
Analisis Perbandingan Optimizer pada Arsitektur NASNetMobile Convolutional Neural Network untuk Klasifikasi Ras Kucing

D. Diffran Nur Cahyo¹, Muhammad Anwar Fauzi², Jangkung Tri Nugroho³, Kusri⁴

¹²³⁴Magister Teknik Informatika - Universitas Amikom Yogyakarta

Email: difffran@students.amikom.ac.id¹, anwarfauzi1999@students.amikom.ac.id²,
jan.nugroho@students.amikom.ac.id³, kusrini@amikom.ac.id⁴

ABSTRACT

Searching for research titles and abstracts is made easy with these keywords. Artificial Intelligence (AI) technology is currently developing very rapidly, there are various applications of AI that we can find in everyday life around us without realizing it. AI technology now allows us to work with computers more easily, just as we can know the type of cat breed and other information. There is deep learning that works by imitating the human brain or artificial neural networks to enhance current machine-learning capabilities. Deep learning can recognize and classify image categories. This study aims to determine the optimal optimizer in the classification of cat breeds. With the classification of cat breeds, cat keepers can find out the type of cat breed so they can find out how to care for it, the activities, and the personality possessed by the cat. The use of algorithm method used in this study uses the CNN algorithm with the NASNetMobile architecture. The dataset contains 840 images which are divided into 4 classes and divided into 588 training data, 168 testing data, and 84 validation data. for the RMSprop optimizer with a learning rate of 0.0001 to get an accuracy of 89.88%, this result is the highest among the others. Meanwhile, the SGD optimizer gets an accuracy of 78.57 & this result is the lowest. So it can be concluded that the architecture and optimizer are very important and influential in improving the performance of the model.

Keywords: cat breed classification, convolutional neural network, deep learning, NASNetMobile, optimizer.

INTISARI

Pencarian judul penelitian dan abstraknya dipermudah dengan kata-kata kunci tersebut. Teknologi Artificial Intelligence (AI) saat ini sudah berkembang sangat pesat, terdapat berbagai penerapan AI yang bisa kita temukan di kehidupan sehari-hari disekitar kita tanpa kita sadari. Teknologi AI saat ini memungkinkan kita untuk berkegiatan dengan komputer menjadi lebih mudah, seperti halnya kita bisa tahu jenis ras kucing dan informasi lainnya. Adanya deep learning yang bekerja meniru otak manusia atau jaringan saraf tiruan untuk meningkatkan kemampuan machine learning saat ini. Deep learning dapat mengenali dan mengklasifikasikan kategori citra. Penelitian ini bertujuan untuk menentukan optimizer yang optimal pada klasifikasi ras kucing. Dengan adanya klasifikasi ras kucing, pemelihara kucing dapat mengetahui jenis ras kucing agar dapat mengetahui cara pemeliharannya, aktivitas, dan kepribadian yang dimiliki oleh kucing tersebut. Penggunaan metode algoritma yang digunakan dalam penelitian ini menggunakan algoritma CNN dengan arsitektur NASNetMobile. Dataset berisi 840 gambar yang dibagi menjadi 4 kelas dan dibagi menjadi 588 data training, 168 data testing, dan 84 data validasi. untuk optimizer RMSprop dengan learning rate 0.0001 mendapatkan akurasi 89.88% hasil ini merupakan yang tertinggi diantara yang lainnya. Sedangkan untuk optimizer SGD mendapatkan akurasi 78.57& hasil ini merupakan yang terendah. Sehingga dapat disimpulkan arsitektur dan optimizer sangat penting dan berpengaruh untuk meningkatkan kinerja model.

Kata kunci: convolutional neural network, deep learning, klasifikasi ras kucing, NASNetMobile, optimizer.

