

Klasifikasi Jenis Pola Citra Sidik Jari Dengan ...

By: JULIAN Supardi

As of: Mar 13, 2025 7:49:19 AM
3,358 words - 14 matches - 5 sources

Similarity Index

5%

Mode: Similarity Report ▾

paper text:

Klasifikasi Jenis Pola Citra Sidik Jari Dengan Arsitektur Xception, VGG-16 dan NasNetLarge Classification of Fingerprint Image Pattern Types Using Xception, VGG-16 and NasNetLarge Architectures Agus Andreansyah1]*, Julian Supardi[2] Abstract— This research aims

to enhance and classify fingerprint patterns

3

and determine the best model architecture using the CNN method, namely Xception, VGG-16, and NasNetLarge. Fingerprints are

a unique biometric identity and are often used as evidence in court. However

3

, challenges frequently arise when fingerprint quality deteriorates

due to external factors such as uneven surfaces, weather, or distortion. The fingerprint dataset

3

studied includes both secondary and primary data, both of which will be compared in terms of the accuracy of each CNN architecture. In image processing, CNN can be used for image enhancement and classification. The focus of fingerprint pattern classification consists of whorl, arch, radial loop, ulnar loop, and twinted loop patterns. Some CNN architectures, such as Xception and NasNetLarge, have demonstrated high accuracy in image classification in previous research, with accuracy reaching up to 98.5%. The research results show that the accuracy of secondary and primary data differs significantly. The accuracy of secondary data is higher than that of primary data. For primary data, the Xception architecture has an accuracy of 93%, while for secondary data, it reaches 97.5%. The VGG-16 architecture achieves 98% accuracy for primary data, but only 91% for secondary data. Meanwhile, the NasNetLarge architecture achieves 95.5% accuracy for secondary data and 97% for primary data. Keywords— Fingerprint, CNN Models, Xception, VGG-16 and NasNetLarge Abstrak— Penelitian ini akan melakukan perbaikan dan klasifikasi pola sidik jari dan menentukan model arsitektur metode CNN yaitu Xception, VGG-16, dan NasNetLarge, yang paling baik. Sidik

