

Pengembangan Metode *Deep Metric Learning* Berbasis *Attention* untuk Verifikasi Tanda Tangan Offline pada Lingkungan Data Terbatas

¹Marissa Utami, ²Erwin Dwika Putra

^{1,2}Fakultas Teknik, Universitas Muhammadiyah Bengkulu, Indonesia

¹marissautami@umb.ac.id; ²erwindwikap@gmail.com;

Article Info

Article history:

Received, 2026-06-17

Revised, 2026-06-20

Accepted, 2026-06-27

Kata Kunci:

Offline Signature Verification,
Deep Metric Learning,
Attention Mechanism

Keywords:

Offline Signature Verification,
Deep Metric Learning,
Attention Mechanism

ABSTRAK

Penelitian ini bertujuan mengembangkan metode *Deep Metric Learning* berbasis *attention* untuk verifikasi tanda tangan *offline* pada lingkungan dengan jumlah data terbatas. Permasalahan utama pada verifikasi tanda tangan *offline* terletak pada tingginya variasi intra-kelas dan kemiripan antara tanda tangan asli dan tanda tangan palsu, terutama ketika jumlah data pelatihan terbatas. Metode yang diusulkan menggunakan arsitektur *Siamese Convolutional Neural Network* yang dikombinasikan dengan mekanisme *attention* untuk meningkatkan kemampuan ekstraksi fitur diskriminatif. Dataset yang digunakan diperoleh secara *offline* dan juga menggunakan data yang berseumber dari Kaggle dan terdiri atas tanda tangan asli (*genuine*) dan tanda tangan palsu (*forgery*). Tahapan penelitian meliputi *preprocessing*, pembentukan pasangan data, ekstraksi fitur, proses *embedding* menggunakan *Deep Metric Learning*, serta optimasi menggunakan *Contrastive Loss*. Hasil pengujian menunjukkan bahwa metode yang diusulkan menghasilkan *Accuracy* sebesar 91,12%, *Precision* sebesar 92,27%, *Recall* sebesar 92,43%, *F1-score* sebesar 90,75%, dan *Equal Error Rate* (EER) sebesar 4,88%. Hasil tersebut menunjukkan bahwa integrasi mekanisme *attention* dan *Deep Metric Learning* mampu meningkatkan kemampuan sistem dalam mengenali pola tanda tangan secara efektif pada kondisi data terbatas.

ABSTRACT

This study aims to develop an attention-based Deep Metric Learning method for offline signature verification in environments with limited data availability. The main challenge in offline signature verification lies in the high intra-class variation and the similarity between genuine and forged signatures, particularly when the amount of training data is limited. The proposed method employs a Siamese Convolutional Neural Network architecture combined with an attention mechanism to enhance discriminative feature extraction capabilities. The dataset used in this study was obtained from offline sources and Kaggle, consisting of genuine and forged signature images. The research process includes preprocessing, signature pair generation, feature extraction, embedding generation using Deep Metric Learning, and optimization using Contrastive Loss. Experimental results demonstrate that the proposed method achieved an Accuracy of 91.12%, Precision of 92.27%, Recall of 92.43%, F1-score of 90.75%, and an Equal Error Rate (EER) of 4.88%. These results indicate that the integration of the attention mechanism and Deep Metric Learning effectively improves the system's capability to recognize signature patterns under limited data conditions.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



Penulis Korespondensi:

Marissa Utami,
Program Studi Sistem Informasi,
Universitas Muhammadiyah Bengkulu,
Email: marissautami@umb.ac.id

1. PENDAHULUAN

Tanda tangan masih menjadi salah satu bentuk biometrik yang paling banyak digunakan dalam berbagai aktivitas autentikasi seperti transaksi perbankan, dokumen legal, administrasi pemerintahan, dan sistem keamanan identitas. Dibandingkan metode autentikasi biometrik lainnya, penggunaan tanda tangan memiliki tingkat penerimaan sosial yang tinggi karena tidak memerlukan perangkat khusus dan telah menjadi bagian dari aktivitas sehari-hari [1]. Namun demikian, proses verifikasi tanda tangan secara manual memiliki berbagai keterbatasan, antara lain membutuhkan waktu yang relatif lama, bergantung pada pengalaman pemeriksa, serta rentan terhadap kesalahan identifikasi terutama pada kasus pemalsuan terampil (*skilled forgery*) [2].

