

Deteksi Kecurangan Akademik Berdasarkan Dokumen Tulisan Tangan Menggunakan Siamse ResNet Approach

^aAzhar Andika Putra, ^bBakhtiar K, ^cFirga Abel Astiawan, ^dMuhammad Al Hapiz

Fakultas Ilmu Komputer, Universitas Sjakhyakirti, Palembang, Indonesia

^aazharandikaputra@unisti.ac.id, ^bbakhtiarkaseem@gmail.com, ^c21620007@student.unisti.ac.id,

^d21610014@student.unisti.ac.id

Article Info

Article history:

Received, 2025-11-30

Revised, 2025-11-09

Accepted, 2025-11-11

Kata Kunci:

kecurangan akademik,
tulisan tangan,
siamese network,
cosine similarity,
verifikasi penulis

Keywords:

academic cheating,
handwriting,
siamese network,
cosine similarity,
author verification

ABSTRAK

Kecurangan akademik, terutama yang melibatkan pemalsuan dokumen tulisan tangan, menjadi tantangan dalam dunia pendidikan. Salah satu modus yang sulit dideteksi adalah penyalahgunaan identitas, di mana seseorang menulis atau mengerjakan tugas atas nama orang lain. Penelitian ini bertujuan untuk mengembangkan model deteksi kecurangan akademik berbasis tulisan tangan menggunakan pendekatan Siamese Network dan cosine similarity. Eksperimen dilakukan menggunakan perangkat HP Z8 G5 yang dilengkapi dengan dua GPU NVIDIA RTX 6000, dan dataset yang digunakan berasal dari Universitas Sjakhyakirti. Dataset ini terdiri dari 101.475 pasangan citra tulisan tangan, yang masing-masing diberi label 1 (mirip) untuk pasangan dari penulis yang sama dan 0 (tidak mirip) untuk pasangan dari penulis yang berbeda. Data tersebut dibagi menjadi 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Dataset penelitian ini berasal dokumen tulisan tangan dari 450 mahasiswa yang berbeda yang terdiri dari 450 pasangan positif (label = 1) dan 101.025 pasangan negatif (label = 0). Model dievaluasi menggunakan *threshold cosine similarity* sebesar 0.5, dengan hasil akurasi pelatihan mencapai 95.34%, validasi 84.12%, dan pengujian 83.87%. Penelitian ini memberikan kontribusi dalam pengembangan sistem deteksi kecurangan akademik berbasis tulisan tangan yang dapat diimplementasikan di institusi pendidikan tinggi.

ABSTRACT

Academic cheating, particularly involving the forgery of handwriting documents, has become a significant challenge in the field of education. One of the most difficult modes to detect is identity misuse, where an individual writes or completes tasks on behalf of someone else. This study aimed to develop an academic cheating detection model based on handwriting using the Siamese Network approach and cosine similarity. The experiment was conducted using an HP Z8 G5 device equipped with two NVIDIA RTX 6000 GPUs, and the dataset used came from Universitas Sjakhyakirti. The dataset consisted of 101,475 pairs of handwriting images, each labeled as 1 (similar) for pairs from the same writer and 0 (dissimilar) for pairs from different writers. The data was divided into 70% for training, 15% for validation, and 15% for testing. This research dataset was sourced from handwriting documents of 450 different students, consisting of 450 positive pairs (label = 1) and 101,025 negative pairs (label = 0). The model was evaluated using a cosine similarity threshold of 0.5, with training accuracy reaching 95.34%, validation accuracy at 84.12%, and testing accuracy at 83.87%. This study contributes to the development of a handwriting-based academic cheating detection system that can be implemented in higher education institutions.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Azhar Andika Putra,
Fakultas Ilmu Komputer
Universitas Sjakhyakirti, Palembang, Indonesia
Email: azharandikaputra@unisti.ac.id

