



Optimasi Model TL-CNN Untuk Klasifikasi Citra CIFAR-10

Rastrri Prathivi

¹Jurusan Teknologi Informasi, Fakultas Teknologi Informasi dan Komunikasi, Universitas Semarang¹vivi@usm.ac.id

Abstract

The low accuracy when performing the image classification process is a problem that often occurs. The image classification process requires the completeness of the features of the image which form an informative image pattern so that information from the image can be displayed. The purpose of this study is to classify images in the CIFAR-10 image dataset using the CNN method. Initially the CNN method gave an accuracy of 79.4% but had a long computation time of 12 hours with 10,000 iterations. The optimization process for the CNN method is carried out by combining the CNN method, the PCA algorithm and the t-SNE algorithm. The algorithm is used to reduce the length of the image matrix in the initial transfer of learning without reducing the information in the image so that the classification process can be done correctly. The final result obtained from the optimization has an accuracy of 90.5%. With an optimization rate of 11%. The resulting time is more efficient, namely 3 hours for the feature transfer-value process and 6 minutes for the testing process with 10,000 iterations.

Keywords: CNN, convolutional neural network, CIFAR-10, image classification

Abstrak

Rendahnya akurasi ketika melakukan proses klasifikasi citra merupakan masalah yang seringkali terjadi. Proses klasifikasi citra memerlukan kelengkapan fitur dari citra tersebut yang membentuk pola citra yang informatif sehingga informasi dari citra dapat dimunculkan. Tujuan penelitian ini adalah mengklasifikasikan citra dalam dataset citra CIFAR-10 menggunakan metode CNN. Awalnya metode CNN memberikan hasil akurasi 79.4% tetapi memiliki waktu komputasi yang lama yaitu sebesar 12 jam dengan 10.000 iterasi. Proses optimasi pada metode CNN dilakukan dengan menggabungkan metode CNN, algoritma PCA dan t-SNE. Algoritma tersebut digunakan untuk mereduksi panjang matrik citra pada proses transfer awal pembelajaran tanpa mengurangi informasi dalam citra tersebut sehingga proses klasifikasi dapat dilakukan dengan benar. Hasil akhir yang diperoleh dari optimasi tersebut memiliki akurasi 90.5%. Dengan tingkat optimasi sebesar 11%. Waktu yang dihasilkan lebih efisien yaitu 3 jam untuk proses transfer nilai (transfer-value) fitur dan 6 menit untuk proses testing dengan 10.000 iterasi.

Kata kunci: CNN, jaringan syaraf, CIFAR-10, klasifikasi citra

1. Pendahuluan

Klasifikasi pada citra diperlukan untuk mengelompokkan berbagai bentuk citra menjadi satu kelompok yang memiliki ciri yang sama. Klasifikasi citra pada ranah spasial dapat menggunakan pixel dan fitur yang terdapat pada citra. Fitur yang terdapat pada citra berupa garis, sudut, area bidang citra, warna dan kurva.

Pengenalan citra dapat memberikan informasi yang terkait dengan bentuk dan ciri yang dimiliki oleh sebuah

citra. Rendahnya akurasi ketika melakukan proses klasifikasi dan pengenalan citra merupakan masalah yang seringkali terjadi. Proses klasifikasi citra memerlukan kelengkapan fitur dari citra tersebut yang akan membentuk pola citra yang informatif sehingga informasi dari citra dapat dimunculkan. Metode berbasis jaringan saraf konvolusi (convolutional neural network/ CNN) merupakan metode yang banyak diterapkan untuk mendapatkan informasi fitur pada sebuah citra. Metode ini memiliki akurasi yang tinggi untuk memperoleh informasi fitur yang lengkap pada sebuah citra melalui