Berdasarkan proses akuisisi data, verifikasi tanda tangan dibedakan menjadi verifikasi tanda tangan *online* dan *offline*. Verifikasi *online* memanfaatkan informasi dinamis seperti tekanan pena, kecepatan, dan arah gerakan selama proses penulisan [3]. Sebaliknya, verifikasi *offline* hanya menggunakan citra hasil pemindaian atau hasil tangkapan kamera setelah proses penulisan selesai. Meskipun pendekatan *offline* lebih mudah diterapkan pada dokumen konvensional, metode ini memiliki tingkat kompleksitas yang lebih tinggi karena tidak tersedianya informasi dinamis yang dapat membantu membedakan tanda tangan asli dan palsu [4].

Perkembangan *deep learning* telah memberikan kontribusi besar terhadap peningkatan kinerja sistem verifikasi tanda tangan *offline*. Metode berbasis *Convolutional Neural Network* (CNN) mampu melakukan ekstraksi fitur secara otomatis tanpa memerlukan perancangan fitur manual yang kompleks [5]. Berbagai penelitian menunjukkan bahwa pendekatan pembelajaran representasi mendalam menghasilkan performa yang lebih baik dibandingkan metode konvensional berbasis fitur tekstur, geometri, maupun statistik [2], [4], [6]. Selain itu, pendekatan *writer-independent* berbasis CNN juga menunjukkan kemampuan generalisasi yang baik pada pengguna baru [7]. Meskipun demikian, tantangan utama dalam verifikasi tanda tangan *offline* masih belum sepenuhnya teratasi. Salah satu permasalahan utama adalah tingginya variasi intra-kelas pada tanda tangan asli dan rendahnya perbedaan antar kelas antara tanda tangan asli dengan tanda tangan palsu terampil (*skilled forgery*) [8]. Permasalahan tersebut menjadi lebih kompleks ketika jumlah data pelatihan yang tersedia relatif sedikit. Pada implementasi nyata, pengumpulan sampel tanda tangan dalam jumlah besar untuk setiap pengguna sulit dilakukan karena keterbatasan waktu dan sumber daya [8], [9].

Untuk mengatasi keterbatasan data tersebut, pendekatan *Deep Metric Learning* (DML) mulai banyak digunakan karena mampu mempelajari representasi fitur melalui pengukuran kesamaan dan perbedaan antar pasangan data [10]. Berbeda dengan metode klasifikasi konvensional yang berfokus pada pemisahan kelas secara langsung, DML memetakan data ke ruang fitur sehingga sampel dengan karakteristik serupa memiliki jarak yang dekat, sedangkan sampel yang berbeda dipetakan lebih jauh [11]. Pendekatan ini dinilai lebih efektif pada skenario data terbatas karena model belajar berdasarkan hubungan antar sampel, bukan hanya berdasarkan jumlah data pelatihan [12].

Beberapa penelitian terbaru telah mengintegrasikan *metric learning* dengan arsitektur *Siamese Network* dan menghasilkan peningkatan performa yang signifikan pada sistem verifikasi tanda tangan *offline* [13]. Namun, sebagian besar penelitian masih mengekstraksi fitur secara global sehingga informasi lokal yang penting pada area tertentu dari tanda tangan sering kali tidak dimanfaatkan secara optimal [3]. Padahal, karakteristik tertentu seperti bentuk goresan, lengkungan, ketebalan garis, serta pola lokal pada tanda tangan dapat menjadi informasi penting untuk membedakan tanda tangan asli dan palsu [14].

Mekanisme *attention* merupakan salah satu pendekatan yang saat ini banyak digunakan dalam berbagai tugas *computer vision* karena mampu memfokuskan proses pembelajaran pada area yang memiliki informasi paling relevan [15], [16]. Integrasi mekanisme *attention* pada proses ekstraksi fitur memungkinkan model memberikan bobot lebih besar pada bagian tanda tangan yang memiliki karakteristik diskriminatif, sehingga diharapkan dapat meningkatkan kemampuan model dalam mengidentifikasi pola pemalsuan [17]. Penelitian terbaru menunjukkan bahwa kombinasi *attention mechanism* dan *deep metric learning* mampu meningkatkan performa verifikasi tanda tangan terutama pada skenario *writer-independent* [3].

