

DAFTAR PUSTAKA

- [1] W. Astika and D. Muchtar, "Sutrisno. 1990. pelepasan klon unggul teh," *Warta Teh dan Kina*, vol. 1, no. 1, pp. 20–22.
- [2] W. Astika, D. Muchtar, S. Danimihardja, B. Sriyadi *et al.*, "Tea clone release series pps 1, pps 2, mps 5, mps 6, mps 7, dan gpps 1," in *Pertemuan Teknis Teh Nasional, Bandung (Indonesia), 8-9 Nop 1999*. Puslit Teh dan Kina, 2000.
- [3] V. P. Rahadi, H. S. Khomaeni, L. Chaidir, B. Martono *et al.*, "Keragaman dan kekerabatan genetik koleksi plasma nutfah teh berdasarkan karakter morfologi daun dan komponen hasil," *Jurnal Tanaman Industri Dan Penyegar*, vol. 3, no. 2, pp. 103–108, 2016.
- [4] I. D. S. Effendi, M. Syakir, M. Yusron, R. Pelaksana, I. Jusniarti, A. Budiharto, T. Letak, H. T. Luntungan, and H. C. D. Undang-undang, "Budidaya dan pasca panen teh," *Bogor: Pusat Penelitian dan Pengembangan Perkebunan*, 2010.
- [5] N. Kumar, P. N. Belhumeur, A. Biswas, D. W. Jacobs, W. J. Kress, I. C. Lopez, and J. V. Soares, "Leafsnap: A computer vision system for automatic plant species identification," in *European Conference on Computer Vision*. Springer, 2012, pp. 502–516.
- [6] D. Hall, C. McCool, F. Dayoub, N. Sunderhauf, and B. Upcroft, "Evaluation of features for leaf classification in challenging conditions," in *2015 IEEE Winter Conference on Applications of Computer Vision*. IEEE, 2015, pp. 797–804.
- [7] C. Kalyoncu and Ö. Toygar, "Geometric leaf classification," *Computer Vision and Image Understanding*, vol. 133, pp. 102–109, 2015.

5.2 Saran

Pengujian yang telah dilakukan dengan menggunakan arsitektur LeNet-5 dapat dijadikan acuan dasar dan bisa dikembangkan lagi dengan menggunakan arsitektur yang terbaru terhadap pengaruh *data* citra daun GMB (1-11). Berikut saran terhadap proses pengujian yang telah dilakukan.

1. Perlu adanya penambahan jumlah *dataset* citra daun asli agar sistem klasifikasi yang diperoleh lebih signifikan dan memperoleh nilai akurasi yang lebih baik.
2. Penambahan parameter pada pengujian *dataset* citra untuk memperoleh hasil perbandingan yang lebih kompleks.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Tugas Akhir ini telah mengusulkan metode klasifikasi daun teh GMB (1-11) menggunakan algoritma CNN dengan arsitektur dasar LeNet-5 dan memperoleh hasil akurasi di atas 90%. Data citra dengan *size* 64×64 mempengaruhi hasil klasifikasi yang sangat baik dengan mengikuti rancangan pengujian data yang terdiri dari 2 skenario pada subbab 4.2. Pada model pertama, yaitu dengan menggunakan data citra asli diperoleh nilai akurasi terbaik sebesar 39.55% serta nilai *F1-score* (gabungan rata-rata nilai antara presisi dan *recall*) sebesar 39%. Parameter terbaik yang didapat pada pengujian skenario pertama adalah *optimizer* Adagrad dengan *learning rate* 0.01. Hasil dari model ini tidak bisa dijadikan sebagai acuan parameter dikarenakan adanya pengaruh *overfitting* pada nilai *loss function* dari proses validasi data. Pada model kedua menggunakan *dataset* citra dengan penambahan proses data augmentasi diperoleh hasil akurasi yang sangat baik, yaitu dengan nilai akurasi sebesar 100% untuk *epoch* 80 sebagai ketetapan parameter acuan.