PENDAHULUAN

Kucing (*Felis catus*) merupakan mamalia *karnivora* dari keluarga *Felidae* (Menotti-Raymond & O'Brien, 1995). Pada 6000 SM, kucing diketahui telah berbaur dengan manusia dan menyebar ke berbagai belahan dunia. Jumlah kucing ras di dunia hanya sekitar 1%, sehingga sebagian besar didominasi oleh kucing hibrida atau domestik (Lipinski et al., 2008). Kurangnya kucing ras membuat kucing ras jauh lebih mahal. Setiap ras kucing memiliki karakteristiknya sendiri, tetapi karena banyaknya persilangan, menjadi lebih sulit untuk mengidentifikasi ras kucing (Karlita et al., 2022), namun terkadang tidak semua pemilik kucing mengetahui jenis kucingnya. Perawatan kucing perlu dilakukan dengan perawatan khusus untuk menjamin kesehatan kucing tersebut, tergantung dari

rasnya karena setiap ras kucing memiliki karakteristik yang berbeda sehingga diperlukan perawatan yang berbeda (Lipinski et al., 2008). Ada berbagai ras kucing di seluruh dunia dan setiap ras memiliki ciri, penampilan, dan kepribadian yang berbeda. Mereka juga tidak mirip dengan satu sama lain dalam segala hal. Faktor-faktor yang mempengaruhi ras kucing diantaranya yaitu ukuran, pemeliharaan, aktivitas, bulu, dan kepribadian atau temperamen (O'Brien et al., 2008).

Munculnya era kecerdasan buatan melalui pengenalan gambar berkembang sangat pesat (Zhang et al., 2019). Seringkali koleksi gambar yang digunakan pada beberapa tahap sistem klasifikasi memiliki kekurangan, seperti banyak *noise*, *shading*, kontras rendah, dan gambar buram. Salah satu pendekatan yang dapat digunakan adalah teknik deep learning yang dapat menangkap dan memukul suatu item dalam sebuah citra virtual. Salah satu teknik deep learning yang dapat mengenali dan mengklasifikasikan kategori citra adalah *Convolutional Neural Networks* (CNN) (Purnama, 2020).

Pada penelitian sebelumnya dilakukan klasifikasi ras kucing (Jaka et al., 2022) dengan membandingkan algoritma *Support Vector Machine* (SVM) dan Naive Bayes (NB) dalam klasifikasi citra ras kucing menggunakan model *Deep Learning SqueezeNet* sebagai proses ekstraksi ciri pada citra. Hasil dari penelitian ini secara eksperimental akan mendemonstrasikan perbedaan antara akurasi, presisi dan recall dari masing-masing algoritma. Hasil yang diperoleh menunjukkan *classifier* terbaik adalah algoritma *Support Vector Machine* (SVM) dengan nilai akurasi 88,4%, precision 88,5% dan memori 88,4% sedangkan yang terendah adalah algoritma *Naive Bayes* (NB) dengan akurasi sebesar 79,5%, precision 79,9%, dan recall 79,5%.

Pada penelitian (Imanuel & Setiabudi, n.d.) menggunakan metode transfer *learning* pada Arsitektur *Xception*, model CNN yang terinspirasi oleh model CNN Inception. Model *Xception* adalah model Inception di mana modul Inception diganti dengan *depthwise separable convolutions*. Model CNN *Xception* digunakan dalam tugas akhir ini untuk meningkatkan akurasi dalam mendeteksi ras kucing. Hasil sistem menunjukkan bahwa akurasi tertinggi yang dihasilkan saat mendeteksi ras kucing pada Oxford-IIIT Pet Dataset adalah sebesar 89,58% atau 0,8958. Dibandingkan dengan metode *Mobilenet_v1 FPN SSD* yang memiliki akurasi sebesar 81,74%, implementasi metode *Xception* meningkatkan akurasi menjadi 7,84%, selain itu juga menemukan bahwa kualitas kumpulan data mempengaruhi keakuratan model.

Berbeda dengan penelitian (Wikarta et al., 2020) melalui pendeteksian penggunaan masker oleh pengemudi dan penumpang pada kendaraan akan dilakukan secara otomatis dengan menggunakan *convolutional neural network* (CNN) atau *Convnet*. Ada 3 jenis pengoptimal yang dianalisis, yaitu SGD, RMSprop dan ADAM. Hasil pelatihan CNN menunjukkan bahwa pemilihan jenis pengoptimal akan memberikan tingkat akurasi dan kerugian yang berbeda. Nilai akurasi CNN dengan pengoptimal SGD, RMSprop dan ADAM adalah sebagai berikut: 0,7577, 0,9577 dan 0,9654. Nilai ini menunjukkan bahwa pengoptimal SGD memiliki akurasi terendah, sedangkan pengoptimal ADAM memiliki akurasi tertinggi.

