

Terbit online pada laman web jurnal: <http://jurnal.iaii.or.id>



JURNAL RESTI

(**Rekayasa Sistem dan Teknologi Informasi**)

Vol. 5 No. 4 (2021) 656 - 662

ISSN Media Elektronik: 2580-0760

Klasifikasi Citra Daging Menggunakan Deep Learning dengan Optimisasi *Hard Voting*

Made Bramasta Vikana Putra¹, I Putu Agung Bayupati², Dewa Made Sri Arsa³

^{1,2,3}Teknologi Infromasi, Fakultas Teknik, Universitas Udayana

¹bramastavikanaputra@gmail.com, ²bayupati@unud.ac.id, ³dewamsa@unud.ac.id

Abstract

Meat is a staple food for some Indonesian people, apart from the taste, meat also contains vitamins and minerals that are good for the human body, however, not all meat can be consumed by the Indonesian people. the texture and color of beef, pork and mutton have similarities and tend to be similar, therefore a system is needed to recognize the three types of meat. In this study, the authors use various types of Deep Learning architecture such as Resnet-50, VGG-16, VGG-19 and Densenet-121 with Hard Voting to improve the performance of Deep Learning in recognizing the three types of meat. The results show that Resnet-50 with Hard Voting can outperform Deep Learning Resnet-50, VGG-16, VGG-19 and Densenet-121- with f1 score 98.88%, precision 98.89% and recall 98.88%. in image classification of pork, beef and mutton.

Keywords: Deep Leaning, Ensemble Learning, Image Recognition, Transfer Learning

Abstrak

Daging merupakan makanan pokok bagi sebagian masyarakat Indonesia, selain karena cita rasa, daging juga mengandung vitamin dan mineral yang baik untuk tubuh manusia, namun dengan demikian tidak semua daging dapat dikonsumsi oleh masyarakat Indonesia, secara tekstur dan warna daging sapi,daging babi dan daging kambing memiliki kemiripan dan cenderung serupa maka dari itu dibutuhkan sebuah sistem mengenali ketiga jenis daging tersebut. Penelitian ini penulis menggunakan berbagai jenis arsitektur Deep Learning seperti Resnet-50, VGG-16, VGG-19 dan Densenet-121 dengan Hard Voting untuk meningkatkan performance dari Deep Learning dalam mengenali ketiga jenis daging tersebut. Hasil penelitian menunjukkan bahwa Resnet-50 dengan Hard Voting dapat mengungguli kemampuan Deep Learning Resnet-50, VGG-16, VGG-19 dan Densenet-121- dengan f1 score 98,88%, precision 98,89% dan recall 98,88% dalam klasifikasi citra daging babi, daging sapi dan daging kambing.

Kata kunci: Deep Leaning, Ensemble Learning, Image Recognition, Transfer Learning

1. Pendahuluan

Daging merupakan makanan pokok bagi sebagian masyarakat indonesia selain dari aspek rasa, daging juga memiliki banyak kandungan vitamin dan sehingga tidak heran jika daging dapat ditemukan di banyak pasar di Indonesia namun, tidak semua jenis daging dapat dikonsumsi oleh masyarakat Indonesia seperti daging babi, hal tersebut mengakibatkan harga daging babi di Indonesia cenderung lebih murah dibandingkan dengan harga daging sapi dan kambing hal ini yang dapat membuat pedagang mencampuri daging babi dengan daging lainnya demi meningkatkan keuntungan. Secara umum tekstur dan warna daging babi, sapi dan kambing cenderung serupa.

Karakteristik yang serupa dari ketiga jenis daging ini menyebabkan orang tidak menyadari perbedaan dari ketiga jenis daging tersebut. Kemajuan teknologi dibidang pengolahan citra digital semakin berkembang, oleh karena itu pengolahan citra digital dapat digunakan untuk mengenali dan membedakan ketiga jenis daging tersebut.