jari merupakan identitas biometrik yang unik dan sering digunakan sebagai alat bukti di pengadilan. Namun, hambatan sering muncul ketika kualitas sidik jari menurun akibat faktor eksternal seperti permukaan yang tidak rata, cuaca, atau distorsi. Dataset sidik jari yang diteliti meliputi data sekunder dan primer yang keduanya akan dibandingkan akurasi setiap arsitektur CNN. Dalam pengolahan citra, CNN dapat digunakan untuk perbaikan dan klasifikasi citra. Fokus klasifikasi pola sidik jari terdiri dari pola whorl, arch, loop radial, loop ulnar dan twinted loop. Beberapa arsitektur CNN yang digunakan, seperti Xception dan NasNetLarge, telah menunjukkan tingkat akurasi yang tinggi dalam klasifikasi citra pada penelitian sebelumnya, dengan akurasi mencapai hingga 98,5%. Hasil penelitian menunjukkan bahwa akurasi data sekunder dan primer memiliki perbedaan yang cukup signifikan. Akurasi data sekunder lebih tinggi dibandingkan dengan data primer. Pada data primer, arsitektur Xception memiliki akurasi 93%, sedangkan pada data sekunder mencapai 97,5%. Arsitektur VGG-16 pada data primer memiliki akurasi 98%, sedangkan data sekunder hanya 91%. Sementara itu, arsitektur NasNetLarge pada data sekunder mencapai 95,5%, sedangkan pada data primer mencapai 97%. Kata Kunci—Sidik Jari, CNN Model, Xception, VGG-16 and NasNetLarge I. INTRODUCTION Proses modernisasi suatu negara, termasuk Indonesia, membawa perubahan dalam adat, budaya, dan pola pikir masyarakat. Perubahan ini memiliki dampak positif dan negatif, seperti kesenjangan ekonomi, kriminalitas, dan kenakalan remaja. Purba, Nelvitia, dkk. (2017) menjelaskan bahwa kejahatan dipengaruhi oleh dua faktor: internal, seperti usia, kondisi mental dan pendidikan; serta eksternal, yaitu waktu, tempat, dan kondisi keluarga. Bentuk kejahatan yang berdampak besar salah satunya adalah pembunuhan, menyebabkan kerugian psikologis dan materiil. Pada Mei 2024, terdapat delapan kasus pembunuhan di Cirebon, Batang, Sukabumi, Sulawesi Utara, Kepulauan Riau, Bekasi, Ciamis, dan Boyolali dengan motif seksual, kekerasan, dan ekonomi. Polisi sedang melakukan penyelidikan untuk mengidentifikasi para pelaku (Sidik, dkk., 2024). Hadaris, Arisy Nabawi (2020) menjelaskan bahwa dalam ilmu kriminalistik, identifikasi berarti membandingkan kesamaan antara manusia, hewan, atau benda. Proses ini mencakup pemeriksaan tindakan penjahat, pemotretan, pengumpulan barang bukti seperti sidik jari, dan penahanan tersangka. Namun, identifikasi sering terhambat karena sulitnya mengumpulkan bukti, terutama pada kasus pembunuhan di mana jasad rusak atau pelaku menghilangkan jejak. Sidik jari, sebagai identitas biometrik yang unik, sering digunakan untuk identifikasi dengan alat INAFIS Portable System (IPS) yang terhubung ke database nasional. Namun, identifikasi sidik jari dapat menghadapi hambatan, seperti kualitas sidik jari latent yang buruk akibat permukaan yang kasar, distorsi, atau faktor cuaca. Pengolahan citra digital membantu meningkatkan kualitas dan akurasi identifikasi sidik jari. Kecerdasan buatan, terutama metode deep learning seperti CNN, sangat berperan dalam proses ini. CNN dapat menganalisis citra secara mandiri dengan menggunakan fitur ekstraksi yang kompleks. Penelitian menunjukkan arsitektur CNN seperti ResNet-50, VGG-16, dan Xception mencapai tingkat akurasi yang tinggi dalam klasifikasi sidik jari, dengan Xception mencapai akurasi hingga 98,5%. Penelitian ini akan mengklasifikasikan pola sidik jari menjadi lima kelas whorl, arch, loop radial, loop ulnar dan twinted loop. dengan menggunakan arsitektur CNN Xception, VGG-16, dan NasNetLarge. II. LITEATUR REVIEW A. Daktiloskopi Sidik Jari Hadaris, Arisy Nabawai (2020) menjelaskan bahwa daktiloskopi berasal dari dua kata Yunani: daktulos yang berarti garis jari, dan scopeo yang berarti mengamati jari. Jadi, daktiloskopi adalah ilmu pengenalan identitas seseorang melalui pola unik

sidik jari pada tangan **dan** kaki. **Sidik jari**

5

yang digunakan dalam identifikasi biasanya berupa sidik jari latent,

yaitu sidik jari yang tertinggal di permukaan **benda yang**

5

disentuh. Tiga prinsip utama dalam pemilihan sidik jari adalah: 1. Setiap sidik jari unik dan berbeda untuk setiap individu. 2. Pola sidik jari terbentuk sejak janin berusia 120 hari dan tidak berubah seumur hidup. 3. Pola sidik jari dapat dirumuskan berdasarkan parameter seperti core, delta, ridge counting, dan ridge tracing. Sidik jari manusia, hewan, dan makhluk hidup lainnya bersifat unik, terbentuk oleh gen pada kromosom sejak usia 4 bulan dalam kandungan, dan ukurannya berubah seiring bertambahnya usia. Untuk mengambil sidik jari latent, biasanya digunakan minyak, asam amino, cat, atau bahan nano, yang kemudian ditempelkan ke permukaan kertas atau plastik (Syarif Hartawan, et al., 2020). Saat ini, terdapat empat pola jenis sidik jari di masyarakat, yaitu loop ulnar, whorl, arch, loop radial dan tented arch. Pola arch ditandai dengan garis tengah yang sedikit meninggi, membentuk tonjolan keluar dengan sudut 45 derajat. Pola whorl memiliki garis melingkar di titik tengah yang mencapai 360 derajat. Sedangkan pola loop membentuk garis lengkung yang dimulai dan berakhir di sisi yang sama, lebih dari satu garis. Titik tengah yang mempertemukan garis-garis dari arah berbeda disebut triradius (Syarif Hartawan, et al., 2022).