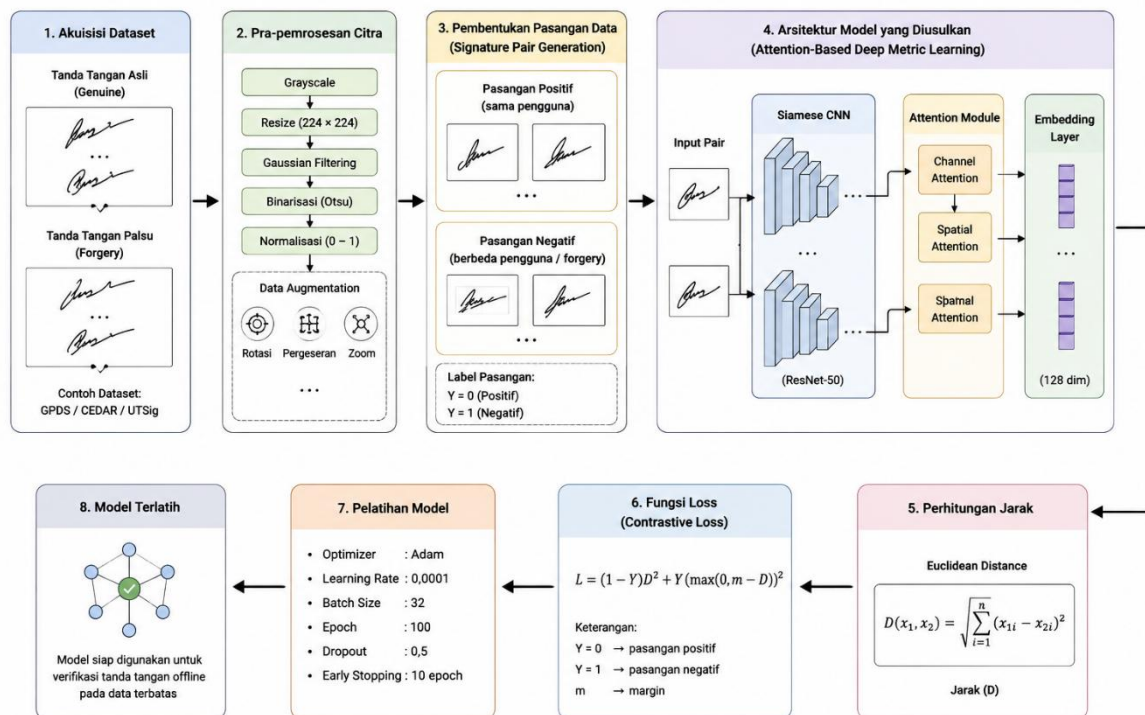
Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pengembangan metode *Deep Metric Learning* berbasis *Attention* untuk verifikasi tanda tangan *offline* pada lingkungan data terbatas [18]. Metode yang diusulkan mengintegrasikan mekanisme *attention* ke dalam proses pembelajaran representasi fitur sehingga model dapat mengekstraksi karakteristik tanda tangan yang lebih diskriminatif [19]. Diharapkan pendekatan yang diusulkan dapat meningkatkan kemampuan model dalam membedakan tanda tangan asli dan palsu, khususnya pada kondisi jumlah sampel pelatihan yang terbatas.

Penelitian ini berfokus pada pengembangan arsitektur *Deep Metric Learning* yang diintegrasikan dengan mekanisme *attention* untuk meningkatkan kinerja verifikasi tanda tangan *offline*, khususnya pada lingkungan dengan jumlah data pelatihan yang terbatas. Pendekatan yang diusulkan dirancang untuk meningkatkan

kemampuan model dalam mengekstraksi fitur-fitur diskriminatif yang mampu membedakan karakteristik tanda tangan asli dan tanda tangan palsu secara lebih efektif. Selain itu, performa model akan dievaluasi menggunakan beberapa parameter pengukuran, yaitu *Accuracy*, *Precision*, *Recall*, *F1-score*, dan *Equal Error Rate (EER)*, guna memberikan analisis yang lebih komprehensif terhadap kemampuan sistem. Dengan demikian, pendekatan yang diusulkan diharapkan dapat menjadi solusi yang lebih efektif dalam meningkatkan akurasi sistem verifikasi tanda tangan offline pada implementasi di lingkungan nyata yang memiliki keterbatasan jumlah data pelatihan.

2. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen dengan pendekatan *Deep Metric Learning* berbasis *attention* untuk mengembangkan sistem verifikasi tanda tangan offline pada lingkungan data terbatas. Metode yang diusulkan dirancang agar model mampu mempelajari tingkat kesamaan dan perbedaan karakteristik antar tanda tangan melalui pembelajaran representasi fitur yang lebih diskriminatif. Sistem dibangun menggunakan arsitektur Siamese *Convolutional Neural Network* yang dikombinasikan dengan mekanisme *attention* untuk meningkatkan kemampuan model dalam memfokuskan proses pembelajaran pada bagian tanda tangan yang memiliki informasi penting.



Gambar 1. Alur penelitian

Tahap awal penelitian dimulai dengan proses pengumpulan dataset tanda tangan *offline* yang diperoleh dari platform Kaggle. Dataset terdiri atas citra tanda tangan asli (*genuine signature*) dan tanda tangan palsu (*forgery signature*) yang digunakan sebagai data masukan untuk proses pelatihan dan pengujian model. Dataset kemudian dibagi menjadi data pelatihan, data validasi, dan data pengujian dengan rasio tertentu untuk memastikan model dapat dilatih dan dievaluasi secara optimal. Pada penelitian ini, kondisi *limited sample* diterapkan dengan membatasi jumlah sampel pelatihan yang digunakan pada setiap pengguna sehingga penelitian dapat mensimulasikan kondisi nyata yang umumnya memiliki keterbatasan jumlah data tanda tangan.

Tahap berikutnya adalah pra-pemrosesan citra untuk meningkatkan kualitas data sebelum digunakan dalam proses pembelajaran model. Proses pra-pemrosesan meliputi konversi citra ke format *grayscale*, normalisasi ukuran citra menjadi 224 x 224 piksel, pengurangan noise menggunakan *Gaussian filtering*, proses binarisasi menggunakan metode *Otsu*, dan normalisasi nilai piksel ke rentang 0-1. Selain itu, dilakukan proses data

augmentation melalui rotasi, pergeseran posisi, *zoom*, dan variasi ketebalan garis untuk meningkatkan keragaman data pelatihan dan mengurangi risiko *overfitting* akibat jumlah data yang terbatas.

Setelah tahap pra-pemrosesan selesai, dilakukan pembentukan pasangan data (*signature pair generation*) yang terdiri atas pasangan positif dan pasangan negatif. Pasangan positif merupakan pasangan tanda tangan yang berasal dari pengguna yang sama, sedangkan pasangan negatif merupakan pasangan tanda tangan dari pengguna berbeda atau pasangan antara tanda tangan asli dan tanda tangan palsu. Pembentukan pasangan data ini dilakukan karena metode *Deep Metric Learning* mempelajari tingkat kemiripan antar data melalui hubungan antar pasangan citra.

Model yang diusulkan menggunakan arsitektur *Attention-Based Deep Metric Learning* yang terdiri atas *Siamese CNN*, *attention module*, dan *embedding layer*. *Siamese CNN* digunakan untuk mengekstraksi fitur visual dari citra tanda tangan, sedangkan mekanisme *attention* digunakan untuk memberikan fokus lebih besar pada bagian citra yang memiliki informasi penting seperti pola goresan, bentuk lengkungan, dan karakteristik unik tanda tangan. Hasil ekstraksi fitur selanjutnya dipetakan ke dalam *embedding space* sehingga karakteristik tanda tangan dapat direpresentasikan dalam bentuk vektor fitur.

Selanjutnya dilakukan perhitungan jarak antar pasangan data menggunakan metode *Euclidean Distance* untuk menentukan tingkat kemiripan antar tanda tangan. Nilai jarak yang dihasilkan kemudian digunakan pada fungsi *Contrastive Loss* yang bertujuan memperkecil jarak pasangan positif dan memperbesar jarak pasangan negatif [5]. Proses pelatihan model dilakukan menggunakan *optimizer Adam* dengan *learning rate* sebesar 0,0001, *batch size* sebanyak 32, dan jumlah *epoch* sebanyak 100 iterasi sehingga menghasilkan model yang siap digunakan dalam proses verifikasi tanda tangan *offline*.