proses training dari citra pelatihan. Tetapi penggunaan metode CNN untuk diterapkan dalam pengenalan fitur citra memiliki tantangan tersendiri yaitu dimensi fitur citra yang diekstraksi akan meningkat secara dramatis dengan lebih banyak lapisan jaringan yang terbentuk. Semakin lengkap fitur citra diekstraksi maka semakin besar lapisan jaringan yang terbentuk sehingga dimensi citra juga semakin meningkat. Banyak penelitian terkait yang membahas tentang cara mereduksi fitur citra menggunakan metode CNN. Beberapa penelitian yang terkait dengan akurasi algoritma PCA dan t-SNE sudah banyak dilakukan. Zhong melakukan penelitian pada citra hiperspektral dengan mengadopsi t-SNE untuk memproyeksikan data mentah citra hiperspektral dan mengekstraksi fitur spektral spasial untuk mendapatkan representasi fitur ke dalam bidang dua dimensi. Dia menggunakan metode residual network (ResNets) dan t-SNE dengan 1000 iterasi. Gabungan metode tersebut memiliki performa lebih baik dan lebih stabil.[1]

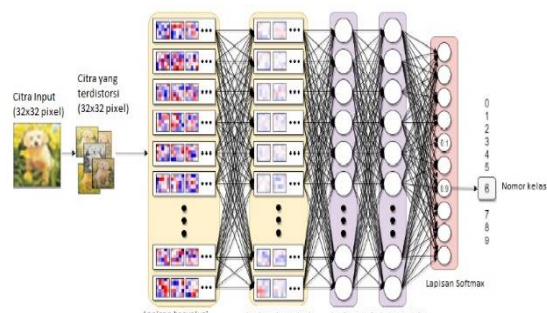
J.Ma dan Y. Yuan melakukan penelitian dengan menggabungkan metode CNN dengan PCA. Hasil dari penelitian ini menunjukkan bahwa akurasi rata-rata algoritma CNN sebelum menggunakan PCA sebesar 87,98%. Setelah menerapkan CNN dengan PCA akurasinya lebih besar yaitu 90,35 % dengan pengurangan dimensi fitur citra sebesar 4 kali dari sebelum menggunakan PCA[2]. Gao melakukan penelitian pada citra hiperspektral yang diklasifikasi dengan metode t-SNE CNN dibandingkan dengan dimension-reduced CNN (DR-CNN) dan CNN multiskala. Hasil yang diperoleh menunjukkan bahwa metode t-SNE CNN memiliki akurasi rata-rata paling tinggi yaitu 98% dibandingkan metode DR-CNN 97% dan CNN multiskala 92% [3]. Dalam penelitian yang dilakukan oleh Kobak yang memvisualisasi ribuan citra sel RNA (Ribonucleic Acid) menggunakan kombinasi metode t-SNE dengan inisialisasi menggunakan PCA. Hasil yang diperoleh adalah memiliki rata-rata tingkat pembelajaran 2.058.652/12, tingkat prediksi distribusi pixel pada citra sebesar 30, dan nilai perbesaran citra 4 [4]. Husnain dalam penelitiannya memvisualisasi angka dan tulisan tangan Urdu asli menggunakan metode t-SNE dengan mengeksplorasi struktur lokal dan global dari kumpulan data besar pada skala yang berbeda. Visualisasi yang diproduksi oleh t-SNE mengungguli teknik analisis komponen utama (PCA) dan auto-encoders (AE)[5]. Giuste dalam penelitiannya mengklasifikasikan citra menggunakan dataset CIFAR-10. Mereka meningkatkan akurasi klasifikasi dengan mengoptimasi bobot jaringan optimal transfer learning (TL) dengan memilih 1000 komponen utama teratas dari TLVGG, TL-Inception, HOG, intensitas piksel, dan CIFAR-VGG, dengan akurasi pengujian sebesar 94,6% [6]. Basha melakukan penelitian terhadap metode CNN seberapa banyak jaringan yang terbentuk untuk melakukan eksperimen pengenalan citra pada beberapa dataset yang berbeda yaitu CIFAR-10, CIFAR-100, Tiny ImageNet, dan CRCHistoPhenotypes [7]. Dalam