B. Arsitektur Convolutional Neural Network CNN memiliki beberapa arsitektur yang dapat digunakan dalam memproses data masukan, berikut beberapa arsitektur : 1. Extream Inception (Xception) Yucel Cimtay (2021) dalam penelitiannya menggunakan arsitektur yang efisien dalam komputasi, cocok untuk pengenalan citra, dan memiliki kinerja yang baik. Arsitektur ini menggunakan 36 lapisan konvolusi dengan depthwise separable convolutions, yaitu proses konvolusi dalam dua langkah: depthwise dan pointwise (1x1). Total lapisannya mencapai 71. Proses ini lebih cepat dan berbeda dari konvolusi konvensional karena tidak perlu memproses semua saluran sekaligus, membuat model lebih ringan dan efisien. Fig. 2. Arsitektur Xception

2. Visual Geometry Group – 16 Andreea Monica Dinca (2022) menjelaskan bahwa arsitektur ini mampu mencapai akurasi tinggi dalam klasifikasi gambar dan sangat sederhana. Fig. 1. Citra Sidik Jari Menurut Triwani (2018), pada minggu ke-6 pola sidik jari mengalami perkembangan dan ke-7 perkembangan janin. Pada minggu ke-9 hingga ke-14, pola seperti whorl, arch, dan loop sudah terbentuk. Sidik jari latent sangat membantu polisi dalam mengungkap kasus karena sifatnya yang unik, bahkan pada kembar identik. Sidik jari manusia memiliki berbagai jenis dan tipe, tergantung pada letak bagian tengah atau pusat sidik jari. Fig. 3. Arsitektur VGG-16 Beberapa fitur utamanya adalah: a. Memiliki 16 lapisan konvolusi. b. Menggunakan kernel 3x3 sehingga parameternya sedikit. c. Setiap lapisan memakai max pooling 2x2 dengan stride 2, memudahkan klasifikasi dan efisiensi waktu. d. Menggunakan ReLU untuk input dan softmax untuk output.

3. NasNetLarge Yucel Cimtay (2021) juga menggunakan arsitektur ini dalam penelitiannya. Neural Architecture Search Network – Large dikembangkan oleh Google Brain dengan teknik algoritma yang secara otomatis mencari arsitektur jaringan optimal untuk mencapai kinerja yang baik. Fig. 4. Arsitektur NasNetLarge Arsitektur didalamnya memiliki layer yang terdiri dari blok- blok yang dirancang khusus. Arsitektur jenis ini cenderung lebih kompleks dan lebih canggih sama halnya dengan arsitektur Xception.

III. METHOD RESEARCH Penelitian ini mengusulkan metode untuk mengklasifikasi citra pola sidik jari menggunakan deep learning dengan arsitektur Xception, VGG-16, dan NasNetLarge. Tujuannya adalah untuk menentukan arsitektur yang paling cocok untuk klasifikasi citra pola sidik jari. Dalam proses pelatihan, citra sidik jari akan melalui beberapa tahap, termasuk pengaturan ukuran kernel, filter, dan lapisan untuk mendapatkan model CNN yang optimal. Fig. 5. Usulan Arsitektur 1. Arsitektur Xception Dalam proses menggunakan arsitektur Xception, citra sidik jari akan melalui proses input shape, output shape, convolution, max pooling, dropout, flatten dan dense. Fig. 6. Parameter Arsitektur Xception