3. HASIL DAN ANALISIS

Implementasi metode *Attention-Based Deep Metric Learning* pada penelitian ini dilakukan menggunakan dataset tanda tangan *offline* yang dan dataset diperoleh dari Kaggle dan terdiri atas tanda tangan asli (*genuine signature*) serta tanda tangan palsu (*forgery signature*). Dataset diproses melalui tahapan *preprocessing* yang meliputi konversi citra menjadi grayscale, normalisasi ukuran citra, reduksi *noise*, binarisasi, dan normalisasi nilai piksel. Selanjutnya dilakukan proses data *augmentation* untuk meningkatkan keragaman data pelatihan. Data yang telah diproses kemudian dibentuk menjadi pasangan data positif dan pasangan data negatif sebelum digunakan sebagai masukan pada arsitektur *Attention-Based Deep Metric Learning*.

Model dibangun menggunakan *Siamese Convolutional Neural Network* dengan mekanisme *attention* yang bertujuan untuk meningkatkan kemampuan model dalam memfokuskan proses ekstraksi fitur pada bagian tanda tangan yang memiliki karakteristik penting. Pada proses pelatihan, model menggunakan *optimizer Adam* dengan *learning rate* sebesar 0,0001, *batch size* sebanyak 32, dan jumlah *epoch* sebanyak 100 iterasi. Setelah proses pelatihan selesai, dilakukan evaluasi terhadap performa model menggunakan parameter *Accuracy*, *Precision*, *Recall*, *F1-score*, dan *Equal Error Rate* (EER).

Hasil pengujian menunjukkan bahwa metode yang diusulkan mampu menghasilkan performa yang cukup baik pada kondisi data terbatas. Model memperoleh nilai *Accuracy* sebesar 91,12%, *Precision* sebesar 92,27%, *Recall* sebesar 92,43%, *F1-score* sebesar 90,75%, dan *Equal Error Rate* (EER) sebesar 4,88%. Nilai *Accuracy* menunjukkan bahwa sistem mampu mengklasifikasikan tanda tangan dengan tingkat ketepatan yang tinggi. Tingginya nilai *Precision* sebesar 92,27% menunjukkan bahwa model memiliki kemampuan yang baik dalam mengurangi kesalahan identifikasi terhadap tanda tangan palsu yang terdeteksi sebagai tanda tangan asli. Sementara itu, nilai *Recall* sebesar 92,43% menunjukkan bahwa model cukup efektif dalam mengenali tanda tangan asli sehingga tingkat kehilangan identifikasi terhadap data positif dapat diminimalkan.

Tabel 1. Hasil pengujian

Parameter	Nilai (%)
Accuracy	91,12
Precision	92,27
Recall	92,43
F1-score	90,75
Equal Error Rate (EER)	4,88

Nilai *F1-score* sebesar 90,75% menunjukkan adanya keseimbangan yang baik antara nilai *Precision* dan *Recall*. Hal tersebut mengindikasikan bahwa model memiliki performa yang stabil dalam mengidentifikasi berbagai karakteristik tanda tangan. Selain itu, nilai *Equal Error Rate* sebesar 4,88% menunjukkan tingkat kesalahan sistem yang relatif rendah. Dalam sistem biometrik, nilai EER yang semakin kecil menunjukkan bahwa sistem memiliki kemampuan yang semakin baik dalam menyeimbangkan tingkat penerimaan tanda tangan palsu (*False Acceptance Rate*) dan tingkat penolakan terhadap tanda tangan asli (*False Rejection Rate*).

Dengan nilai EER di bawah 5%, metode yang diusulkan menunjukkan kemampuan yang cukup baik dalam proses verifikasi tanda tangan *offline*.