penelitian ini menggunakan dataset citra yang berasal dari dataset public CIFAR-10. Di dalam dataset CIFAR-10 terdapat 10 kelas citra yang setiap kelas memiliki 5.000 citra training dan 1.000 citra testing [8]. Citra training dalam penelitian ini sejumlah 50.000 dan citra testing sejumlah 10.000. Citra di dalam dataset CIFAR-10 merupakan jenis citra berwarna yang memiliki dimensi 32x32. Penelitian ini bertujuan untuk mengklasifikasi citra berdasarkan kelasnya melalui ekstraksi fitur citra dan melakukan proses pengenalan citra pada dataset CIFAR-10 sehingga memperoleh informasi dari citra tersebut sesuai dengan bentuk dan ciri citra. Ekstraksi fitur citra pada penelitian ini menggunakan metode CNN. Sedangkan optimasi pengenalan fitur citra dan reduksi dimensi citra menggunakan algoritma PCA dan t-SNE. Algoritma tersebut akan mereduksi citra CIFAR-10 tanpa mengurangi informasi pada citra tersebut. Metode CNN yang dioptimasi dengan t-SNE dan PCA akan diterapkan pada proses transfer awal pembelajaran/ *transfer learning inception* (TL-Inception). Model *transfer learning* dapat memberikan model jaringan yang kompleks dengan tingkat akurasi yang tinggi untuk membentuk klasifikasi citra CIFAR-10 yang lebih akurat [9]. Dalam penelitian yang dilakukan oleh Hussain, beliau menggunakan model arsitektur CNN Inception V3 untuk menentukan efisiensi dan akurasi dataset citra CIFAR-10 melalui model transfer learning (TL). Hasil akurasi yang diperoleh adalah sebesar 70,1% dengan efisiensi GPU dan CPU lebih baik [10]. Klasifikasi terhadap beberapa dataset menggunakan model pra latih atau transfer learning dan CNN diterapkan juga oleh Muhammed. Hasil akurasi tertinggi sebesar 99% dihasilkan dari model TL CNN v3 untuk dataset ke-1 sedangkan model ResNet v2 memberikan hasil akurasi sebesar 87% dan 97% untuk dataset ke-2 dan ke-3 [11].

2. Metode Penelitian

2.1. Algoritma Metode CNN

Awalnya metode CNN pada citra CIFAR-10 diterapkan tanpa optimasi. Metode CNN ini menggunakan jaringan yang memiliki dua lapisan konvolusional, dua lapisan yang terhubung sepenuhnya dan lapisan akhir yaitu lapisan softmax yang merupakan lapisan klasifikasi. Arsitektur metode CNN dapat dilihat pada gambar 1.



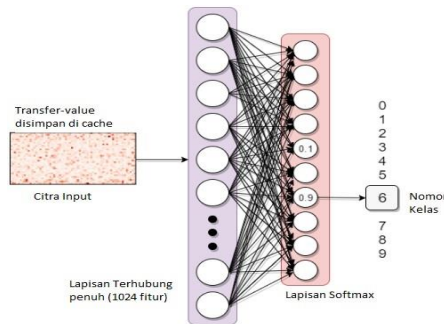
Gambar 1. Arsitektur Metode CNN

Algoritma pada metode CNN diawali dengan proses preprocessing. Pada langkah yang pertama ini preprocessing dilakukan untuk data training dan data testing. Di dalam preprocessing citra yang di-input-kan akan mengalami distorsi citra secara acak. Hal ini menyebabkan citra training menjadi lebih besar ukurannya. Sedangkan pada pembentukan neural network pada fase testing, citra testing akan mengalami distorsi di bagian tengah saja. Neural network yang sudah terbentuk selanjutnya perlu dioptimasi pada proses training. Adam Optimizer digunakan untuk meminimalisir *loss function*. Untuk mengoptimalkan kinerja neural network maka pada langkah ketiga ditambahkan bobot pada lapisan konvolusional. Selanjutnya langkah keempat adalah mengambil output pada lapisan konvolusi serta menambahkan fungsi optimasi iterasi. Fungsi optimasi iterasi ini digunakan untuk mengoptimalkan sejumlah iterasi dan secara bertahap akan meningkatkan variabel lapisan jaringan.