2. Arsitektur VGG-16 Model CNN ini memiliki 16 lapisan dengan kinerja sederhana tetapi cukup efektif. Model ini sedikit berbeda dengan Xception yang memiliki jumlah saluran bertambah seiring bertambahnya kedalaman jaringan. Setiap lapisan arsitektur ini menggandakan jumlah filter yang awalnya dari 64 hingga 512. Fig. 7. Parameter Arsitektur VGG-16

3. Arsitektur NasNetLarge Arsitektur ini sangat efisien dan fleksibel dalam menyesuaikan kebutuhan klasifikasi gambar dengan jumlah kelas yang berbeda. Fig. 8. Parameter Arsitektur NasNetLarge

IV. RESULT AND ANALYSIS Klasifikasi dan perbaikan kualitas citra sidik jari menggunakan deep learning CNN dengan 3 arsitektur. Data sidik jari dibagi menjadi dua yaitu data sekunder dan primer. Hal ini bertujuan untuk menentukan model arsitektur CNN yang paling sesuai dalam penerapan klasifikasi sidik jari serta membandingkan Tingkat akurasi melalui confusion matrix masing-masing dataset.

1. Performansi Metrik CNN Model Hasil performa model CNN dibawah ini adalah data sekunder dan primer, untuk mengukur seberapa baik model memprediksi. Tabel diatas menunjukkan akurasi arsitektur CNN pada data FVC. Model yang diusulkan menunjukkan hasil yang kompetitif dibandingkan penelitian sebelumnya. Dengan learning rate 0,001, arsitektur VGG-16 memberikan hasil optimal dengan akurasi 97,5%, sebanding dengan penelitian Ramesh Chandra Sahoo. Meski Xception dan NasNetLarge sedikit di bawah VGG-16,

keduanya tetap mencapai akurasi tinggi dan layak untuk klasifikasi pada dataset yang sama. Pada learning rate 0,0001, VGG-16 mencapai akurasi sempurna 100%, sementara Xception dan NasNetLarge memperoleh akurasi 97%. Ini menunjukkan bahwa model CNN yang diusulkan memiliki kinerja sangat baik dan cocok untuk klasifikasi sidik jari pada data sekunder. a) Performansi metrik data sekunder TABLE I. PERFORMANSI METRIK DATA SEKUNDER Arsitektur Data Sekunder

Learning Rate 0.001		Learning Rate 0.0001														4
----------------------------	--	-----------------------------	--	--	--	--	--	--	--	--	--	--	--	--	--	---

	Accuracy	Precision	Recall	F1-Score	Accuracy	Precision	Recall	F1-Score	Xception	0	.97	0	.97	0	.93	0	.95	0	.97	0	.97	0	.93	0	.95
VGG	0	.97	0	.95	0	.95	0	.95	0	.97	0	.97	0	.93	0	.95	0	.97	0	.97	0	.93	0	.95	

.94 1.00 1.00 1.00 1.00 NasnetLarge 0.95 0.94 0.97 0.95 0.97 0.99 0.98 0.98 Tabel 1 menunjukkan hasil penelitian performa arsitektur CNN berdasarkan tingkat akurasi. Pada data sekunder dengan learning rate 0,001, arsitektur VGG-16 mencapai akurasi tertinggi sebesar 97,5%, diikuti oleh Xception dengan 97%, dan NasNetLarge dengan 95%. Dengan learning rate 0,0001, VGG-16 mencapai akurasi sempurna 100%, sedangkan Xception dan NasNetLarge mencapai akurasi yang sama, yaitu 97%. b) Performansi metrik data primer TABLE II. PERFORMANSI METRIK DATA PRIMER Arsitektur