1. PENDAHULUAN

Kecurangan akademik menjadi salah satu tantangan serius dalam dunia pendidikan, baik di tingkat sekolah menengah maupun perguruan tinggi [1], [2], [3]. Bentuk kecurangan ini beragam, mulai dari plagiarisme hingga pemalsuan dokumen seperti ujian dan tugas tertulis. Salah satu modus yang cukup sulit dideteksi secara manual adalah penyalahgunaan identitas, di mana seseorang menulis atau mengerjakan tugas atas nama orang lain [4], [5], [6]. Untuk deteksi kecurangan pada dokumen tulisan tangan, hal ini menjadi lebih kompleks karena verifikasi identitas penulis memerlukan ketelitian dan sering kali bersifat subjektif [7], [8], [9].

Penelitian sebelumnya telah mengkaji pendekatan dalam mendeteksi kemiripan tulisan tangan menggunakan berbagai teknik ekstraksi fitur dan metode pengukuran kemiripan. Penelitian oleh Bhatt, Nasriwala, dan Savant (2022) menggunakan *Convolutional Neural Network* (CNN) untuk mengekstraksi fitur tulisan tangan dalam bahasa India dan menghitung kemiripan antar tulisan menggunakan *cosine similarity* [10]. Pendekatan serupa juga diterapkan oleh Cui (2025), yang menggunakan CNN dan *cosine similarity* dalam konteks tulisan tangan berbahasa Korea [11]. Sementara itu, Kumar et al. (2023) mengadopsi CNN dengan pendekatan *Euclidean distance* untuk mendeteksi kemiripan tulisan tangan dalam bahasa India [12].

Berbeda dari pendekatan CNN, Tahir et al. (2021) memanfaatkan *Multi-Layer Perceptron* (MLP) dan *Euclidean distance* dalam analisis tulisan tangan berbahasa China [13]. Miao et al. (2024) mengembangkan sistem berbasis CNN dan *autoencoder* untuk menghasilkan *latent vector* yang dibandingkan menggunakan *cosine similarity* dalam konteks tulisan tangan berbahasa Inggris [14]. Dalam penelitian yang serupa, Singh dan Chaturvedi (2024) juga mengimplementasikan CNN dan *autoencoder* untuk ekstraksi fitur tulisan tangan berbahasa Inggris dengan pengukuran kemiripan menggunakan *cosine similarity* [15]. Keseluruhan studi ini menunjukkan kecenderungan pemanfaatan CNN sebagai metode utama dalam ekstraksi fitur, serta variasi dalam metode pembandingan yang digunakan untuk mengukur kemiripan tulisan tangan. Ringkasan penelitian terkait menunjukkan berbagai pendekatan yang telah dikembangkan dalam mendeteksi kemiripan tulisan tangan dapat dilihat pada **Tabel 1**.

Tabel 1 Penelitian Terkait

No	Sumber	Ekstraksi Fitur	Latent Vector	Skor Kemiripan	Bahasa
1	[10]	CNN	x	Cosine Similarity	India
2	[11]	CNN	x	Cosine Similarity	Korea
3	[12]	CNN	x	Euclidean Distance	India
4	[13]	MLP	x	Euclidean Distance	China
5	[14]	CNN	Autoencoder	Cosine Similarity	Inggris
6	[15]	CNN	Autoencoder	Cosine Similarity	Inggris
7	Usulan	ResNet	Siamse	Cosine Similarity	Indonesia

Seiring berkembangnya teknologi kecerdasan buatan, pendekatan berbasis *deep learning* mulai digunakan untuk mengenali pola tulisan tangan. Salah satu metode yang menjanjikan adalah penggunaan *Siamese Neural Network*, yang mampu membandingkan dua input gambar dan menentukan tingkat kemiripan di antara kedua citra input yang dibandingkan. Pada penelitian ini akan menggabungkan arsitektur ResNet sebagai backbone pada *Siamese Neural Network* untuk mengekstraksi fitur tulisan tangan.