Hasil skenario kedua pada pengujian model kedua memberikan urutan *optimizer* terbaik dengan nilai *loss function* sebagai nilai pembanding. Posisi pertama *optimizer* terbaik yaitu *optimizer* Adam, kedua RMSprop, ketiga SGD, dan yang terakhir Adagrad. *optimizer* Adam dengan *learning rate* 0.001 telah diuji pada hasil pengujian akhir dengan memperoleh hasil akurasi sebesar 94.55% dengan *epoch* 13, dan *F1-score* sebesar 94%.

Tabel 4.12. Nilai Akurasi validasi dengan menggunakan augmentasi data.

Model + Augmentasi Data + <i>Optimizer Adam</i>(lr=0.001)					
Epoch	<i>Validation Accuracy</i>	<i>Validation Loss</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
7	70.45%	29,55%	73%	71%	70%
10	85.90%	14.1%	87%	87%	86%
13	94.55%	5.45%	96%	94%	94%

Pada tabel 4.12 memperlihatkan hasil performansi yang sangat baik. Pada *epoch* 13 memperoleh nilai akurasi validasi sebesar 94.55%. Dalam jangka waktu proses klasifikasi selama 39 detik mampu memperoleh nilai akurasi di atas 90%. Dengan kata lain, proses klasifikasi model tersebut terbilang sangat optimal.

4.5.2 Hasil Pengujian Skenario Kedua

Skenario kedua pada data augmentasi merupakan hasil pemilihan *optimizer* terbaik dengan membandingkan nilai evaluasi dari pengujian skenario pertama.

Tabel 4.11. Nilai *loss function* validasi dan *training* pada *optimizer* dengan *learning rate* terbaik.


Epoch = 80	SGD (lr=0.1)	Adam (lr=0.001)	RMSprop (lr=0.001)	Adagrad (lr=0.01)
<i>Loss Function Val_Loss</i>	0.0001	0	0.00002	0.04
<i>Loss Function Training_Loss</i>	0.0001	0	0.003	0.03

Pada Tabel 4.11 menampilkan nilai *loss function* yang berbeda pada setiap *optimizer*. Hal ini membuktikan bahwa *optimizer* Adam memiliki keunggulan dengan yang lain, yaitu memperoleh nilai 0 atau tidak mengalami kerugian data pada saat proses validasi. *Optimizer* RMSprop dengan *learning rate* 0.001 hampir mendekati 0 atau dengan nilai 0.00002. Jika dilihat dari nilai *loss function*, parameter *optimizer* terbaik dengan *epoch* 80 secara berurutan yaitu *optimizer* Adam, RMSprop, SGD, dan Adagrad.

4.6 Hasil Pengujian Akhir


Batas tingkat akurasi yang diharapkan adalah sebesar 90%. Maka, proses klasifikasi model bisa dilakukan dengan menggunakan *pre-processing* data augmentasi sebagai *dataset* citra, parameter yang digunakan adalah *optimizer* Adam dengan *learning rate* sebesar 0.001, *size* 64×64 , serta menggunakan *Categorical Cross Entropy* (CCE) sebagai *loss function*.

nakan *learning rate* 0.001.



Gambar 4.12. Grafik data augmentasi validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0.001.

Pada Gambar 4.12, nilai akurasi tertinggi jatuh kepada *optimizer* SGD dan Adagrad. Hal ini dapat dilihat perolehan hasil akurasi *optimizer* pada *learning rate* 0.01 berkebalikan hasilnya dengan *learning rate* 0.001. Klasifikasi dengan *optimizer* Adam memperoleh nilai yang tetap, dan *optimizer* RMSprop nilai akurasi meningkat pada saat rentang *epoch* 1-49, namun menurun drastis pada *epoch* 50.




Gambar 4.13. Grafik data augmentasi validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0.0001.