Pada setiap iterasi kumpulan sampel data baru akan dipilih dari dataset training dan program akan mengoptimasi berdasarkan data sampel tersebut. Hasilnya akan dicetak setiap 100 iterasi dan akan disimpan setiap 1000 iterasi setelah iterasi terakhir dijalankan. Akurasi dari proses konvolusi neural network ditentukan dengan perhitungan confusion matrix. Dan langkah terakhir adalah menghitung klasifikasi dan menampilkan hasil prediksi dari dataset testing

2.2. Arsitektur Model TL-Inception CNN

Model Transfer Learning Inception CNN atau dikenal dengan nama Model Inception v3 adalah berasal dari Google cloud machine learning. Untuk melatih dataset training menggunakan model tersebut langsung di komputer terlalu berat sehingga pada penelitian ini penulis akan mengunduh model Inception yang sudah dilatih sebelumnya dan menggunakannya untuk mengklasifikasi citra CIFAR-10 dan membangun classifier.



Gambar 2. Arsitektur Model TL-Inception CNN

Pada gambar 2 terlihat bahwa pada model TL-Inception digunakan sebagai pra latih (pretraining) bagi dataset neural network yang kedua dan memiliki struktur lapisan yang kompleks. Transfer-value ini berisi perhitungan fitur dari dataset yang diproses. Transfer –

value ini kemudian digunakan sebagai input pada neural network kedua yang akan dilatih dengan kelas-kelas dari dataset baru. Hasil dari klasifikasi akhir didasarkan pada transfer-value yang diperoleh dari model TL-Inception.

2.3. Algoritma Model TL-CNN

Proses awal dalam algoritma model TL-CNN adalah klasifikasi citra menggunakan model inception V3 yang diterapkan pada citra CIFAR-10. Model inception ditransfer menjadi objek model. Dataset pada CIFAR-10 yang ditransfer ke model inception memerlukan skala pixel 0 sampai 255. Sedangkan pada dataset CIFAR-10 hanya akan mengembalikan nilai pixel antara 0 sampai 1. Maka diperlukan sebuah objek untuk menampung hasil perkalian dengan 255 pada data training dan data testing.

```

Program Optimasi_PCA_t-SNE
#Input:
# Import algoritma PCA dan t-SNE dari library sklearn
from sklearn.decomposition import PCA
from sklearn.manifold import TSNE
transfer_values = transfer_values_train[0:1000]
cls = cls_train[0:1000]
#Proses algoritma PCA dan t-SNE:
# Mengurangi dimensi 2048 tmenjadi 50 menggunakan PCA
pca = PCA(n_components=50)
transfer_values_50d = pca.fit_transform(transfer_values)
# Mengurangi 2 dimensi menggunakan t-SNE
tsne = TSNE(n_components=2)
transfer_values_reduced = tsne.fit_transform(transfer_values_50d)
#Output:
# fungsi untuk plot ke scatter
def plot_scatter(values, cls):
    u.plot_scatter(values=values, cls=cls, num_classes=num_classes)
plot_scatter(transfer_values_reduced, cls)
    
```

Penerapan algoritma PCA dan t-SNE dilakukan pada langkah yang kedua. Listing program Optimasi_PCA_t-SNE digunakan untuk mereduksi transfer-value dengan metode PCA. Pada awalnya citra memiliki panjang array 2048 direduksi menjadi 50. Tingkat optimasi untuk mereduksi panjang array pada citra memiliki angka ideal sebesar minimal 85%. Prosentase tersebut menunjukkan bahwa semakin tinggi tingkat optimasi akan semakin banyak reduksi yang dilakukan pada citra yang berdampak pada kecepatan komputasi untuk mengesktrak dan mengklasifikasi citra. Perhitungan tingkat optimasi reduksi citra dihitung dengan rumus:

$$Optimasi = \frac{LA_0 - LA_1}{LA_0} \times 100\% \tag{1}$$

dengan LA₀ = Panjang array awal dan LA₁ = Panjang array akhir.

Langkah ketiga adalah terbentuknya jaringan baru yang mengambil nilai transfer-value sebagai input yang kemudian menghasilkan output pada lapisan softmax berupa klasifikasi citra CIFAR-10.