Selanjutnya pada penelitian (Vani & Rao, 2019), *Deep Learning* adalah sub-disiplin dari *Machine Learning* dengan Layers digunakan di dalamnya untuk membuat *Artificial Neural Network* (ANN). *Convolutional Neural Network* (CNN), Arsitektur Deep Learning telah menjadi inovasi paling berpengaruh dalam *Computer Vision*. Pengoptimal terbentuk dan membentuk model menjadi bentuk yang paling akurat dengan menggunakan bobot. Dalam makalah ini, tujuh pengoptimal yaitu *Stochastic Gradient Descent* (SGD), *RMSProp*, *Adam*, *Adamax*, *Adagrad*, *Adadelta*, dan *Nadam* diimplementasikan di CNN pada *Dataset Indian Pines* dan hasil perbandingan akurasi ditampilkan secara grafis di mana *Adamax* mengungguli dengan akurasi 99,58%.

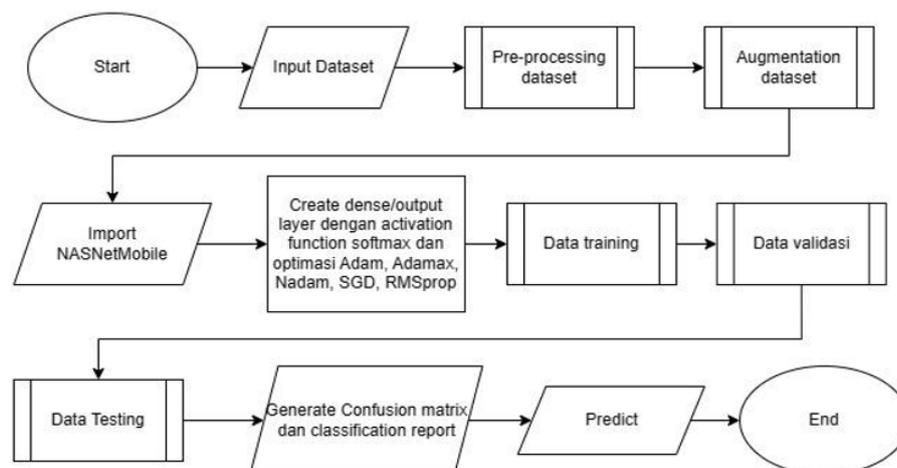
Penelitian lainnya (Amiruddin & Kadir, 2020) mengidentifikasi spesies atau genera nyamuk merupakan bagian penting dalam pengendalian penyebaran penyakit menular yang ditularkan oleh nyamuk. Dengan pesatnya perkembangan arsitektur *neural network*, jenis nyamuk dapat diidentifikasi tanpa menggunakan mikroskop melainkan langsung dari gambar yang ditangkap oleh kamera atau kamera smartphone. Dengan alat ini, jenis atau tipe nyamuk dapat diketahui dengan cepat. Dalam pekerjaan ini, evaluasi kinerja arsitektur *Convolutional Neural Network* (CNN) dilakukan untuk menganalisis tugas klasifikasi citra nyamuk dengan mengklasifikasikan 200 data citra nyamuk dari mesin pencari Bing, dibagi menjadi empat kategori. Menurut hasil yang diperoleh, arsitektur *NASNetMobile* memberikan akurasi 73% dan arsitektur *MobileNetV2* memberikan performa terbaik pada metrik yang diuji. Model ini memberikan akurasi 80% pada set pengujian.

Selanjutnya pada penelitian (Adedoja et al., 2022) mengembangkan sistem diagnostik penyakit pohon bergerak cerdas yang bekerja pada telepon pintar. Sistem diagnostik didasarkan pada *NASNet-Mobile*, arsitektur *convolutional neural network* (CNN) ringan yang menggunakan

pencitraan daun untuk mendiagnosis penyakit tanaman. Aplikasi seluler telah dikembangkan untuk smartphone Android dan iOS untuk mengambil gambar daun. Sistem berjalan pada layanan web yang memperoleh diagnostik dari model CNN. Gambar daun yang diambil dengan aplikasi seluler yang dikembangkan dikirim melalui layanan web dan identifikasi penyakit dilakukan menggunakan model *NASNet-Mobile* CNN, sistem diagnosis penyakit pohon model CNN yang disediakan oleh *NASNet-Mobile* mencapai tingkat akurasi 99,31%.