Grafik validasi akurasi dengan *learning rate* 0.0001 pada Gambar 4.13 yang paling terbaik adalah *optimizer* Adam, sedangkan yang kedua adalah *optimizer* RMSprop. Grafik *loss* pada kedua *optimizer* tersebut menurun tanpa adanya pengaruh *overfitting*. Sedangkan *optimizer* SGD dan Adagrad memperoleh hasil akurasi yang buruk jika dilihat kurva akurasi dan *loss* validasi.


4.5.1.5 Perbandingan Performansi Optimizer

Berikut hasil performansi klasifikasi dengan parameter *optimizer* yang diuji dengan *learning rate* 0.1 pada Gambar 4.10.



Gambar 4.10. Grafik data augmentasi validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0,1.

Pada Gambar 4.10, perolehan tingkat akurasi terbaik dengan *learning rate* 0.1 adalah dengan menggunakan parameter *optimizer* SGD, lalu dilanjutkan dengan parameter *optimizer* Adagrad. Hasil akurasi pada *optimizer* Adam serta RMSprop sangat tidak baik jika menggunakan *learning rate* 0.1 dan nilai akurasi tetap sama tiap *epoch*.




Gambar 4.11. Grafik data augmentasi validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0,01.

Akurasi dengan *Optimizer* Adam pada *learning rate* 0.001 meningkat sangat baik, dilanjutkan dengan *optimizer* RMSprop namun tingkat representasi akurasi masih kurang tapi masih bisa mempertahankan kualitas akurasi serta *loss* validasi. Perolehan *optimizer* SGD serta Adagrad terlihat cukup baik jika dengan menggu-


Tabel 4.10. Perbandingan nilai akurasi terhadap parameter *learning rate optimizer* Adagrad.

Opt. Adagrad				
Epoch 80	lr = 0.1	lr = 0.01	lr = 0.001	lr = 0.0001
Validation Accuracy	75%	100%	37.73%	16.82%
Validation Loss	25%	0%	62.27%	83.18%
Loss Function Val loss	0.71	0.04	1.78	2.33
Loss Function Training Loss	0.72	0.03	1.69	0.98
Precision	78%	100%	36%	12%
Recall	76%	100%	36%	17%
F1-score	75%	100%	36%	12%



Gambar 4.9. Grafik akurasi *optimizer* Adagrad lr=0,01.

Nilai akurasi tertinggi dari keempat *learning rate* yang diuji pada *epoch 80* sebesar 100%. Dengan menggunakan parameter *learning rate* 0.01 data validasi mampu mengklasifikasi model data augmentasi dengan baik, dapat dilihat dari Gambar 4.9.



Gambar 4.8. Grafik akurasi *optimizer* RMSprop lr=0.001.

Pada Tabel 4.8 hasil performansi terbaik yang dideperoleh dengan *learning rate* 0.001. Grafik pada Gambar 4.5 memperlihatkan proses yang cukup baik walaupun terjadi kenaikan *loss* validasi di titik *epoch* 20-30 dan *epoch* 43.

4.5.1.4 Hasil Performansi Optimizer Adagrad

Berikut hasil peroformansi model data augmentasi dengan menggunakan *optimizer* Adagrad.

Pada Tabel 4.8 *learning rate* 0.1 dan 0.01 memperoleh nilai akurasi tertinggi. Perbedaan dari kedua hasil tersebut dapat dilihat dari proses waktu klasifikasi model serta jumlah *epoch* mendekati nilai 90%. Pada Gambar 4.7(b) dengan *epoch* 10 sampai 20 memperoleh nilai akurasi terbaik, sedangkan pada Gambar 4.7(a) memperoleh nilai akurasi tertinggi dengan *epoch* 70 dan mengalami representasi yang kurang baik pada proses *cross validasi* jika dilihat dari kurva *loss validasi*.

4.5.1.3 Hasil Performansi Optimizer RMSprop

Berikut hasil performansi model data augmentasi dengan menggunakan *optimizer* RMSprop.

Tabel 4.9. Perbandingan nilai akurasi terhadap parameter *learning rate optimizer* RMSprop.