Deep Learning merupakan pembelajaran representasi multilayer dalam jaringan syaraf tiruan [1]. Sementara pembelajaran representasi itu sendiri adalah metode dalam pembelajaran mesin untuk secara otomatis dalam mengekstrak mempelajari representasi (fitur) dari data yang ada, Deep Learning telah memecahkan banyak masalah seperti klasifikasi gambar [2–4], deteksi objek [5–7], pengenalan suara [8]. Penelitian tentang

klasifikasi citra babi, kambing dan sapi telah banyak dilakukan oleh beberapa peneliti diantaranya [9] melakukan penelitian untuk membuat model klasifikasi citra sapi dan babi dengan *Grey Level Co-occurrence matrix* (GLCM) dan *Backpropagation* dengan tingkat akurasi 89% sedangkan penelitian lainnya mengenai klasifikasi jenis daging menggunakan SVM dan GLCM dengan nilai rekognisi terbesar sebesar 87,5%[10]. Selanjutnya penelitian yang berhubungan dengan *Deep Learning* yaitu *Fish Recognition* menggunakan VGG-16 oleh Handayani dkk [11] menggunakan arsitektur VGG-16 untuk mengenali 50 jenis spesies ikan. Hasil penelitian diperoleh nilai *Genuine Acceptance Rate* (GAR) sebesar 96,4%. Selain itu, Agastya et al. [12] menggunakan VGG-16 dan VGG-19 untuk mengklasifikasikan pola batik dan menemukan bahwa kinerja pengenalan meningkat 10% dengan memasukkan proses augmentasi. Penelitian tentang *Deep Learning* lainnya adalah, penelitian yang dilakukan oleh Rokhana et al. [13] untuk membandingkan kinerja *Convolutional Neural Network* (CNN) dan metode klasifikasi klasik seperti K-NN dan *Support Vector Machine* (SVM) untuk mendeteksi fraktur tulang paha secara otomatis dari gambar *ultrasound*. Hasilnya, mendapatkan hasil bahwa jaringan saraf konvolusional mengungguli metode tradisional tersebut.

Kemampuan meningkatkan kinerja suatu model melalui metode *Voting* menjadi menarik untuk saat ini, seperti yang ditunjukkan oleh penelitian oleh Kaur et al. [14] hasil dari penelitian menunjukkan bahwa metode berbasis *Voting* secara signifikan melampaui kemampuan model tunggal seperti *Support Vector Machine*, *naïve bayes* dan *decision tree*, selanjutnya penelitian yang berhubungan dengan *voting based* adalah klasifikasi tumor payudara dimana metode *voting based* melewati akurasi [15] dari metode lain seperti algoritma, *K-Nearest neighbour* dan algoritma klasifikasi lainnya.

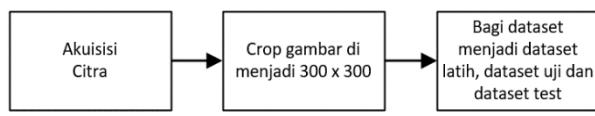
Dalam studi ini, kami mengusulkan metode *Deep Learning* berbasis *voting* untuk mengenali jenis daging babi, daging kambing dan daging sapi berbasis citra, metode *voting* yang kami gunakan adalah *Hard Voting* yang merupakan keluarga *Ensemble Learning*. *Ensemble learning* adalah bidang baru dalam *machine learning* [16] dan *Deep Learning* [17-18] yang merupakan penggabungan algoritma yang berbeda untuk melatih kumpulan data dan memilih prediksi akhir berdasarkan suara terbanyak [19].

2. Metode Penelitian

2.1. Pengumpulan Dataset dan *Preprocessing Data*

Pengumpulan data pada penelitian ini bersumber dari 2 sumber yang berbeda yang pertama dengan akuisisi citra langsung ke pasar traditional menggunakan 2 buah alat yaitu Nikon D3200 dengan resolusi kamera 24 *Mega*

Pixels dan *Handphone* Xiaomi Redmi Note Pro 8 dengan resolusi kamera 64 *Mega Pixels* pada kondisi cahaya lingkungan pasar tradisional yang kedua dengan mengunduh citra melalui Internet dari *Google Images*. *Preprocessing data* pada penelitian seperti pada alur Gambar 1.