Usulan penelitian ini focus pada kebaruan dengan menggabungkan arsitektur *Residual Network* (ResNet) sebagai metode ekstraksi fitur dan *Siamese Neural Network* sebagai pendekatan pembandingan kemiripan tulisan tangan, yang hingga kini belum diterapkan pada konteks tulisan tangan berbahasa Indonesia. Berbeda dengan penelitian sebelumnya yang sebagian besar menggunakan *Convolutional Neural Network* (CNN) standar atau *Multi-Layer Perceptron* (MLP), ResNet memiliki keunggulan dalam mengatasi masalah *vanishing gradient* pada jaringan yang sangat dalam, sehingga mampu mengekstraksi fitur yang lebih kompleks dan mendalam dari dokumen tulisan tangan [16], [17]. Sementara itu, arsitektur *Siamese Neural Network* memungkinkan pembelajaran berbasis perbandingan dua input, sehingga lebih cocok untuk tugas verifikasi identitas, karena berfokus pada relasi antar pasangan gambar daripada klasifikasi tunggal [18], [19], [20].

Pendekatan yang dirumuskan dalam penelitian ini menggabungkan arsitektur *Residual Network* (ResNet) untuk ekstraksi fitur mendalam dari citra tulisan tangan dengan *Siamese Neural Network* sebagai strategi pembandingan dua input. Strategi ini dirancang untuk mengatasi permasalahan kecurangan akademik berupa pemalsuan identitas penulis dalam dokumen tulisan tangan, dengan menggunakan metode *cosine similarity* sebagai metrik pengukuran kedekatan antar fitur. Sistem ini akan dilatih menggunakan pasangan citra tulisan tangan yang telah dilabeli (mirip atau tidak mirip), sehingga model dapat belajar mengenali pola dan karakteristik khas dari tulisan tangan individu.

2. METODE PENELITIAN

Penelitian ini merupakan bagian dari pengembangan arsitektur sistem informasi akademik yang dikembangkan yang akan mengintegrasikan data tulisan tangan mahasiswa. Sistem ini dirancang untuk mendukung digitalisasi proses akademik, termasuk pengumpulan dokumen tulisan tangan sehingga memudahkan analisis deteksi kecurangan berbasis AI [21]. Penelitian ini fokus pengumpulan dataset tulisan tangan, proses *preprocessing*, perancangan arsitektur model dan eksperimen.

Model yang digunakan dalam penelitian ini adalah integrasi arsitektur *Residual Network* (ResNet) untuk mengekstraksi fitur visual dari citra tulisan tangan dan arsitektur *Siamese Network* untuk membandingkan pasangan citra tulisan tangan dengan menggunakan *cosine similarity* sebagai metrik perhitungan. Adapun tahapan penelitian dapat digambarkan pada **Gambar 1**.



Gambar 1 Tahapan Penelitian

Eksperimen dilakukan pada lingkungan komputasi menggunakan perangkat HP Z8 G5 yang dilengkapi dengan GPU NVIDIA RTX 6000. Dataset yang digunakan dalam penelitian ini berasal dari institusi pendidikan tinggi, yaitu Universitas Sjakhyakirti. Dokumen tulisan tangan dikumpulkan dari mahasiswa aktif di kedua universitas melalui integrasi dengan sistem informasi akademik masing-masing institusi. Jenis data yang dikumpulkan berupa lembar yang memuat tulisan tangan asli dari 450 mahasiswa. Setiap data dilengkapi dengan metadata seperti nama institusi, ID mahasiswa, mata kuliah, tanggal pengumpulan, dan jenis dokumen. Untuk pelatihan model *Siamese Network*, data tersebut diproses melalui tahap *preprocessing* berupa segmentasi area tulisan. Pelabelan data dalam bentuk pasangan data dengan label pasangan tulisan dari penulis yang sama (diberikan label 1) dan pasangan dari penulis berbeda (diberikan label 0).