Learning Rate 0.001		Learning Rate 0.0001														4
----------------------------	--	-----------------------------	--	--	--	--	--	--	--	--	--	--	--	--	--	---

	Accuracy	Precision	Recall	F1-Score	Accuracy	Precision	Recall	F1-Score	Xception	0	.93	0	.93	0	.93	0	.93	0	.91	0	.91	0	.91	0	.91
VGG	0	.98	0	.98	0	.98	0	.98	0	.98	0	.91	0	.91	0	.91	0	.91	0	.91	0	.91	0	.91	
NasnetLarge	0	.97	0	.98	0	.96	0	.97	0	.97	0	.97	0	.97	0	.97	0	.97	0	.97	0	.97	0	.97	

.97 Tabel di atas menunjukkan bahwa learning rate 0,001 menghasilkan akurasi yang lebih baik dibandingkan 0,0001. Pada learning rate 0,001, setiap arsitektur CNN mencapai akurasi stabil sekitar 98%. Sebaliknya, pada learning rate 0,0001, arsitektur NasNetLarge hanya mencapai akurasi 97%. 2. Hasil Akurasi dan Loss Pada Learning Rate Berbeda dengan 50 Epoch Kinerja model CNN selama pelatihan dan validasi dapat dipantau melalui grafik accuracy dan loss berdasarkan learning rate. Grafik loss menunjukkan seberapa baik atau buruk model dalam melakukan klasifikasi selama pelatihan, sementara grafik accuracy mengukur ketepatan klasifikasi model dibandingkan dengan nilai yang benar. a) Grafik Akurasi dan Loss Data Sekunder Learning Rate 0.0001 Xception VGG NasnetLarge Grafik ini menunjukkan hasil pelatihan tiga model deep learning: Xception, VGG, dan NasnetLarge. Xception dan NasnetLarge menunjukkan kinerja yang sangat baik dengan loss yang cepat turun dan akurasi cepat mencapai 100%, sehingga lebih efektif dibandingkan VGG. Sementara itu, VGG menunjukkan