Gambar 1 Alur preprosesing data

Setelah proses akuisisi citra dilakukan, proses selanjutnya adalah melakukan *cropping* citra menjadi ukuran 300 x 300 *pixels*, hal ini dilakukan untuk mendapatkan bagian citra dan menghilangkan *noise* yang terdapat pada gambar seperti *background* yang tidak di perlukan, illustrasi proses *cropping image* seperti pada gambar 2.



Gambar 2 illustrasi hasil cropping dataset

hasil dari *cropping* menghasilkan jumlah dataset sebanyak 456 buah dataset dengan rincian dataset kambing berjumlah 143 buah citra, dataset sapi berjumlah 164 buah citra dan dataset babi berjumlah 150 buah citra contoh hasil dataset yang telah di *cropping* dapat dilihat pada Gambar 3.

Gambar 3 adalah contoh beberapa dari citra daging yang telah melalui proses *cropping*, A) merupakan dataset citra daging babi, B) merupakan dataset citra daging sapi dan C) pada merupakan citra dataset daging kambing. Selanjutnya dataset yang akan di bagi menjadi 3 bagian yaitu dataset latih, dataset validasi dan dataset test hal ini dilakukan untuk malakukan evaluasi terhadap model, rincian pembagian dataset dapat dilihat pada Tabel 1.

Tabel 1 jumlah dataset

jenis	sapi	babi	kambing
Dataset latih	104	92	82
Dataset validasi	31	31	31
Dataset test	29	27	30





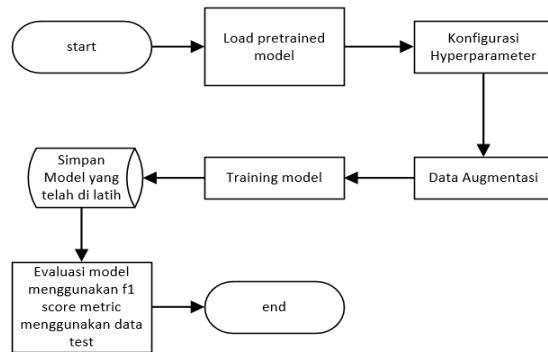
Gambar 3 contoh dataset

2.2. Transfer Learning

Salah satu teknik yang kami gunakan adalah *transfer learning*. *Transfer Learning* merupakan teknik transfer pengetahuan melalui *Weight* yang telah didapatkan dari proses latih yang dilakukan sebelumnya [20]. *Transfer Learning* yang digunakan dalam penelitian ini menggunakan model CNN yang telah dilatih menggunakan data *imagenet*. Kami menggunakan *Transfer Learning* atau bisa dikatakan sebagai *pretrained* model karena ingin menggunakan kelebihan dari *pretrained* model dalam mengklasifikasikan citra babi, citra kambing dan citra sapi sehingga dapat meningkatkan performansi yang dihasilkan. Penelitian ini menggunakan 4 jenis *pretrained* model CNN yaitu Resnet-50, VGG-16, VGG-19 dan DenseNet-121, ke empat *pretrained* model tersebut akan di latih dengan beberapa skenario pelatihan dan pengujian, *top layer* dari ke empat *pretrained* model tersebut di *freeze* yang diubah hanya bagian *fully connected layer* nya saja,

2.3. Fase latih dan fase evaluasi

Fase latih dan fase evaluasi pada penelitian ini seperti pada Gambar 4, ke empat *pretrained* model akan di latih dengan *hyperparameter* yang telah di tentukan.



Gambar 4 Alur penelitian

Proses latih dan proses evaluasi pada penelitian ini dilakukan untuk mengetahui *performance* dari model terhadap *hyperparameter*. *Hyperparameter* yang digunakan pada penelitian ini berupa *learning rate*, *momentum*, *epoch* dan *fully connected layer* selain itu penelitian ini menggunakan *Data Augmentation* saat proses latih berlangsung. Variabel *data Augmentation* yang digunakan adalah *zooming*, *shear_range* dengan nilai 0.2 yang dimana nilai 0.2 tersebut merupakan nilai persenan dari citra tersebut, jika nilai *zooming* 0.2 maka citra akan di *zooming* 0.2 % dari ukuran citra asli selain itu *flipping image* juga digunakan pada *Data Augmentation* pada proses evaluasi performa dari model dilakukan setelah suatu model telah dilatih, proses evaluasi model pada penelitian ini menggunakan data test yang telah dipersiapkan ini dilakukan untuk mengetahui performa dari model tertentu terhadap citra di luar dataset latih, selain itu *metric* yang digunakan pada penelitian ini adalah *f1 score*, *precision* dan juga *recall* dengan rumus 1,2 dan 3.