Metodologi dimulai dari tahap *document profile*, yaitu pengumpulan sampel tulisan tangan mahasiswa yang menjadi data utama. Selanjutnya, dilakukan tahap *data preprocessing* yang meliputi pemisahan sederhana (*simple split*), deteksi area teks, dan *bootstrapping* untuk augmentasi data, sehingga dokumen siap untuk diproses lebih lanjut. Pada tahap *feature extraction*, citra tulisan tangan dianalisis menggunakan arsitektur *Residual Network* (ResNet) untuk mengekstraksi fitur setiap penulis. Hasil ekstraksi kemudian dikonversi menjadi vektor melalui *Siamese Network*, yang dirancang untuk membandingkan dua input dan menentukan tingkat kemiripan di antara citra input. Proses selanjutnya adalah *similarity scoring*, di mana dua vektor dibandingkan menggunakan metode *cosine similarity* untuk menghasilkan nilai kemiripan.


Nilai yang dihasilkan berada dalam rentang -1 hingga 1, di mana nilai 1 menunjukkan bahwa dua tulisan memiliki kemiripan arah vektor yang tinggi (sangat mirip), nilai 0 menunjukkan tidak ada hubungan arah (tidak mirip), dan nilai -1 menunjukkan arah vektor yang berlawanan (sangat berbeda) [24], [25]. Perhitungan *cosine similarity* antara dua representasi vektor dari tulisan tangan mahasiswa dijelaskan dalam Persamaan (1).

$$\text{Cosine similarity } (A, B) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (1)$$

Berdasarkan persamaan diatas, operasi *dot product* $A \cdot B$ merepresentasikan jumlah dari hasil perkalian antara elemen-elemen yang sesuai pada dua vektor representasi tulisan. Sementara nilai $\|A\|$ dan $\|B\|$ masing-masing menunjukkan besar atau panjang dari vektor A dan B. Elemen A_i dan B_i merupakan komponen ke-i dari masing-masing vektor yang mewakili ciri khas tulisan tangan mahasiswa, dan n menunjukkan jumlah dimensi atau panjang dari vektor tersebut. Tahap akhir adalah *decision making* untuk memberikan rekomendasi apakah dua tulisan berasal dari penulis yang sama (*matching*) atau berbeda (*non-matching*), berdasarkan nilai ambang kemiripan yang telah ditentukan.

3. HASIL DAN ANALISIS

Pada penelitian ini menggunakan *siamese network* yang merupakan arsitektur jaringan saraf yang dirancang untuk menerima dua input, memproses keduanya melalui jaringan yang sama, dan menghasilkan satu output yang merepresentasikan tingkat kemiripan antara kedua input tulisan tangan mahasiswa. Jaringan (*network*) ini digunakan untuk membandingkan dua citra tulisan tangan dan menentukan apakah keduanya berasal dari penulis yang sama. Struktur *siamese network* terdiri atas dua komponen utama, yaitu *feature extractor* yang bertugas mengekstraksi ciri atau fitur dari masing-masing tulisan, serta *layer* perhitungan kemiripan berdasarkan fitur yang dihasilkan. Komponen lengkap dari arsitektur model *template matching* yang diusulkan dapat dilihat pada **Gambar 2**.



Gambar 2 Arsitektur Model Deteksi Tulisan Tangan

Dataset penelitian ini berasal dokumen tulisan tangan dari 450 mahasiswa yang berbeda. Pada pelabelan dataset terdapat 450 pasangan positif (label = 1), yang merupakan jumlah pasangan citra dari mahasiswa yang sama, serta 101.025 pasangan negatif (label = 0), yang merupakan jumlah pasangan citra dari mahasiswa yang berbeda. Dengan total pasangan citra dan label yang mencapai 101.475 untuk membedakan apakah dua citra tulisan tangan berasal dari mahasiswa yang sama atau berbeda. Contoh pelabelan dataset tulisan tangan mahasiswa dapat dilihat pada **Tabel 2**.