Opt. RMSprop				
<i>Epoch 80</i>	<i>lr = 0.1</i>	<i>lr = 0.01</i>	<i>lr = 0.001</i>	<i>lr = 0.0001</i>
<i>Validation Accuracy</i>	8.18%	9.09%	100%	61.36%
<i>Validation Loss</i>	91.82%	90.91%	0%	38.64%
<i>Loss Function Val_Loss</i>	2.412	2.4	0.00002	1.07
<i>Loss Function Training_Loss</i>	2.412	2.4	0.003	0.98
<i>Precision</i>	1%	1%	100%	67%
<i>Recall</i>	9%	9%	100%	62%
<i>F1-score</i>	1%	2%	100%	61%

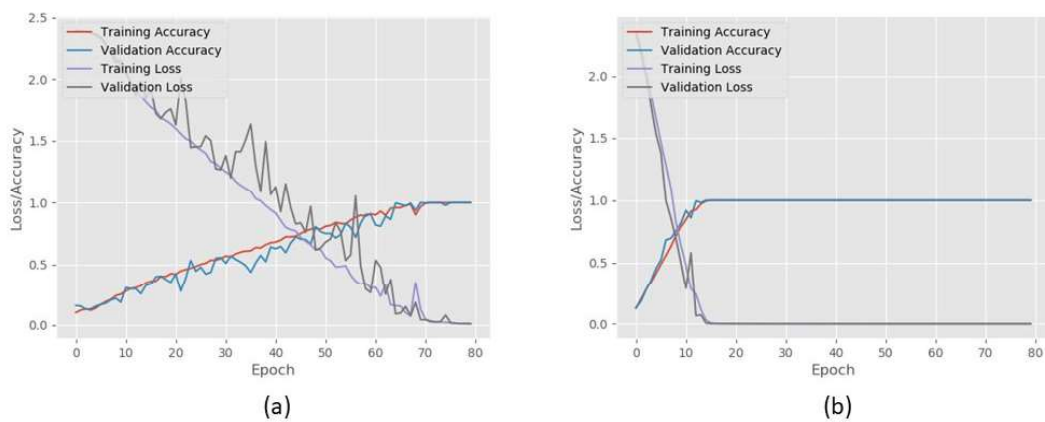
learning rate 0.001. Grafik dengan *learning rate* 0.001 pada Gambar 4.6 diketahui perolehan akurasi mendekati nilai 90% berada di antara *epoch* 10 sampai *epoch* 15.

4.5.1.2 Hasil Performansi Optimizer SGD

Berikut hasil performansi model parameter *optimizer SGD* terhadap pengaruh *learning rate* yang telah ditentukan.

Tabel 4.8. Perbandingan nilai akurasi terhadap parameter *learning rate optimizer SGD*.

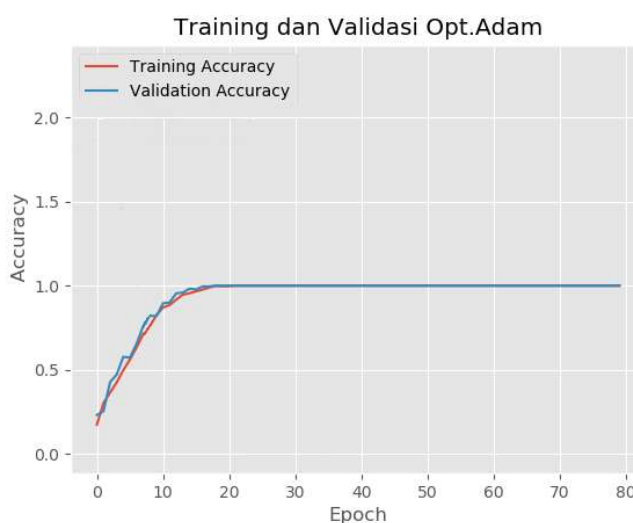
<i>Opt. SGD</i>				
<i>Epoch 80</i>	lr = 0.1	lr = 0.01	lr = 0.001	lr = 0.0001
<i>Validation Accuracy</i>	100%	100%	30%	10.45%
<i>Validation Loss</i>	0%	0%	70%	89.55%
<i>Loss Function</i> <i>Val_loss</i>	0.0001	0.01	1.98	2.39
<i>Loss Function</i> <i>Training loss</i>	0.0001	0.01	1.91	2.39
<i>Precision</i>	100%	100%	33%	15%
<i>Recall</i>	100%	100%	29%	10%
<i>F1-score</i>	100%	100%	28%	8%