$$\text{Precision (\%)} = \frac{\text{TP}}{(\text{FP} + \text{TP})} \quad (1)$$

$$\text{Recall (\%)} = \frac{\text{TP}}{(\text{FN} + \text{TP})} \quad (2)$$

$$\text{F-Measure (\%)} = \frac{(2 \times \text{Recall} \times \text{Precision})}{(\text{Recall} + \text{Precision})} \quad (3)$$

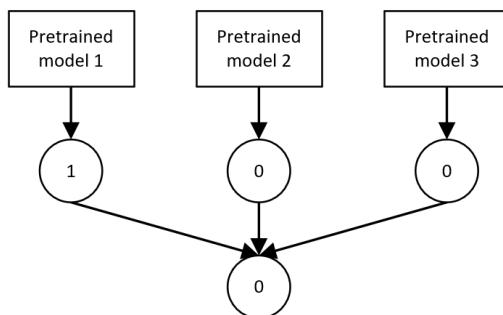
perhitungan *f1 score*, *precision* dan *recall* berdasarkan data TP, FN, FP dan TN yang didapatkan dari tabel *confusion matrix*. *True Positive* (TP) merupakan jumlah prediksi yang benar di kelas positif, sedangkan *False Negative* (FN) memiliki makna jumlah prediksi yang salah di kelas negatif, *False Negative* (FP) adalah jumlah prediksi yang salah di kelas positif sedangkan untuk *True Negative* (TN) memiliki arti jumlah prediksi yang benar di kelas negatif. Illustrasi *confusion matrix* dapat dilihat pada Gambar 5

		True class		
		Beef	Mutton	Pork
prediction	Beef	1	2	3
	Mutton	4	5	6
	Pork	7	8	9

Gambar 5 illustrasi confussion matrix

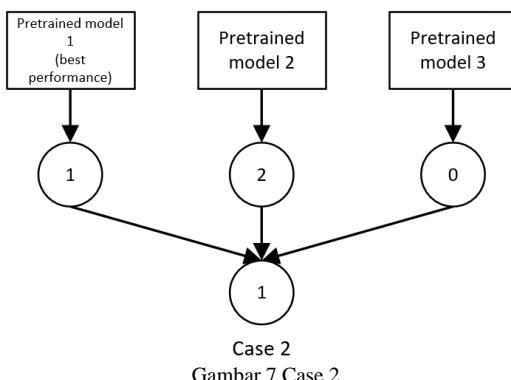
2.4. Hard Voting Classifier

Pada penelitian ini kami melakukan metode *voting based* yaitu *Hard Voting* yang dimana memiliki konsep mengambil sebuah keputusan dari nilai yang terbanyak muncul [19].



Gambar 6 Case 1

Gambar 6 merupakan illustrasi *Hard Voting* pada penelitian ini, pengambilan keputusan *Hard Voting* didasari dari suara prediksi terbanyak, jika prediksi suara terbanyak tidak ada maka model dengan performansi terbaik akan menjadi keputusan sistem *Hard Voting* seperti pada illustrasi case 2 seperti pada Gambar 7.



Gambar 7 Case 2

Pemilihan model arsitektur pada *Hard Voting* menggunakan sistem peringkat, peringkat pertama untuk model dengan kinerja terbaik sedangkan peringkat terakhir untuk model dengan kinerja terburuk. Pada penelitian ini kami membuat 2 kombinasi untuk *Hard*

Voting, rincian model yang digunakan pada *Hard Voting* seperti terlihat pada Tabel 3, hal ini kami lakukan untuk mengetahui pengaruh *Hard Voting* terhadap *pretrained* model.