Tabel 2 Penelitian Terkait

Input 1	Input 2	Label
Universitas Sjakhyakirti mhs001_citra001.jpg	University of Sjakhyakirti mhs001_citra002.jpg	1
Universitas Sjakhyakirti mhs002_citra001.jpg	University of Sjakhyakirti mhs002_citra002.jpg	1
Universitas Sjakhyakirti mhs003_citra001.jpg	University of Sjakhyakirti mhs003_citra002.jpg	1

Dalam penelitian ini, pembagian dataset dalam bentuk dataset pelatihan (70%), dataset validasi (15%), dan dataset pengujian (15%). Total jumlah pasangan citra dan label adalah 101.475 yang terdiri dari 450 pasangan label positif dan 101.025 pasangan label negatif. Jika dihitung berdasarkan presentase 70% dari dataset maka dataset pelatihan sebanyak 71.032, presentase 15% atau sebanyak 15.221 pasangan citra digunakan untuk dataset validasi, dan presentase 15% atau sebanyak 15.221 pasangan citra digunakan untuk dataset pengujian. Eksperimen dilakukan dengan mengimplementasikan model Siamese ResNet dan dihitung dengan menggunakan metode cosine similarity dengan contoh hasil seperti pada **Tabel 3**.

Tabel 3 Hasil Perhitungan *Cosine Similarity*

Input Citra 1	Input Citra 2	Cosine Similarity
mhs001_citra001.jpg	mhs001_citra002.jpg	0.98
mhs001_citra001.jpg	mhs002_citra001.jpg	0.45
mhs002_citra001.jpg	mhs003_citra001.jpg	0.60
mhs002_citra001.jpg	mhs002_citra002.jpg	0.97
mhs001_citra001.jpg	mhs003_citra001.jpg	0.40

Dalam eksperimen, label aktual dan prediksi digunakan untuk menilai hasil deteksi kecurangan berdasarkan pasangan citra tulisan tangan mahasiswa. Label aktual untuk setiap pasangan citra adalah 1 (mirip) atau 0 (tidak mirip), yang menunjukkan sejauh mana dua citra tersebut berasal dari mahasiswa yang sama atau berbeda. Prediksi model menggunakan nilai *cosine similarity* dengan nilai ambang batas (*threshold*) lebih besar atau sama dengan 0.5 untuk hasil prediksi label 1 (mirip), yang berarti kedua citra tersebut berasal dari tulisan mahasiswa yang sama. Jika nilai *cosine similarity* kurang dari 0.5, maka model akan memprediksi label 0 (tidak mirip), yang menunjukkan bahwa citra tersebut berasal dari tulisan mahasiswa yang berbeda. Contoh hasil eksperimen pada dataset pengujian dapat dilihat pada **Tabel 4**.

Tabel 4 Perhitungan Prediksi *Threshold 0.5*

Input 1	Input 2	Cosine Similarity	Prediksi Model	Label Aktual	Kesimpulan
mhs001_citra001.jpg	mhs001_citra002.jpg	0.98	1	1	True
mhs001_citra001.jpg	mhs002_citra001.jpg	0.45	0	0	True
mhs002_citra001.jpg	mhs002_citra002.jpg	0.97	1	1	True
...	...	...	...	...	...
mhs001_citra001.jpg	mhs003_citra001.jpg	0.40	0	0	True

Berdasarkan evaluasi dengan menggunakan threshold 0.5, model menunjukkan akurasi yang sangat baik pada setiap tahap evaluasi. Akurasi pelatihan mencapai 95.34%, yang menunjukkan bahwa model mampu memprediksi pasangan citra dengan sangat tepat selama proses pelatihan. Untuk validasi, akurasi mencapai 84.12%, yang menunjukkan bahwa model juga berhasil dengan baik dalam menggeneralisasi dataset. Akurasi pengujian sedikit lebih rendah, yaitu 83.87%, namun masih menunjukkan performa yang sangat baik dalam mengklasifikasikan pasangan citra tulisan tangan mahasiswa.