Gambar 4.7. (a) Grafik Opt. SGD lr=0,01. (b) Grafik Opt.SGD lr=0,1.

Tabel 4.7. Perbandingan nilai akurasi terhadap parameter *learning rate optimizer Adam*.

Opt. Adam				
<i>Epoch 80</i>	lr = 0.1	lr = 0.01	lr = 0.001	lr = 0.0001
<i>Validation Accuracy</i>	100%	100%	100%	80.91%
<i>Validation Loss</i>	0%	0%	0%	19.09%
<i>Loss Function Val_loss</i>	0.0001	0.01	0.00	0.66
<i>Loss Function Training_loss</i>	0.0001	0.01	0.00	0.75
<i>Precision</i>	100%	100%	100%	83%
<i>Recall</i>	100%	100%	100%	81%
<i>F1-score</i>	100%	100%	100%	81%



Gambar 4.6. Grafik hasil data latihan dan validasi data augmentasi *optimizer Adam*.

Pada Tabel 4.7 menampilkan nilai akurasi *optimizer Adam* terhadap pengaruh parameter *learning rate*. Diketahui dengan *epoch 80* pada *learning rate 0.001* memperoleh nilai akurasi yang sangat baik. Dapat disimpulkan bahwa perolehan nilai akurasi di atas 90% berada di bawah epoch 80. *Learning rate* yang lain juga menampilkan hasil yang baik, namun kualitas kecepatan proses tertinggi berada di

dari setiap *optimizer* mengalami *overfitting*. Pada Gambar 4.5 diketahui kurva validasi *loss* naik hingga proses selesai pada *epoch* 80. Hal itu dapat terjadi karena nilai *loss function* dari validasi *cross* sangat tinggi/besar dibandingkan dengan nilai *training-loss*.

4.5 Pengujian dengan Data Augmentasi

Model kedua merupakan proses klasifikasi dengan menggunakan *dataset* yang telah diaugmentasi. Data citra bertambah dengan jumlah data latih sebesar 4400 data sampel dan data uji(*validation set*) sebesar 220 data sampel. Pengujian data augmentasi akan diambil 3 proses *epoch* dengan tingkat akurasi mendekati nilai 90%.

4.5.1 Hasil Pengujian Skenario Pertama

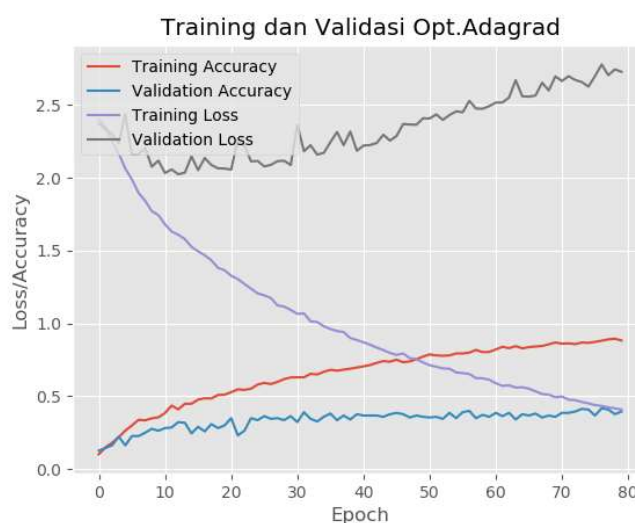
Pada pengujian klasifikasi data augmentasi akan dilakukan proses pencarian nilai akurasi terbaik dari pengaruh parameter *optimizer* Adam, SGD, RMSprop, dan Adagrad. Parameter yang akan diuji adalah dengan *learning rate* sebesar 0.1, 0.01, 0.001, dan 0.0001, *batch size* 32, dan *epoch* 80.