METODE

Metode penelitian dilakukan untuk mengetahui perbandingan antara lima Optimizer (Bera & Shrivastava, 2020) dengan menggunakan Arsitektur *NASNetMobile* (Radhika et al., 2020), sedangkan Algoritma CNN pada klasifikasi ras kucing yang akan dibuat memiliki beberapa tahapan pada gambar 1.



Gambar 1. Tahapan penelitian

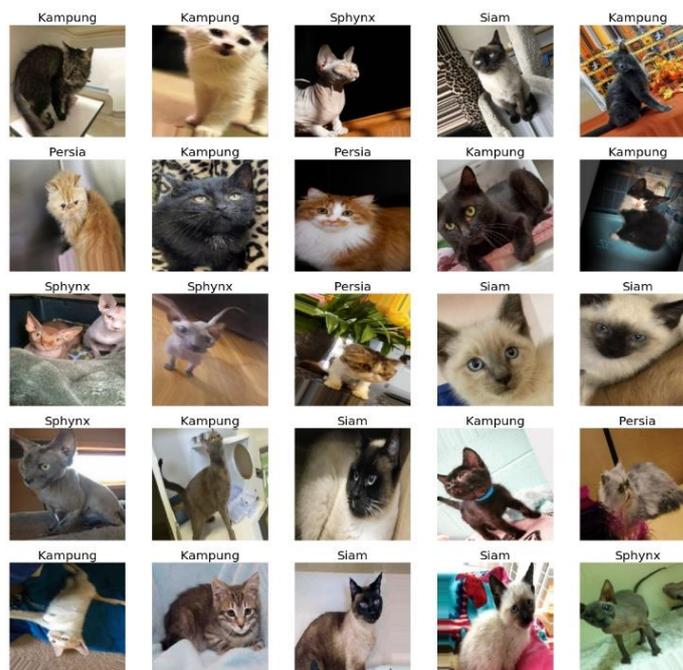
Tahapan tersebut adalah melakukan input database, pre-processing dataset, augmentation dataset, import *NASNetMobile*, membuat output/dense layer dengan activation function softmax dan optimizer menggunakan *Adam*, *Adamax*, *Nadam*, *SGD*, dan *RMSprop*, melakukan data training dan data testing, dan evaluasi dengan menggunakan confusion matrix dan *classification report*. Pada input dataset, dataset diambil dari *Kaggle* yaitu *Cat Breeds Dataset*. Keseluruhan dataset ras kucing sebanyak 840 gambar dengan 4 jenis ras kucing yaitu kucing kampung, persia, siam, dan sphynx. Pada tabel 1 menunjukkan dataset ras kucing yang akan digunakan untuk penelitian.

Tabel 1. Dataset

Class	Jumlah	Contoh Gambar
Kampung	210	
Persia	210	
Siam	210	

Sphynx	210	
Total	840	

Selanjutnya pada tahap *preprocessing* data, gambar-gambar dari dataset di *resize* menjadi 224x224. Setelah proses *resize* dilakukan *preprocessing* selanjutnya yaitu *rescale* 1/225, *rotation range* sebesar 30, *zoom range* sebesar 0.2, *width shift range* 0.1, *height shift range* 0.1, *horizontal flip*, dan *fill mode nearest*. Setelah tahap *preprocessing*, selanjutnya masuk ke tahap *augmentasi* dalam tahap ini hanya melakukan *penggandaan* agar gambar menjadi bervariasi. Pada gambar 2 menunjukkan hasil setelah *preprocessing* dan *augmentasi* data.