Hasil penelitian menunjukkan bahwa penggunaan mekanisme *attention* memberikan kontribusi terhadap peningkatan kualitas representasi fitur yang dihasilkan oleh *Siamese CNN*. Mekanisme *attention* memungkinkan model untuk lebih fokus pada bagian tanda tangan yang mengandung informasi penting seperti pola goresan, arah lengkungan, ketebalan garis, dan karakteristik lokal lainnya. Pendekatan tersebut membantu model dalam membedakan karakteristik antara tanda tangan asli dan tanda tangan palsu secara lebih efektif. Selain itu, penggunaan *Deep Metric Learning* juga memberikan keuntungan pada lingkungan dengan jumlah data terbatas karena proses pembelajaran dilakukan berdasarkan hubungan kesamaan antar pasangan data, bukan hanya berdasarkan jumlah data pelatihan yang tersedia.

Untuk mengetahui efektivitas metode yang diusulkan, dilakukan perbandingan terhadap beberapa penelitian sebelumnya yang menggunakan pendekatan berbeda pada verifikasi tanda tangan *offline*. Hasil perbandingan menunjukkan bahwa metode yang diusulkan mampu memberikan hasil yang kompetitif dibandingkan penelitian sebelumnya.



Gambar 2. Perbandingan akurasi dengan penelitian sebelumnya

Berdasarkan hasil perbandingan tersebut, metode yang diusulkan menghasilkan akurasi sebesar 91,12%. Nilai tersebut masih berada di atas metode CNN konvensional yang digunakan oleh Hafemann et al., namun masih lebih rendah dibandingkan pendekatan *Region-Based Deep Metric Learning* yang memperoleh akurasi sebesar 94,10%. Perbedaan tersebut dapat dipengaruhi oleh beberapa faktor, seperti karakteristik dataset yang digunakan, jumlah sampel pelatihan yang tersedia, konfigurasi arsitektur jaringan, serta kompleksitas proses ekstraksi fitur. Meskipun demikian, metode yang diusulkan tetap menunjukkan kemampuan yang baik pada skenario data terbatas dan berhasil mempertahankan keseimbangan antara tingkat akurasi dan tingkat kesalahan sistem yang relatif rendah. Hasil ini menunjukkan bahwa integrasi mekanisme *attention* dan *Deep Metric Learning* memiliki potensi untuk meningkatkan performa verifikasi tanda tangan *offline* pada implementasi nyata.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, metode *Deep Metric Learning* berbasis *attention* berhasil diterapkan pada sistem verifikasi tanda tangan *offline* dalam kondisi jumlah data yang terbatas. Integrasi *Siamese Convolutional Neural Network* dengan mekanisme *attention* mampu meningkatkan kemampuan model dalam mengekstraksi fitur-fitur diskriminatif yang berperan penting dalam membedakan tanda tangan asli dan tanda tangan palsu. Hasil pengujian menunjukkan bahwa model memperoleh nilai *Accuracy* sebesar 91,12%, *Precision* sebesar 92,27%, *Recall* sebesar 92,43%, *F1-score* sebesar 90,75%, dan *Equal Error Rate* (EER) sebesar 4,88%. Nilai tersebut menunjukkan bahwa metode yang diusulkan memiliki performa yang baik dalam proses verifikasi tanda tangan *offline* serta mampu mempertahankan tingkat kesalahan yang relatif rendah. Selain itu, pendekatan *Deep Metric Learning* menunjukkan kemampuan yang efektif dalam mengatasi keterbatasan jumlah data pelatihan melalui pembelajaran hubungan antar pasangan data. Dengan demikian, metode yang dikembangkan memiliki potensi untuk diterapkan pada sistem autentikasi biometrik di lingkungan nyata. Penelitian selanjutnya dapat difokuskan pada pengembangan arsitektur yang lebih kompleks, penggunaan dataset yang lebih beragam, serta penerapan metode *attention* yang lebih adaptif untuk meningkatkan performa sistem.

REFERENSI

- [1] M. M. Hameed, R. Ahmad, M. L. M. Kiah, and G. Murtaza, "Machine learning-based offline signature verification systems: A systematic review," *Signal Process. Image Commun.*, vol. 93, p. 116139, Apr. 2021, doi: 10.1016/j.image.2021.116139.