Tabel 2. kombinasi pretrained model

No	Kombinasi pertama	urutan	Kombinasi kedua	urutan
1	Pretrained Model	4	Pretrained Model	3
2	Pretrained Model	3	Pretrained Model	2
3	Pretrained Model	2	Pretrained Model	1

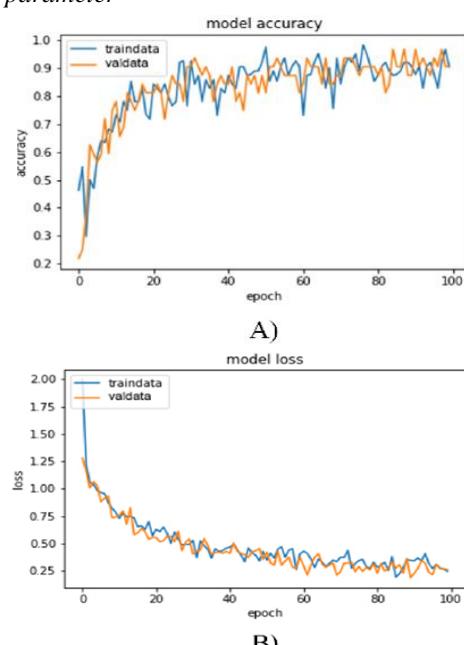
3. Hasil dan Pembahasan

Hyperparameter pada *pretrained* model akan diganti dan di kombinasikan beberapa kali dengan nilai yang telah ditentukan seperti pada Tabel 3, hal ini dilakukan untuk melihat dampak dan performansi dari model terhadap nilai *hyperparameter* yang digunakan.

Tabel 3 Hyperparameter yang digunakan

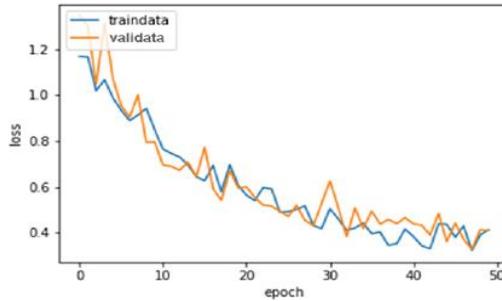
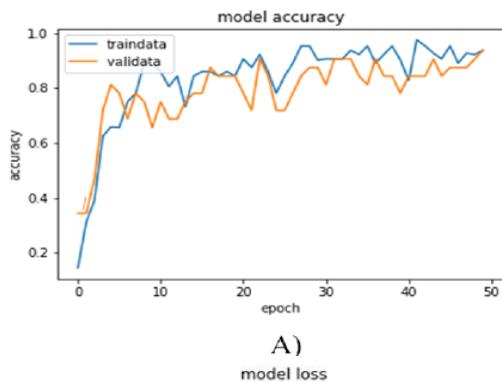
Learning rate	momentum	Fully connected layer	epoch
0.01	0.9	3	50
0.001	0.6	3-64	75
0.0001	0.3	3-64-128	100

Hyperparameter yang telah ditentukan akan dikombinasikan sama dengan masing-masing *pretrained* model agar hasilnya dapat dibandingkan pada saat evaluasi performansi dari masing-masing jenis *pretrained* model yang digunakan terhadap nilai suatu *hyperparameter*.



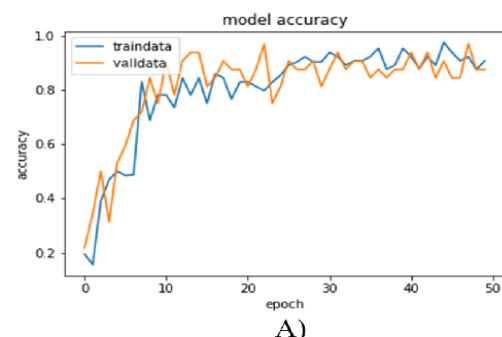
Gambar 8 A) grafik performance Resnet-50 B) grafik loss Resnet-50