2.4 Formula Akurasi dan Tingkat Optimasi

Akurasi pada algoritma CNN dan TL-CNN dihitung dengan metode Confussion Matrix.

Rumus Confusion Matrix:

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

dengan TP = True positif, positif tuple pada dataset citra yang diklasifikasikan dengan benar, TN = True negatif, negative tuple pada dataset citra yang diklasifikasikan dengan benar, FP = False Positif, negative tuple yang diklasifikasikan sebagai kelas positif dan FN = False Negatif, negative tuple yang diklasifikasikan sebagai kelas negatif.

Tingkat optimasi metode CNN menjadi metode TL-CNN secara ideal ditentukan minimal sebesar 10%. Prosentase tersebut menunjukkan adanya peningkatan akurasi metode CNN dan TL-CNN. Kenaikan sebesar 10% cukup baik pada varian metode CNN karena metode CNN memiliki tingkat akurasi yang tinggi.

Tingkat optimasi akurasi metode dihitung dengan rumus:

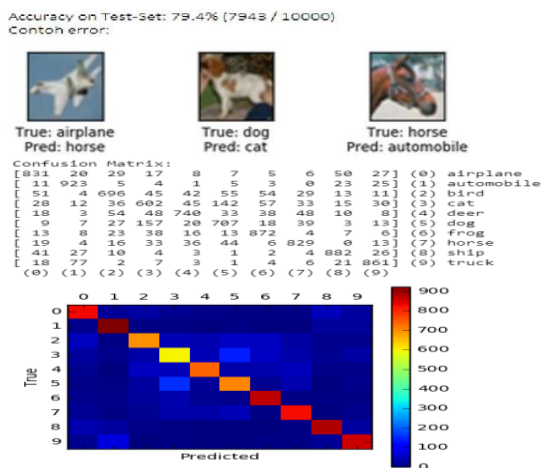
$$Optimasi = \frac{NA_1 - NA_0}{100} \times 100\% \quad (3)$$

Dengan NA_1 =Nilai Akurasi metode akhir dan NA_0 =Nilai Akurasi metode awal

3. Hasil dan Pembahasan

3.1. Hasil dari metode CNN

Optimasi dilakukan pada 10.000 iterasi. Contoh kesalahan yang terjadi pada klasifikasi terlihat pada gambar 3.



Gambar 3. Kesalahan Klasifikasi dan Hasil Akurasi Confusion Matrix

Gambar 3 memperlihatkan hasil perhitungan confusion matrix dengan akurasi klasifikasi sebesar 79.4% yang dipresentasikan dalam matrix angka dan diagram confusion matrix dan telah diterapkan pada data testing. Pada gambar 3 juga terlihat citra dengan hasil prediksi yang salah.

3.2 Hasil dari Klasifikasi Inception v3



- 89.23% : giant panda
- 0.86% : indri
- 0.26% : lesser panda
- 0.14% : custard apple
- 0.11% : earthstar
- 0.08% : sea urchin
- 0.05% : forklift
- 0.05% : soccer ball
- 0.05% : go-kart
- 0.05% : digital watch

Gambar 4a. Hasil Output Lapisan Softmax

Pada gambar 4a terlihat bahwa akurasi klasifikasi citra tersebut sebesar 89,23%. Klasifikasi ini dihasilkan dari lapisan softmax sebelum proses perhitungan transfer-value.




- 46.54% : golden retriever
- 16.03% : sunglasses
- 12.33% : sunglasses
- 4.01% : Pembroke
- 1.04% : cocker spaniel
- 0.92% : Cardigan
- 0.78% : collie
- 0.66% : Irish setter
- 0.64% : Norfolk terrier
- 0.41% : Pekinese

Gambar 4b. Hasil Output Lapisan Softmax dari image_path

Gambar 4b memperlihatkan hasil lain dari klasifikasi yang dilakukan oleh Model Inception v3 pada lapisan softmax. Hasil ini memiliki akurasi kumulatif sebesar 28% yang dapat juga memprediksi jenis anjing dari citra yang diinput.