4. KESIMPULAN

Berdasarkan hasil eksperimen dengan menggunakan menggunakan pendekatan Siamese ResNet dan perhitungan *cosine similarity* dengan threshold 0.5, hasil menunjukkan akurasi yang sangat pada setiap tahap evaluasi pelatihan, validasi dan pengujian. Pembagian dataset yang proporsional menjadi pelatihan (70%), validasi (15%), dan pengujian (15%) memberikan dasar yang kuat untuk evaluasi model. Model ini menggunakan label aktual dan prediksi berbasis *cosine similarity* untuk menentukan apakah pasangan citra berasal dari mahasiswa yang sama atau berbeda. Akurasi pelatihan yang mencapai 95.34% menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam memprediksi pasangan citra yang mirip atau tidak mirip. Meskipun akurasi validasi dan pengujian sedikit lebih rendah, yaitu 84.12% dan 83.87%, hasil akurasi masih menunjukkan kinerja yang baik dalam menggeneralisasi dataset.

UCAPAN TERIMA KASIH

Ucapan terima kasih diberikan kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia dan Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Sjakhyakirti atas dukungan melalui hibah penelitian tahun 2025 dengan nomor kontrak turunan 175/LL2/DT.05.00/PL/2025 dan 01/VII/PG.2/VI/2025.

REFERENSI

- [1] S. Z. Ong, T. Connie, and M. K. O. Goh, "Cheating Detection for Online Examination Using Clustering Based Approach," *JOIV Int. J. Informatics Vis.*, vol. 7, no. 3–2, pp. 2075–2085, 2023.
- [2] Y. Zhen and X. Zhu, "An ensemble learning approach based on TabNet and machine learning models for cheating detection in educational tests," *Educ. Psychol. Meas.*, vol. 84, no. 4, pp. 780–809, 2024.
- [3] T. T. B. Vo, L. P. Hoang, N. T. H. Nguyen, and B. Q. Dinh, "Mitigating academic cheating through innovations in interdisciplinary and transdisciplinary teaching and peer assessment in digital educational environments," *J. Res. Innov. Teach. Learn.*, 2025.
- [4] D. R. E. Cotton, P. A. Cotton, and J. R. Shipway, "Chatting and cheating: Ensuring academic integrity

