rate* 0.00005 mampu mengklasifikasikan teh hitam tepat sesuai dengan kelasnya sehingga mampu menghasilkan akurasi *testing* sebesar 100%. Berdasarkan hasil tersebut, maka dapat disimpulkan bahwa model CNN dapat bekerja secara efektif untuk mengklasifikasikan teh hitam.

#### **UCAPAN TERIMA KASIH**

Terima kasih kepada LPDP (Lembaga Pengelola Dana Pendidikan) dari Kementerian Keuangan selaku pemberi dana pada penelitian ini, juga kepada seluruh pihak yang telah membantu dalam proses pengambilan citra serta pengolahan data.

#### **PENDANAAN**

Penelitian ini didanai oleh dana penelitian awardee beasiswa pendidikan Indonesia, Lembaga Pengelola Dana Pendidikan (LPDP).

#### **CONFLICT OF INTEREST**

Pemberi dana tidak memiliki peran dalam desain penelitian; dalam pengumpulan, analisis, atau interpretasi data; dalam penulisan naskah; atau dalam keputusan untuk mengumumkan hasil penelitian

#### **DAFTAR REFERENSI**

- Alzubaidi, L. *et al.* (2021) *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, Journal of Big Data*. Springer International Publishing. doi: 10.1186/s40537-021-00444-8.
- Anton, A. *et al.* (2021) 'Application of Deep Learning Using Convolutional Neural Network (CNN) Method For Women's Skin Classification', *Scientific Journal of Informatics*, 8(1), pp. 144-153. doi: 10.15294/sji.v8i1.26888.
- Celano, G. G. A. (2021) 'A ResNet-50-based Convolutional Neural Network Model for Language ID Identification from Speech Recordings', *SIGTYP 2021 - 3rd Workshop on Research in Computational Typology and Multilingual NLP, Proceedings of the Workshop*, pp. 136-144. doi: 10.18653/v1/2021.sigtyp-1.13.
- Gill, G. S., Kumar, A. and Agarwal, R. (2013) 'Nondestructive grading of black tea based on physical parameters by texture analysis', *Biosystems Engineering*, 116(2), pp. 198-204. doi: 10.1016/j.biosystemseng.2013.08.002.
- Hakim, A. A. (2021) 'Klasifikasi Human Activity Recognition Menggunakan Metode CNN', *Jurnal Repositor*, 3(2). doi: 10.22219/repositor.v3i2.1265.

- Hendrawan, Y. *et al.* (2022) 'Deep Learning to Detect and Classify the Purity Level of Luwak Coffee Green Beans', *Pertanika Journal of Science and Technology*, 30(1), pp. 1-18. doi: 10.47836/pjst.30.1.01.
- Hendrawan, Y. *et al.* (2021) 'Classification of soybean tempe quality using deep learning', *IOP Conference Series: Earth and Environmental Science*, 924(1), pp. 1-9. doi: 10.1088/1755-1315/924/1/012022.
- Irfansyah, D., Mustikasari, M. and Suroso, A. (2021) 'Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi', *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, 6(2), pp. 87-92. Available at: <http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2802>.
- Jepkoech, J. *et al.* (2021) 'The Effect of Adaptive Learning Rate on the Accuracy of Neural Networks', *International Journal of Advanced Computer Science and Applications*, 12(8), pp. 736-751. doi: 10.14569/IJACSA.2021.0120885.
- Lin, H. *et al.* (2019) 'Robust classification of tea based on multi-channel LED-induced fluorescence and a convolutional neural network', *Sensors (Switzerland)*, 19(21), pp. 1-9. doi: 10.3390/s19214687.
- Naufal, M. F. *et al.* (2021) 'Analisis Perbandingan Algoritma Klasifikasi Citra Chest X-ray Untuk Deteksi Covid-19', *Teknika*, 10(2), pp. 96-103. doi: 10.34148/teknika.v10i2.331.
- Ngafifi, M. (2014) 'Kemajuan Teknologi Dan Pola Hidup Manusia Dalam Perspektif Sosial Budaya', *Jurnal Pembangunan Pendidikan: Fondasi dan Aplikasi*, 2(1), pp. 33-47. doi: 10.21831/jppfa.v2i1.2616.
- Nurohman, Lirphandari RH, Dwiastuti R. Analisis Kinerja Pasar Benih Padi Di Kabupaten Madiun. *J Ekon Pertan dan Agribisnis*. 2018;2(5):405-416. doi:10.21776/ub.jepa.2018.002.05.6
- Rochmawati, N. *et al.* (2021) 'Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam', *Journal of Information Engineering and Educational Technology*, 5(2), pp. 44-48. doi: 10.26740/jieet.v5n2.p44-48.
- Roy, R. B. *et al.* (2014) 'Improved classification of black tea employing feature level fusion of electronic nose and tongue responses', *International Conference on Control, Instrumentation, Energy and Communication, CIEC 2014*, pp. 166-170. doi: 10.1109/CIEC.2014.6959071.
- Saleem, M. A. *et al.* (2022) 'Comparative Analysis of Recent Architecture of Convolutional Neural Network', 2022.
- Sari, E. I., Prasetya, N. H. and Lubis, R. S. (2021) 'Black Tea Grade Classification Using Probabilistic Neural Network ( PNN ) Corresponding Author ', 2(1), pp. 7-12.

- Setiawan, W. *et al.* (2021) 'Deep Convolutional Neural Network AlexNet and Squeezenet for Maize Leaf Diseases Image Classification', *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 4, pp. 0-7. doi: 10.22219/kinetik.v6i4.1335.
- Wardana, B. K., Rachmawati, E. and Wirayuda, T. A. B. (2021) 'Pengenalan Gestur Tangan Statis Menggunakan CNN Dengan Arsitektur Efficient-Net B4', 8(2), pp. 3446-3463.
- Wikarta, A., Sigit Pramono, A. and Ariatedja, J. B. (2020) 'Analisa Berbagai Optimizer Pada Convolutional Neural Network Untuk Deteksi Pemakaian Masker Pengemudi Kendaraan', *Seminar Nasional Informatika, 2020(Semnasif)*, pp. 69-72.
- Zakariyah MY. 2014. Analisis Daya Saing Teh Indonesia di Pasar Internasional. *Agrimeta: Jurnal Pertanian Berbasis Keseimbangan Ekosistem*. Volume 4, Nomor 8, Halaman 29-37. Denpasar: Universitas Mah Saraswati Denpasar