Gambar 8 adalah grafik *performance* dan grafik *loss* yang dimana kedua grafik tersebut merupakan grafik dari model dengan performansi terbaik yang dihasilkan oleh Resnet-50 pada saat proses latih. grafik tersebut dilatih dengan kombinasi nilai *learning rate* 0.01, *momentum* 0.9, *fully connected layer* 64-3 pada epoch 100 dengan akurasi *f1 score* sebesar 97.77%, *precision* 97.71% dan *recall* 97.77%

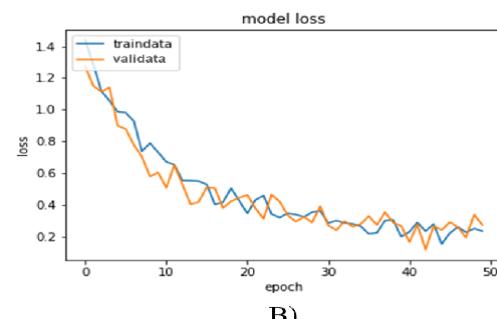


Gambar 8 A) grafik performance VGG-19 B) grafik loss VGG-19

Gambar 9 merupakan grafik *performance* dan grafik *loss* dari model dengan performansi terbaik VGG-16, kedua grafik tersebut merupakan grafik hasil dengan kombinasi nilai *learning rate* 0.001, *momentum* 0.9, *fully connected layer* 64-3 pada epoch 50 mendapatkan nilai *f1 score* sebesar 95.33%, *precision* sebesar 95.67% dan *recall* sebesar 94.1%.

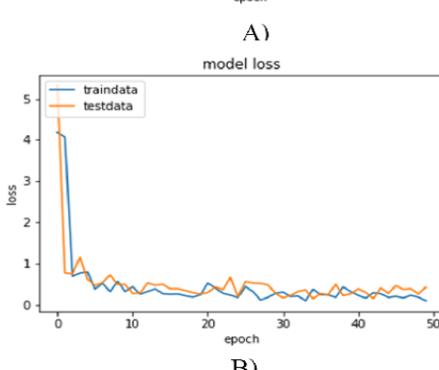
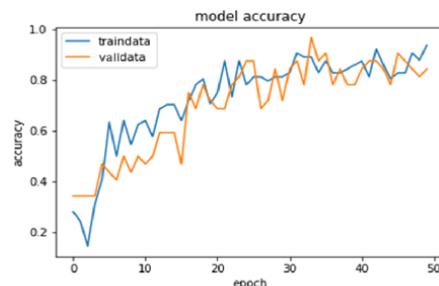


Gambar 9 A) grafik performance VGG-16 B) grafik loss VGG-16



Gambar 10 A) grafik performance VGG-19 B) grafik loss VGG-19

Gambar 10 terdiri dari 2 grafik yaitu grafik *loss* dan grafik *performance pretrained* model VGG-19, grafik tersebut merupakan grafik dengan *performance* terbaik VGG-19 dengan kombinasi *learning rate* 0.01, *momentum* 0.6, *fully connected layer* 64-3 pada epoch 50. Kedua grafik tersebut masih menunjukkan performa model yang baik dengan memperoleh nilai *f1 score* sebesar 94.1%, *precision* sebesar 94.2% dan *recall* sebesar 94.1%.



Gambar 11 A) grafik performance Densenet- 121 B) grafik loss Densenet-121

Gambar 11 merupakan grafik *performance* dan grafik *loss* dari *pretrained* model Densenet-121 dengan performansi terbaik dengan kombinasi dengan nilai *learning rate* 0.01, *momentum* 0.9, *fully connected layer* 3 pada epoch 50 yang dapat menghasilkan nilai *f1 score* sebesar 93%, *precision* 93% dan *recall* 93%. Rangkuman *performance* terbaik untuk masing-masing *pretrained* model dapat dilihat pada Tabel 4.

Tabel 4 Rangkuman Performance Pretrained Model

No	Pretrained Model	F1 score	Precision	Recall
1	Resnet-50	97.77%	97.91%	97.77%
2	VGG-16	95.33%	95.67%	95.33%
3	VGG-19	94.1%	94.2%	94.1%
4	Densenet-121	93%	93%	93%

3.2 hasil Voting-based Deep Learning

Hard Voting pada penelitian ini akan dicoba 2 kali dengan menggabungkan 3 model seperti terlihat pada Tabel 5.