4.5.1.1 Hasil Performansi Optimizer Adam

Berikut hasil performansi *optimizer* Adam dengan parameter *learning rate* yang telah ditentukan.


Tabel 4.6. Hasil performansi parameter *optimizer* dengan *learning rate* terbaik.

Epoch = 80	SGD (lr=0.1)	Adam (lr=0.001)	RMSprop (lr=0.001)	Adagrad (lr=0.01)
<i>Validation Accuracy</i>	26.82%	38.18%	38.18%	39.55%
<i>Validation Loss</i>	73.18%	61.82%	61.82%	60.45%
<i>Loss Function Val_loss</i>	4.69	3.36	3.95	2.73
<i>Loss Function Training_loss</i>	0.24	0.22	0.13	0.41
<i>Precision</i>	26%	40%	42%	41%
<i>Recall</i>	26%	39%	39%	39%
<i>F1-score</i>	26%	38%	38%	39%



Gambar 4.5. Hasil proses klasifikasi model *optimizer* Adagrad.

Pada Tabel 4.6 menampilkan kembali nilai performansi terbaik *optimizer* sesuai dari parameter *learning rate* yang diuji. Dapat dilihat bahwa nilai terbaik dari keempat *optimizer* yang diuji adalah *optimizer* Adagrad. Validasi akurasi *optimizer* Adagrad diperoleh sebesar 39.55% dan F1-score sebesar 39% jauh lebih baik dibandingkan dengan *optimizer* yang lain. Namun, apabila dilihat dari nilai *loss function*




Gambar 4.4. Grafik validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0.0001

Pada Gambar 4.4 *learning rate* 0.0001 *optimizer* Adam dan RMSprop mengalami peningkatan akurasi validasi tiap *epoch* serta validasi *loss* tidak mengalami *overfitting*. Sedangkan dengan *optimizer* SGD dan Adagrad memperoleh *loss* tetap senilai 2.4 tiap *epoch*.


4.4.2 Hasil Pengujian Skenario Kedua

Skenario kedua merupakan proses hasil pemilihan *optimizer* terbaik terhadap sistem klasifikasi model data citra asli. Pada subbab ini akan menampilkan evaluasi perbandingan nilai performansi dari hasil pengujian skenario pertama.



Gambar 4.2. Grafik validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0.01.

Pada Gambar 4.2 *learning rate* 0.01, sistem klasifikasi dengan *optimizer* SGD dan Adagrad mengalami peningkatan akurasi validasi tiap *epoch*, namun memperoleh nilai tetap pada *optimizer* Adam dan RMSprop. Jika dilihat dari *loss* validasi, *optimizer* SGD mengalami *overfitting* dimulai dari epoch 70, sedangkan *optimizer* Adagrad mengalami *overfitting* dimulai dari epoch 10.



Gambar 4.3. Grafik validasi akurasi dan validasi *loss optimizer* dengan *learning rate* 0.001.

Pada Gambar 4.3 *learning rate* 0.001, *optimizer* Adam dan RMSprop mengalami perubahan tingkat akurasi dan memperoleh hasil tertinggi daripada *optimizer* SGD dan Adagrad. Namun, tetap mengalami *overfitting* pada *optimizer* Adam dan RMSprop sehingga belum bisa dijadikan parameter tetap dari nilai perolehan klasifikasi. Jika dilihat dari *optimizer* Adagrad, *loss* validasi yang didapat mengalami penurunan secara perlahan. bisa disimpulkan bahwa klasifikasi sistem dengan menggunakan parameter *optimizer* Adagrad memperoleh performa terbaik jika *epoch* lebih dari 80 dan proses klasifikasi yang cukup lama.