3.4 Hasil Transfer-Value Model TL-Inception



Gambar 5. Hasil Plot Transfer-Value Pada Model TL-Inception

Gambar 5 merupakan contoh plotting hasil perhitungan citra input menjadi nilai transfer (transfer-value) pada model TL-Inception. Nilai transfer citra tersebut memiliki nilai pixel antara 0 sampai 255.

3.5 Hasil dari Optimasi PCA dan t-SNE




Gambar 6. Hasil Ploting Algoritma PCA dan t-SNE

Pada gambar 6 terlihat bahwa transfer-value terbagi menjadi beberapa kelompok yang berbeda setelah dioptimasi dengan algoritma PCA dan t-SNE. Tingkat optimasi pada reduksi citra dengan PCA tersebut mencapai angka 97,56%.

3.6 Hasil dari Akurasi Klasifikasi

Accuracy on Test-Set: 7.0% (700 / 10000)
 Confusion Matrix:
 [45 4 0 58 145 244 0 472 27 5] (0) airplane
 [124 1 0 121 157 77 0 499 21 0] (1) automobile
 [60 16 3 352 90 137 0 265 76 1] (2) bird
 [58 3 9 196 255 65 0 361 39 14] (3) cat
 [36 9 20 343 180 33 0 151 218 10] (4) deer
 [55 9 7 225 227 54 0 355 55 13] (5) dog
 [60 8 13 194 76 68 0 542 36 3] (6) frog
 [16 1 37 304 192 35 0 205 195 15] (7) horse
 [12 1 6 59 169 228 0 483 14 28] (8) ship
 [38 0 1 80 204 27 0 642 6 2] (9) truck
 (0) (1) (2) (3) (4) (5) (6) (7) (8) (9)



Gambar 7. Hasil Confusion Matrix Sebelum Dioptimasi

Pada gambar 7 terlihat hasil akurasi confusion matrix sebelum dioptimasi. Hasilnya 7% dari 10.000 data testing, terlihat dalam matrix angka dan diagram confusion matrix. Sedangkan tabel 1 memperlihatkan hasil akurasi pada 10.000 iterasi yang diproses hanya pada satu lapisan terhubung penuh (fully connected

layer). Seperti yang terlihat pada gambar 2. Tidak seperti pada metode CNN sebelumnya yang menggunakan dua lapisan konvolusi dan dua lapisan terhubung penuh yang terlihat pada gambar 1.

Tabel 1. Hasil Optimasi Akurasi Klasifikasi

Jumlah Iterasi	Akurasi
100	85.9%
200	84.4%
300	81.2%
400	87.5%
500	85.9%
...	...
1000	96%
...	...
2000	85.9%
...	...
9000	96.9%
9100	100%
...	...
9900	98.4%
10000	95.3%

Waktu
 Komputasi : 0:06:58

Accuracy on Test-Set: 90.5% (9045 / 10000)

Contoh error:



True: ship
 Pred: frog

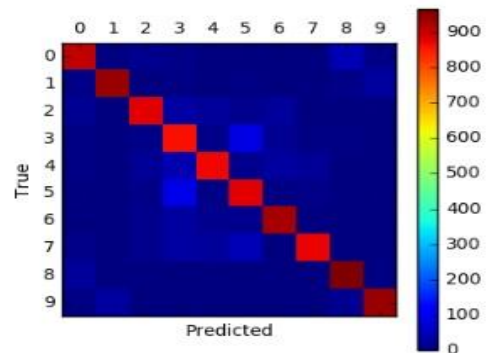


True: deer
 Pred: cat



True: automobile
 Pred: truck

Confusion Matrix:
 [907 7 13 9 1 3 1 1 47 11] (0) airplane
 [8 941 1 5 0 4 0 1 11 29] (1) automobile
 [18 0 882 33 24 12 24 3 1] (2) bird
 [4 1 11 862 10 84 17 5 4 2] (3) cat
 [4 0 20 42 867 15 28 20 3 1] (4) deer
 [3 0 8 87 9 879 4 8 2 0] (5) dog
 [3 0 12 30 12 12 928 1 2 0] (6) frog
 [8 0 12 28 25 46 2 873 3 3] (7) horse
 [24 2 0 3 0 1 1 0 965 4] (8) ship
 [6 29 3 3 0 0 1 1 16 941] (9) truck
 (0) (1) (2) (3) (4) (5) (6) (7) (8) (9)