Tabel 5 Kombinasi Voting-Based

No	Kombinasi pertama	urutan	Kombinasi kedua	urutan
1	VGG-16	4	Resnet-50	3
2	VGG-19	3	VGG-16	2
3	Densenet-121	2	VGG-19	1

Kombinasi pertama terdiri dari VGG-16, VGG-19, Densenet-121 sedangkan kombinasi kedua adalah Resnet-50, VGG-16, VGG-19 yang dimana pembagian tersebut didasari dari urutan performansi masing-masing model. *Hard Voting* di evaluasi menggunakan dataset test dengan *f1 score metric*. Hasil *Hard Voting* dapat dilihat pada Table 6 terlihat bahwa *Hard Voting* model 1 dapat mengungguli *pretrained* model VGG-16, VGG-19 dan Densenet-121 dengan akurasi *f1 score* 96,55% *precision* 96,56% dan *recall* 96,55% tetapi tidak dapat mengungguli model Resnet-50 yang telah dilatih sebelumnya dengan akurasi *f1 score* 97,77% *precision* 97,91% dan *recall* 97,77%, Model *Hard Voting* 2 yang terdiri dari Resnet-50, VGG-16 dan VGG-19 mendapatkan akurasi yang sangat tinggi yaitu 98,88% *f1 score*, *precision* 98,89% dan *recall* 98,88% mengungguli *pretrained* model Resnet-50, VGG-16, VGG-19 dan juga mengungguli *Hard Voting* model 1, rangkuman *performance voting based* model dan *pretrained* model dapat dilihat pada Tabel 6.

Tabel 6 *Hard Voting* di komparasi dengan model lainya

No	Kombinasi pertama	F1 Score	Precision	Recall
1	<i>Hard Voting</i> -2	98.88%	98.89%	98.88%
2	Resnet-50	97.77%	97.91%	97.77%
3	<i>Hard Voting</i> -1	96.55%	96.56%	96.55%
4	VGG-16	95.33%	95.67%	95.33%
5	VGG-19	94.1%	94.2%	94.1%
6	Densenet-121	93%	93%	93%

4. Kesimpulan

Dalam penelitian ini, kami mengklasifikasikan citra daging babi, sapi dan kambing menggunakan beberapa metode *Deep Learning* seperti Resnet-50, VGG-16, VGG-19 dan Densenet-121 dengan mengkombinasikan beberapa konfigurasi *hyperparameter* dan *Hard Voting* untuk mendapatkan model yang baik. Hasil tersebut kami menemukan bahwa Resnet-50 merupakan aristekturnya *pretrained* model terbaik dalam studi kasus ini dengan

tingkat akurasi *f1 score* sebesar 97,7%, *precision* 97,91% dan *recall* 97,77% dengan kondisi *learning rate momentum* 0,01 / 0,9 pada epoch 100 dengan *fully connected layer* 64 3 *node* disusul oleh VGG-16, VGG-19 dan Densenet-121, selanjutnya *Hard Voting* 2 yang terdiri dari Resnet-50, VGG-16, VGG-19 pada studi kasus ini dapat mengungguli *Hard Voting* 1 dan dapat menungguli kemampuan 4 *pretrained* model dengan dengan akurasi *f1 score* 98,88%, *precision* 98,89% dan *recall* 98,88% sedangkan untuk *Hard Voting* 2 berada di bawah Resnet-50 dengan akurasi *f1 score* 96,55%, *recall* 96,56% dan *precision* 96,55% namun dapat mengungguli *performance* VGG-16, VGG19 dan Densenet-121, dari hasil evaluasi pada studi ini dapat dikatakan bahwa *Hard Voting* dapat meningkatkan kemampuan *performance* dari suatu model selain itu hasil dari studi kasus ini Resnet-50 merupakan *pretrained* model yang dapat mengungguli *performance* dari VGG-16, VGG-19 dan Densenet-121 dalam melakukan klasifikasi citra daging.