Gambar 2. Proses setelah *preprocessing* dan *augmentasi*

HASIL DAN PEMBAHASAN

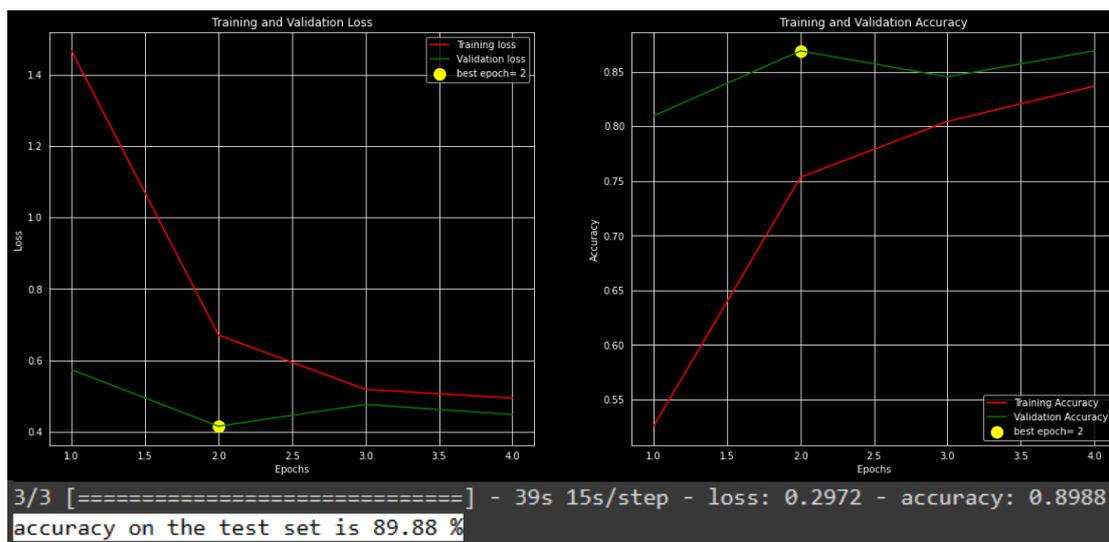
Proses data training terdapat lima skenario. Untuk kelima skenario ini menggunakan Arsitektur *NASNetMobile* dengan menggunakan *weights* dari *imagenet*. Kemudian untuk layer menggunakan 1 *max pooling* dengan size 2 dan *fully connection* dengan 1 *dropout* dengan nilai 0.5. Untuk skenario 1 menggunakan *optimizer Adam* dengan *learning rate* 0.0001. Skenario 2 menggunakan *optimizer Adamax* dengan *learning rate* 0.0001. Skenario 3 menggunakan *optimizer Nadam* dengan *learning rate* 0.0001. Skenario 4 menggunakan *optimizer SGD* dengan *learning rate* 0.0001. Dan skenario 5 menggunakan *optimizer RMSprop* dengan *learning rate* 0.0001. Pada tabel 2 menunjukkan hasil skenario yang telah dilatih.

Tabel 2. Hasil skenario

Skenario	Optimizer	Learning Rate	Akurasi	Validasi
1	Adam	0.0001	88.1%	88.1%
2	Adamax	0.0001	87.5%	90.48%
3	Nadam	0.0001	83.93%	86.9%
4	SGD	0.0001	78.57%	80.95%
5	RMSprop	0.0001	89.88%	86.9%

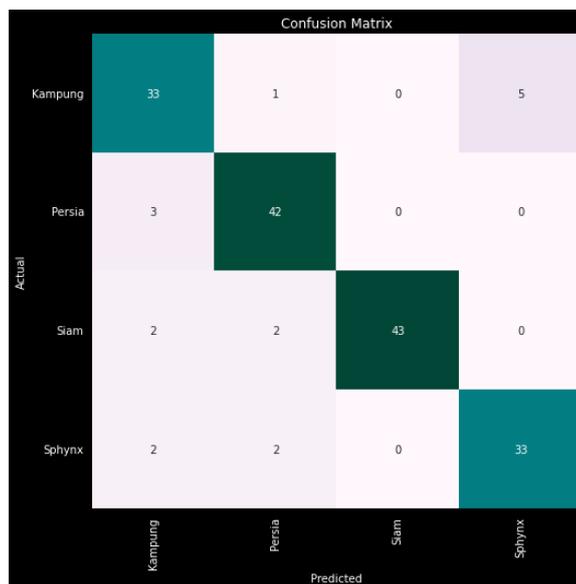
Pada tabel 2 menunjukkan *optimizer RMSprop* dengan *learning rate* 0.0001 mendapatkan akurasi 89.88% yang dimana hasil ini merupakan yang tertinggi diantara yang lainnya. Sedangkan

untuk *optimizer* SGD mendapatkan akurasi 78.57% dan hasil ini merupakan yang terendah. Pada gambar 3 menunjukkan grafik training dan validasi pada *optimizer RMSprop*.