Gambar 8. Hasil Confusion Matrix Setelah Dioptimasi

Hasil akurasi setiap iterasi yang terlihat pada tabel 1 juga menunjukkan nilai yang maksimal dengan waktu komputasi yang lebih singkat yaitu 6 menit 58 detik.

Setelah dioptimasi maka akurasi dari confusion matrix meningkat menjadi 90.5%. Sedangkan tingkat optimasi dari akurasi kedua metode tersebut sebesar 11%. Pada gambar 8 terlihat pada matrix angka, bagian diagonal memiliki nilai yang tinggi dan pada diagram confusion matrix pola diagram yang tersusun diagonal memiliki tingkat warna prediksi benar antara 800-900. Meskipun masih ada beberapa kesalahan prediksi pada citra tetapi persentasenya kecil.

4. Kesimpulan

Dari penelitian ini maka telah dibuktikan bahwa metode CNN yang dikombinasi dengan proses transfer learning inception dan dioptimasi menggunakan algoritma PCA dan t-SNE memiliki akurasi lebih tinggi sebesar 90.5% dari metode CNN sebelumnya yang memiliki akurasi 79.4%. Dengan tingkat optimasi sebesar 11%. Waktu komputasi yang dihasilkan pada proses iterasi data testing dari metode TL-Inception CNN adalah 6 menit 58 detik. Waktu yang dihasilkan lebih efisien yaitu 3 jam untuk proses transfer nilai (transfer-value) fitur citra dibandingkan dengan waktu training metode CNN yaitu 12 jam pada mesin virtual Linux 2 core pada CPU 3.5 GHz dan SSD drive.

Daftar Rujukan

- [1] Zhong, Z., Li, J., Ma, L., Jiang, H. and Zhao, H. 2017, July. Deep residual networks for hyperspectral image classification. In *2017 IEEE international geoscience and remote sensing symposium (IGARSS)* (pp. 1824-1827). IEEE.
- [2] Ma, J. and Yuan, Y. 2019. Dimension reduction of image deep feature using PCA. *Journal of Visual Communication and Image Representation*, 63, p.102578.
- [3] Gao, L., Gu, D., Zhuang, L., Ren, J., Yang, D. and Zhang, B. 2019. Combining t-Distributed Stochastic Neighbor Embedding With Convolutional Neural Networks for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters*.
- [4] Kobak, D. and Berens, P. 2019. The art of using t-SNE for single-cell transcriptomics. *Nature communications*, 10(1), pp.1-14.
- [5] Husnain, M., Missen, M.M.S., Mumtaz, S., Luqman, M.M., Coustaty, M. and Ogier, J.M., 2019. Visualization of High-Dimensional data by pairwise fusion matrices using t-SNE. *Symmetry*, 11(1), p.107.
- [7] Giuste, F.O. and Vizcarra, J.C. 2020. CIFAR-10 Image Classification Using Feature Ensembles. *arXiv preprint arXiv:2002.03846*.
- [8] Basha, S.S., Dubey, S.R., Pulabaigari, V. and Mukherjee, S. 2020. Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, pp.112-119.
- [9] Krizhevsky, A., Sutskever, I. and Hinton, G.E. 2012. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105)
- [10] Hussain, M., Bird, J.J. and Faria, D.R. 2018, September. A study on cnn transfer learning for image classification. In *UK Workshop on Computational Intelligence* (pp. 191-202). Springer, Cham.
- [11] Mohamed, S.S.N. and Srinivasan, K., 2019, September. Comparative Analysis of Deep Neural Networks for Crack Image Classification. In *International Conference on Intelligent Data Communication Technologies and Internet of Things* (pp. 434-443). Springer, Cham.