peningkatan akurasi dan penurunan loss yang lebih lambat, serta fluktuasi pada akurasi validasi, yang bisa mengindikasikan overfitting pada data pelatihan. b) Grafik Akurasi dan Loss Data Sekunder Learning Rate 0.001 Ketiga model CNN, yaitu Xception, VGG-16, dan NasNetLarge, menunjukkan kinerja baik dengan learning rate rendah sebesar 0,0001. Dengan pengaturan ini, model mencapai akurasi tinggi pada data training dan validation, dengan overfitting yang minim. Grafik loss turun bertahap, dan akurasi stabil pada tingkat tinggi setelah sekitar 20 epoch. NasNetLarge khususnya menunjukkan konvergensi lebih cepat, sehingga cocok untuk tugas klasifikasi yang membutuhkan akurasi tinggi dan generalisasi yang baik. Xception VGG NasnetLarge c) Grafik Akurasi dan Loss Data Primer Learning Rate 0.0001 Grafik akurasi dan loss penting untuk mengevaluasi, memantau, dan mengoptimalkan performa model CNN selama pelatihan. Xception VGG NasnetLarge Tiga model CNN—Xception, VGG-16, dan NasNetLarge—dilatih dengan learning rate 0,0001. Xception menunjukkan penurunan loss yang cepat dan stabil pada akhir pelatihan, menandakan minimnya overfitting. VGG-16 juga stabil dengan penurunan loss yang lebih lambat dibandingkan Xception. Sementara itu, NasNetLarge menunjukkan fluktuasi pada beberapa bagian validation loss, yang menunjukkan sedikit masalah dalam generalisasi, tetapi akhirnya stabil seperti model lain. Xception unggul dalam pengurangan loss cepat di awal, VGG-16 lebih stabil tapi lambat, dan NasNetLarge sedikit fluktuatif tetapi mencapai hasil akurasi dan loss yang baik pada akhirnya. Setiap model memiliki keunikan dalam kecepatan dan stabilitas pembelajarannya. d) Grafik Akurasi dan Loss Data Primer Learning Rate 0.001 Percobaan pertama dilakukan menggunakan learning rate 0.001, hasil ketiga model menunjukkan tren yang mirip. Xception VGG NasnetLarge Tabel menunjukkan bahwa ketiga model CNN—Xception, VGG-16, dan NasNetLarge—memiliki hasil yang seimbang dan mirip satu sama lain. Pada grafik pertama, Xception dan VGG-16 menunjukkan training dan validation loss yang konsisten menurun hingga stabil setelah beberapa epoch. NasNetLarge mengalami penurunan loss yang lebih cepat dari awal dan akhirnya stabil. Grafik kedua memperlihatkan akurasi yang stabil setelah sekitar 20 epoch, dengan ketiga model mendekati akurasi 90% di akhir pelatihan. 3. Hasil Confusion Matrix Pengujian Terbaik Dibawah ini merupakan tabel yang digunakan untuk mengevaluasi kinerja model klasifikasi. Tabel ini menunjukkan perbandingan antara prediksi model dan label sebenarnya dari dataset yang digunakan. Penelitian ini menggunakan dua dataset yaitu data sekunder dan data primer. Dari 3 arsitektur CNN, didapatkan hasil akurasi pengujian terbaik untuk masing- masing learning rate. A) Confusion Matrix data sekunder learning rate 0.0001 Percobaan berikutnya menggunakan data sekunder dengan arsitektur VGG-16, menghasilkan akurasi sempurna tanpa kesalahan dalam mengklasifikasikan pola citra sidik jari dalam masing-masing kelas. Fig. 9. Confusion Matrix Arsitektur VGG-16 0.0001 Confusion matrix ini menunjukkan bahwa model CNN dengan arsitektur VGG-16 sangat efektif dan akurat dalam mengklasifikasikan pola sidik jari, tanpa kesalahan sama sekali. Hal ini membuktikan bahwa model ini cocok untuk aplikasi klasifikasi sidik jari pada data ini. B) Confusion Matrix data sekunder learning rate 0.001 Sementara itu, pada arsitektur VGG-16 dengan data masukan FVC yang sama, diperoleh confusion matrix sebagai berikut: Fig. 10. Confusion Matrix Arsitektur VGG-16 0.001 Gambar tersebut memiliki akurasi model baik, terlihat dari banyaknya prediksi yang benar. Namun, ada juga beberapa kesalahan prediksi pada kelas leftloop tetapi jumlahnya relatif kecil dibandingkan jumlah prediksi yang benar. C) Confusion Matrix data primer learning rate 0.0001 Fig. 11. Confusion Matrix data Primer Arsitektur NasNetLarge Arsitektur NasNetLarge berhasil memprediksi pola leftloop dan twintedloop dengan akurasi 100% tanpa kesalahan. Pada pola arch, terdapat 1 prediksi yang salah menjadi leftloop, dengan 21 sampel berhasil diprediksi benar. Untuk pola plainwhorl, terdapat 1 kesalahan menjadi rightloop, dengan 15 sampel diprediksi benar. Pola rightloop memiliki 23 prediksi benar dan 1 kesalahan menjadi plainwhorl. D) Confusion Matrix data primer learning rate 0.001 Fig. 12. Confusion Matrix data Primer Arsitektur VGG-16 Arsitektur ini menghasilkan sangat sedikit kesalahan dalam setiap pola citra sidik jari. Hanya ada satu kesalahan pembacaan pada pola left loop dan right loop, sementara pola lainnya berhasil diklasifikasikan dengan tepat. Dengan demikian, persentase keberhasilan mencapai 100%, menunjukkan tingkat akurasi yang sangat tinggi dalam klasifikasi ini. II. CONCLUSION Berdasarkan confusion matrix klasifikasi pola sidik jari dan evaluasi kinerja arsitektur Xception, VGG-16, dan NasNetLarge

,001, dapat disimpulkan: 1. Ketiga arsitektur CNN mampu mencapai akurasi tinggi dalam klasifikasi pola sidik jari. Akurasi tertinggi

dengan learning rate 0,001 diperoleh

2

oleh VGG-16 sebesar 98%,

sedangkan dengan learning rate 0,0001, NasNetLarge mencapai akurasi

2

97%. 2. Variasi learning rate memengaruhi kinerja model.