Gambar 3. Grafik training dan validasi pada *optimizer RMSprop*

Setelah melakukan data training dari kelima skenario, selanjutnya masuk ke tahap testing atau pengujian dalam pengujian ini menggunakan *Optimizer RMSprop* karena mendapatkan nilai akurasi yang terbaik. Dalam pengujian ini akan melakukan proses evaluasi matrix dan classification report yang menggunakan confusion matrix. Pada gambar 4 menunjukkan hasil dari *confusion matrix* pada Algoritma CNN dengan Arsitektur *NASNetMobile* dengan optimasi *RMSprop*.



Gambar 4. Confusion Matrix pada *optimizer RMSprop*

Sesuai hasil confusion matrix pada Algoritma CNN dengan arsitektur *NASNetMobile* dan *Optimizer RMSprop* didapatkan bahwa:

1. Dari 40 gambar kucing kampung, terdapat 33 gambar dengan prediksi yang sesuai dengan aktual.
2. Dari 47 gambar kucing persia, terdapat 42 gambar dengan prediksi yang sesuai dengan aktual.
3. Dari 43 gambar kucing siam, terdapat 43 gambar dengan prediksi yang sesuai dengan aktual.
4. Dari 38 gambar kucing sphynx, terdapat 33 gambar dengan prediksi yang sesuai dengan aktual.

Setelah mengetahui hasil *confusion matrix*, selanjutnya memproses *classification report* yang meliputi *precision*, *recall*, dan *F1-Score*. Pada gambar 5 menunjukkan hasil *classification report*.

```

Classification Report:
-----

```

	precision	recall	f1-score	support
Kampung	0.82	0.85	0.84	39
Persia	0.89	0.93	0.91	45
Siam	1.00	0.91	0.96	47
Sphynx	0.87	0.89	0.88	37
accuracy			0.90	168
macro avg	0.90	0.90	0.90	168
weighted avg	0.90	0.90	0.90	168

Gambar 5. Classification Report pada optimizer RMSprop

KESIMPULAN

Kesimpulan yang diperoleh dari penelitian ini berfokus pada perbandingan optimizer pada Algoritma CNN untuk mengklasifikasikan ras kucing. Penggunaan arsitektur *NASNetMobile* dengan dataset 840 gambar dari 4 ras kucing yang berbeda dengan 588 gambar digunakan untuk training, 168 untuk testing, dan 84 untuk validasi. Setelah melakukan proses pelatihan dengan 5 skenario, diperoleh hasil yang paling optimal pada *optimizer RMSprop* dengan nilai akurasi 89.88% dan validasi 86.9% sehingga arsitektur dan optimizer sangat penting dan berpengaruh untuk meningkatkan kinerja model. Untuk penelitian selanjutnya, dapat dilakukan untuk memperbaiki model yang sudah ada, dengan alternatif tambahkan kelas dataset untuk ras kucing yang memiliki karakteristik yang cukup mirip. Dapat juga digunakan arsitektur dan pengoptimalan lain untuk hasil yang lebih baik, juga menambahkan lebih banyak gambar ras kucing untuk training, testing, dan validasi, serta menambahkan lebih banyak kategori ras kucing ke sistem.