- in the era of ChatGPT,” *Innov. Educ. Teach. Int.*, vol. 61, no. 2, pp. 228–239, 2024.
- [5] K. Sevnarayan and K. B. Maphoto, “Exploring the dark side of online distance learning: Cheating behaviours, contributing factors, and strategies to enhance the integrity of online assessment,” *J. Acad. Ethics*, vol. 22, no. 1, pp. 51–70, 2024.
- [6] J. Cantiello and R. H. Geschke, “Preventing Academic Dishonesty in Online Courses: Best Practices to Discourage Cheating,” *J. Health Adm. Educ.*, vol. 40, no. 2, pp. 205–230, 2024.
- [7] J. R. Gallagher and K. Wagner, “Comparing student and writing instructor perceptions of academic dishonesty when collaborators are artificial intelligence or human,” *J. Bus. Tech. Commun.*, vol. 38, no. 3, pp. 266–288, 2024.
- [8] R. Bala and P. Gupta, “Navigating the Complexities of Academic Integrity in E-Learning: Challenges and Strategies,” in *Augmented Reality and the Future of Education Technology*, IGI Global, 2024, pp. 157–167.
- [9] U. Anita, “Emerging AI technologies and their implications for academic integrity,” *AI Ethics, Acad. Integr. Futur. Educ.*, 2025.
- [10] P. P. Bhatt, J. V. Nasriwala, and R. R. Savant, “Template-Based Thinning Method for Handwritten Gujarati Character’s Strokes and its Classification for Writer-Dependent Gujarati Font Synthesis,” in *Advanced Machine Intelligence and Signal Processing*, Springer, 2022, pp. 203–216.
- [11] S. Cui, “Context-Aware TinyML Model for Korean Handwriting Recognition Under Online Assisted Learning Scenes,” *Internet Technol. Lett.*, p. e636, 2025.
- [12] N. Kumar, A. Chikmath, G. Y. BR, H. R. Naidu, and D. Acharya, “Interpreting doctor notes using handwriting recognition and deep learning techniques: a survey,” in *2023 International Conference on Advances in Electronics, Communication, Computing and Intelligent Information Systems (ICAECIS)*, IEEE, 2023, pp. 703–708.
- [13] N. M. Tahir, A. N. Ausat, U. I. Bature, K. A. Abubakar, and I. Gambo, “Off-line handwritten signature verification system: Artificial neural network approach,” *Int. J. Intell. Syst. Appl.*, vol. 10, no. 1, p. 45, 2021.
- [14] J. Miao, P. Liu, C. Chen, and Y. Qiao, “Normal Template Mapping: An Association-Inspired Handwritten Character Recognition Model,” *Cognit. Comput.*, vol. 16, no. 3, pp. 1103–1112, 2024.
- [15] S. K. Singh and A. Chaturvedi, “An efficient multi-modal sensors feature fusion approach for handwritten characters recognition using Shapley values and deep autoencoder,” *Eng. Appl. Artif. Intell.*, vol. 138, p. 109225, 2024.
- [16] B. Revathi, M. V. D. Prasad, and N. K. Gattim, “Computationally efficient ResNet based Telugu handwritten text detection,” *Bull. Electr. Eng. Informatics*, vol. 13, no. 6, pp. 4115–4123, 2024.
- [17] M. Chauhan *et al.*, “Self-supervised learning based handwriting verification,” in *IET Conference Proceedings CP887*, IET, 2024, pp. 170–177.
- [18] J. J. Valero-Mas, A. J. Gallego, and J. R. Rico-Juan, “An overview of ensemble and feature learning in few-shot image classification using siamese networks,” *Multimed. Tools Appl.*, vol. 83, no. 7, pp. 19929–19952, 2024.
- [19] Z. Qiqi, W. Sai, T. Shun, Y. Liangbin, Q. Kunlun, and G. Qingfeng, “RockS2Net: Rock image classification via a spatial localization siamese network,” *Comput. Geosci.*, vol. 185, p. 105560, 2024.
- [20] Y. Li, L. Weng, M. Xia, K. Hu, and H. Lin, “Multi-scale fusion siamese network based on three-branch attention mechanism for high-resolution remote sensing image change detection,” *Remote Sens.*, vol. 16, no. 10, p. 1665, 2024.
- [21] Azhar Andika Putra, Rudiansyah, Sutra Romadon, and Lemi Iryani, “Development of an Academic Information System Prototype Using the Logical Record Structure (LRS) Model,” *JSAI (Journal Sci. Appl. Informatics)*, vol. 7, no. 2, pp. 399–404, Jun. 2024, doi: 10.36085/jsai.v7i2.7263.
- [22] W. Wang and Z. Lu, “Few-shot bronze vessel classification via siamese fourier networks,” *Sci. Rep.*, vol. 14, no. 1, p. 18011, 2024.
- [23] H. Wei, R. Chen, C. Yu, H. Yang, and S. An, “BASNet: A boundary-aware Siamese network for accurate remote-sensing change detection,” *IEEE Geosci. Remote Sens. Lett.*, vol. 19, pp. 1–5, 2021.
- [24] Q. Li and S. He, “Similarity matching of medical question based on Siamese network,” *BMC Med. Inform. Decis. Mak.*, vol. 23, no. 1, p. 55, 2023.
- [25] D. Chicco, “Siamese neural networks: An overview,” *Artif. neural networks*, pp. 73–94, 2021.
- [26] F. Lambardo, P. Octavia, and A. Ghaniya, “Rekayasa Perangkat Lunak Penjadwalan Kuliah Menggunakan Metode Mobile-D,” *J. Inform. DAN Sist. Inf.*, vol. 3, no. 1, pp. 77–80, 2023.
- [27] Y. F. Achmad, A. Yulfitri, and P. Maharani, “Penerapan algoritma GLCM dan KNN dalam pengenalan jenis jerawat,” *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 74–82, 2024.