Dengan learning rate 0,001, VGG-16 mencapai akurasi

2

train 99,19%, validasi 99%, dan testing 98% setelah 50 epoch. Sementara NasNetLarge dengan

learning rate 0,0001 menghasilkan akurasi

2

train 95,5%, validasi 98,75%, dan testing 97%. 3. Akurasi pada data sekunder dan primer menunjukkan perbedaan signifikan. VGG-16 mencapai akurasi hingga 100% dengan learning rate 0,0001, menunjukkan bahwa model ini efektif dalam mengenali pola sidik jari dan mampu bersaing dengan hasil penelitian sebelumnya. REFERENCES Albahli, Saleh, 2020, Detection of Coronavirus Disease From X-Ray Images Using Deep Learning and Transfer Learning Algorithms, Journal of X-Ray Science and Technology, Saudi arabia. Andreansyah, Agus, Rika F, M. Jumnahdi., 2019, Pengenalan Pola Sidik Jari Menggunakan Multi-Class Support Vector Machine, Jurnal Elkha, pp. 79-84. Andreea Monica Dinca, Lazarescu. dkk., 2022, A Fingerprint Matching Algorithm Using the Combination of Edge Features and Convolution Neural Network, MDPI Inventions, Romania, Pp. 39. Arnita, Faridawaty, dkk, 2022, Computer Vision dan Pengolahan Citra Digital, ISBN 978-623-8230-27-3, Pustaka Aksara. B. Bakhshi dan H, Veisi, 2017, End to End Fingerprint Verification Based on Convolutional Neural Network, in 27th Iranian Conference on Electrical Engineering (ICEE2019), Tehran, pp. 1994 -1998. Cholussodin, Imam et al, 2020, Buku Ajar AI, Machine Learning & Deep Learning, Filkom, Universitas Brawijaya. Cimtay, Yucel et al, 2021, Fingerprint Pattern Classification by Using Various Pre-Trained Deep Learning Networks, European Journal of Science and Technology (EJOSAT), Special Issue 24, pp. 258-261. Emil Naf'an, et al, 2022, Dasar-dasar Deep Learning dan Contoh Aplikasinya, Penerbit: CV. Mitra Cendekia Media, Sumatra Barat. Garg, Reena et al, 2024, Fingerprint Recognition Using Convolution Neural Network with intevesion and augmented techniques, Journal Elsevier, India. Hadaris, Arisy Nabawi, 2020, Modul Daktiloskopi antara Tantangan, Peluang dan Harapan, Badan Pengembangan Sumber Daya Manusia Hukum dan Hak Asasi Mnausia Kementerian Hukum dan Hak Asasi Manusia Republik Indonesia, ISBN