Daftar Pustaka

- Adedoja, A. O., Owolawi, P. A., Mapayi, T., & Tu, C. (2022). Intelligent Mobile Plant Disease Diagnostic System Using NASNet-Mobile Deep Learning. *IAENG International Journal of Computer Science*, 49(1), 216–231.
- Amiruddin, B. P., & Kadir, R. E. A. (2020). CNN Architectures Performance Evaluation for Image Classification of Mosquito in Indonesia. *Proceedings - 2020 International Seminar on Intelligent Technology and Its Application: Humanification of Reliable Intelligent Systems, ISITIA 2020*, 223–227. <https://doi.org/10.1109/ISITIA49792.2020.9163732>
- Bera, S., & Shrivastava, V. K. (2020). Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification. *International Journal of Remote Sensing*, 41(7), 2664–2683. <https://doi.org/10.1080/01431161.2019.1694725>
- Crowell-Davis, S. L., Curtis, T. M., & Knowles, R. J. (2004). Social organization in the cat: A modern understanding. *Journal of Feline Medicine and Surgery*, 6(1), 19–28. <https://doi.org/10.1016/j.jfms.2003.09.013>
- Imanuel, A., & Setiabudi, D. H. (n.d.). *Penerapan Convolutional Neural Network dengan Pre-Trained Model Xception untuk Meningkatkan Akurasi dalam Mengidentifikasi Jenis Ras Kucing*. www.kaggle.com
- Jaka, K., Abwabul, J., Muhammad Zulkarnain, L., Rubianto, & Rika, R. (2022). Komparasi Algoritma Support Vector Machine Dan Naive Bayes Pada Klasifikasi Ras Kucing. *Jurnal Generic*, 14(1), 8–12. <http://generic.ilkom.unsri.ac.id/index.php/generic/article/view/122>
- Karlita, T., Choirunisa, N. A., Asmara, R., & Setyorini, F. (2022). Cat Breeds Classification Using Compound Model Scaling Convolutional Neural Networks. *Proceedings of the International Conference on Applied Science and Technology on Social Science 2021 (ICAST-SS 2021)*, 647, 909–914. <https://doi.org/10.2991/assehr.k.220301.150>
- Lipinski, M. J., Froenicke, L., Baysac, K. C., Billings, N. C., Leutenegger, C. M., Levy, A. M., Longeri, M., Niini, T., Ozpinar, H., Slater, M. R., Pedersen, N. C., & Lyons, L. A. (2008). The ascent of cat breeds: Genetic evaluations of breeds and worldwide random-bred populations.

- Genomics*, 91(1), 12–21. <https://doi.org/10.1016/j.ygeno.2007.10.009>
- Menotti-Raymond, M. A., & O'Brien, S. (1995). Evolutionary conservation of ten microsatellite loci in four species of felidae. *Journal of Heredity*, 86(4), 319–322. <https://doi.org/10.1093/oxfordjournals.jhered.a111594>
- O'Brien, S. J., Johnson, W., Driscoll, C., Pontius, J., Pecon-Slattery, J., & Menotti-Raymond, M. (2008). State of cat genomics. *Trends in Genetics*, 24(6), 268–279. <https://doi.org/10.1016/j.tig.2008.03.004>
- Purnama, I. N. (2020). Herbal Plant Detection Based on Leaves Image Using Convolutional Neural Network With Mobile Net Architecture. *JITK (Jurnal Ilmu Pengetahuan Dan Teknologi Komputer)*, 6(1), 27–32. <https://doi.org/10.33480/jitk.v6i1.1400>
- Radhika, K., Devika, K., Aswathi, T., Sreevidya, P., Sowmya, V., & Soman, K. P. (2020). Performance analysis of NASNet on unconstrained ear recognition. *Studies in Computational Intelligence, SCI 871*, 57–82. https://doi.org/10.1007/978-3-030-33820-6_3
- Vani, S., & Rao, T. V. M. (2019). An experimental approach towards the performance assessment of various optimizers on convolutional neural network. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019, Icoei*, 331–336. <https://doi.org/10.1109/ICOEI.2019.8862686>
- Wikarta, A., Sigit Pramono, A., & Ariatedja, J. B. (2020). Analisa Berbagai Optimizer Pada Convolutional Neural Network Untuk Deteksi Pemakaian Masker Pengemudi Kendaraan. *Seminar Nasional Informatika, 2020(Semnasif)*, 69–72.
- Zhang, Q., Zhang, M., Chen, T., Sun, Z., Ma, Y., & Yu, B. (2019). Recent advances in convolutional neural network acceleration. *Neurocomputing*, 323, 37–51. <https://doi.org/10.1016/j.neucom.2018.09.038>