- [2] G. K. Pandey, V. Raj, A. Agarwal, M. Dixit, S. S. Chauhan, and S. Srivastava, "Offline Signature Verification: An Extensive Survey of Deep Learning Methods," in *4th International Conference on Sentiment Analysis and Deep Learning, ICSADL 2025 - Proceedings*, IEEE, Feb. 2025, pp. 892–898. doi: 10.1109/ICSADL65848.2025.10933339.
- [3] L. R. Ling, H. Zhang, F. Yin, and C. L. Liu, "Deep Metric Learning with Cross-Writer Attention for Offline Signature Verification," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 14805 LNCS, 2024, pp. 250–267. doi: 10.1007/978-3-031-70536-6_15.
- [4] Y. Muhtar, W. Kang, A. Rexit, Mahpirat, and K. Ubul, "A Survey of Offline Handwritten Signature Verification Based on Deep Learning," in *2022 3rd International Conference on Pattern Recognition and Machine Learning, PRML 2022*, IEEE, Jul. 2022, pp. 391–397. doi: 10.1109/PRML56267.2022.9882188.
- [5] H. Guo, X. Fan, and S. Wang, "Human attribute recognition by refining attention heat map," *Pattern Recognit. Lett.*, vol. 94, pp. 38–45, Jul. 2017, doi: 10.1016/j.patrec.2017.05.012.
- [6] L. G. Hafemann, R. Sabourin, and L. S. Oliveira, "Offline handwritten signature verification - Literature review," in *Proceedings of the 7th International Conference on Image Processing Theory, Tools and Applications, IPTA 2017*, IEEE, Nov. 2017, pp. 1–8. doi: 10.1109/IPTA.2017.8310112.
- [7] G. Tauer, K. Date, R. Nagi, and M. Sudit, "An incremental graph-partitioning algorithm for entity resolution," *Inf. Fusion*, vol. 46, pp. 171–183, Mar. 2019, doi: 10.1016/j.inffus.2018.06.001.
- [8] L. Liu, L. Huang, F. Yin, and Y. Chen, "Offline signature verification using a region based deep metric learning network," *Pattern Recognit.*, vol. 118, p. 108009, Oct. 2021, doi: 10.1016/j.patcog.2021.108009.
- [9] G. Wang, H. Zhang, S. Yu, and S. Ding, "A family of the subgradient algorithm with several cosparsity inducing functions to the cosparsity recovery problem," *Pattern Recognit. Lett.*, vol. 80, pp. 64–69, Sep. 2016, doi: 10.1016/j.patrec.2016.05.012.
- [10] B. Li, B. Wu, J. Su, and G. Wang, "EagleEye: Fast Sub-net Evaluation for Efficient Neural Network Pruning," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12347 LNCS, 2020, pp. 639–654. doi: 10.1007/978-3-030-58536-5_38.
- [11] E. van der Spoel *et al.*, "Siamese Neural Networks for One-Shot Image Recognition," in *ICML - Deep Learning Workshop*, 2015, pp. 956–963. [Online]. Available: <https://api.semanticscholar.org/CorpusID:13874643>
- [12] F. Schroff, D. Kalenichenko, and J. Philbin, "FaceNet: A unified embedding for face recognition and clustering," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2015, pp. 815–823. doi: 10.1109/CVPR.2015.7298682.
- [13] D. Lemire, "Fast random integer generation in an interval," *ACM Trans. Model. Comput. Simul.*, vol. 29, no. 1, pp. 1–12, Jan. 2019, doi: 10.1145/3230636.
- [14] S. Woo, J. Park, J. Y. Lee, and I. S. Kweon, "CBAM: Convolutional block attention module," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11211 LNCS, 2018, pp. 3–19. doi: 10.1007/978-3-030-01234-2_1.
- [15] K. Mohiuddin *et al.*, "Retention Is All You Need," *Int. Conf. Inf. Knowl. Manag. Proc.*, pp. 4752–4758, Aug. 2023, doi: 10.1145/3583780.3615497.
- [16] X. Wang, R. Girshick, A. Gupta, and K. He, "Non-local Neural Networks," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2018, pp. 7794–7803. doi: 10.1109/CVPR.2018.00813.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE, Jun. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [18] L. Liu, L. Huang, F. Yin, and Y. Chen, "Offline signature verification using a region based deep metric learning network," *Pattern Recognit.*, vol. 118, p. 108009, Oct. 2021, doi: 10.1016/j.patcog.2021.108009.

- [19] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *ICML*, Sep. 2020, [Online]. Available: <http://arxiv.org/abs/1905.11946>