978-623-6869-37-6, Percetakan Pohon Cahaya. Hidayatullah, priyanto., 2023, Buku Sakti Deep Learning, Penerbit Stunning Vision AI Academy. Hirsi Mohamed, 2021, Fingerprint Classification Using Deep Convolutional Neural Network, ISSN: 2329-1613, Journal of Electrical and Electronic Engineering, Turkey. Indonesia, Undang-Undang tentang Kitab Undang-Undang Hukum Acara Pidana, UU No. 8 Tahun 1981, LN No. 76 Tahun 1981, Psl. 184. Irsyad, Rahadian, 2018, Penggunaan Python Web Framework Flask untuk Pemula, Laboratorium Telematika, Institut Teknologi Bandung, Liyananta, Mohammad et al, 2024, Klasifikasi Tumor Otak Menggunakan CNN dengan Arsitektur Resnet 50, Prosiding Seminar Nasional Teknologi dan Sains, Universitas Nusantara PGRI Kediri. M. Galar et al, 2015, A Survey of Fingerprint Classification Part II: Experimental Analysis and ensemble proposal, Knowledge Based Systems, Vol. 81, pp. 98-116. Purba, Nelvitia., Amran Basri, dkk., 2017, Kejahatan dan Penjahat dari Aspek Kriminologi, Mahara Publishing, ISBN 978-602-6914-78-1, Tangerang, Banten. Putra, Jan Wira Gotama, 2020, Pengenalan Konsep Pembelajaran Mesindan Deep Learning, wiragotama.github, Tokyo, Jepang. Raharjo, Budi, 2022, Deep Learning dengan python, Penerbit: Yayasan Prima, ISBN: 978-623-5734-33-0, Semarang. Ramesh Chandra Sahoo, dkk. 2019. Application of Deptwise Separable Convolutional Neural Network for Distorted Fingerprint Images, International Journal of control and automation. Vol. 12, No.6, pp. 448-455. Sidik, Farih Maulana, 2024, 8 Kasus Pembunuhan Bikin Geger dalam Dua Pekan Terakhir, detiknews, diakses pada tanggal 8 Juni 2024 pada laman <https://news.detik.com/berita/d-7334539/8-kasus-pembunuhan-bikin-geger-dalam-2-pekan-terakhir/1> Santoso, Joseph Teguh, 2022, Proyek Coding dengan Python, Penerbit: Yayasan Prima, ISBN: 978-623-5734-31-6, Semarang. Satriawan, Akbar Muhammad dan Wijang, 2023, Klasifikasi Pengenalan Wajah untuk Mengetahui Jenis Kelamin Menggunakan Metode Convolutional Neural Network, Jurnal Algoritma, Vol. 4, No. 1, pp. 43-52. Shrestha and B.K Malla, 2019, Study of Fingerprint Pattern in Population of a Community, J Nepal Med Assoc, Vol. 57 No. 219. Supardi, Julian and Shi-Jinn Horng, 2019, Very Small Image Face Recognition Using Deep Convolutional Neural Network, Journal of Physisc: Conference Series 1196 (ICONISCSE). Syarif Hartawan, Muhammad., Suhardjono, dkk., 2022, Digital Forensik, ARS Training, Triwani, Pemeriksaan Dermatoglifi sebagai Alat Identifikasi dan Diagnostik, Fakultas Kedokteran, Universitas Sriwijaya, Palembang. 1 2 3 4 5 6 7

sources:

- 1 56 words / 2% - Internet from 24-May-2023 12:00AM
www.arxiv-vanity.com
- 2 31 words / 1% - Crossref
[Didi Kurniawan, Dhani Ariatmanto. "IDENTIFIKASI VARIETAS BIBIT DURIAN MENGGUNAKAN MOBILENETV2 BERDASARKAN GAMBAR DAUN", Jurnal Informatika dan Rekayasa Elektronik, 2024](#)
- 3 29 words / 1% - Crossref
[Agus Andreansyah, Julian Supardi. "Optimization of VGG-16 Accuracy for Fingerprint Pattern Imager Classification", Jurnal Sisfokom \(Sistem Informasi dan Komputer\), 2025](#)
- 4 16 words / 1% - Internet from 14-Sep-2023 12:00AM
export.arxiv.org
- 5 12 words / < 1% match - ProQuest
[Mulyadi, Mulyadi. "Kedudukan Hukum Sidik jari Dalam Mengungkap Tindak Pidana Pembunuhan di Polres Blora \(Studi Laporan Kepolisian No. Lp/B/05/li/2022/Spkt Polsek Cepu/Polres Blora/Polda Jateng\)", Universitas Islam Sultan Agung \(Indonesia\), 2023](#)