Daftar Rujukan

- [1] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [2] P. Fischer, A. Dosovitskiy, and T. Brox, “Descriptor Matching with Convolutional Neural Networks: a Comparison to SIFT.” 2015.
- [3] R. Raina, A. Battle, H. Lee, B. Packer, and A. Y. Ng, “Self-Taught Learning: Transfer Learning from Unlabeled Data,” in *Proceedings of the 24th International Conference on Machine Learning*, 2007, pp. 759–766, doi: 10.1145/1273496.1273592.
- [4] S. Xia, M. Shao, J. Luo, and Y. Fu, “Understanding kin relationships in a photo,” *IEEE Trans. Multimed.*, vol. 14, no. 4 PART1, pp. 1046–1056, 2012, doi: 10.1109/TMM.2012.2187436.
- [5] W. Liu *et al.*, “SSD: Single Shot MultiBox Detector BT - Computer Vision – ECCV 2016,” 2016, pp. 21–37.
- [6] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788, doi: 10.1109/CVPR.2016.91.
- [7] J. Redmon and A. Farhadi, “YOLO9000: Better, Faster, Stronger,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 6517–6525, doi: 10.1109/CVPR.2017.690.
- [8] Y. Qian and P. C. Woodland, “Very Deep Convolutional Neural Networks for Robust Speech Recognition.” 2016.
- [9] R. A. Asmara *et al.*, “Classification of pork and beef meat images using extraction of color and texture feature by Grey Level Co-Occurrence Matrix method,” *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 434, no. 1, 2018, doi: 10.1088/1757-899X/434/1/012072.
- [10] N. Neneng, K. Adi, and R. Isnanto, “Support Vector Machine Untuk Klasifikasi Citra Jenis Daging Berdasarkan Tekstur Menggunakan Ekstraksi Ciri Gray Level Co-Occurrence Matrices (GLCM),” *J. Sist. Inf. Bisnis*, vol. 6, no. 1, p. 1, 2016, doi: 10.21456/vol6iss1pp1-10.
- [11] P. Hridayami, I. K. G. D. Putra, and K. S. Wibawa, “Fish species recognition using VGG16 deep convolutional neural network,” *J. Comput. Sci. Eng.*, vol. 13, no. 3, pp. 124–130, 2019, doi: 10.5626/JCSE.2019.13.3.124.
- [12] I. M. A. Agastya and A. Setyanto, “Classification of Indonesian Batik Using Deep Learning Techniques and Data Augmentation,” in *2018 3rd International Conference on*

- Information Technology, Information System and Electrical Engineering (ICITISEE)*, 2018, pp. 27–31, doi: 10.1109/ICITISEE.2018.8720990.
- [13] R. Rokhana *et al.*, “Convolutional Neural Network untuk Pendeksiyan Patah Tulang Femur pada Citra Ultrasonik B-Mode,” *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 1, p. 59, 2019, doi: 10.22146/jnteti.v8i1.491.
- [14] H. Kaur and G. Kaur, “Voting based classification method for diabetes prediction,” *Int. J. Recent Technol. Eng.*, vol. 8, no. 2 Special Issue 6, pp. 913–918, 2019, doi: 10.35940/ijrte.B1172.0782S619.
- [15] A. S. Assiri, S. Nazir, and S. A. Velastin, “Breast Tumor Classification Using an Ensemble Machine Learning Method,” *J. Imaging*, vol. 6, no. 6, 2020, doi: 10.3390/JIMAGING6060039.
- [16] T. G. Dietterich, “Ensemble methods in machine learning,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 1857 LNCS, pp. 1–15, 2000, doi: 10.1007/3-540-45014-9_1.
- [17] B. A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Cnn实际训练的,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2012.
- [18] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, “A survey of the recent architectures of deep convolutional neural networks,” *Artif. Intell. Rev.*, vol. 53, no. 8, pp. 5455–5516, 2020, doi: 10.1007/s10462-020-09825-6.
- [19] R. Systems, “Memory-Based Weighted-Majority Prediction for Recommender Systems.”
- [20] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.