

PENERAPAN METODE *SEMI SUPERVISED DEEP EMBEDDED CLUSTERING* PADA KLASTERISASI CITRA BENDA ARKEOLOGI DI SULAWESI TENGGARA UNTUK MENDUKUNG DIGITALISASI KOLEKSI ARKEOLOGI

Sriraya Kuru^{1*}, Adha Mashur Sajiah², Rizal Adi Saputra³

^{1,2,3} Teknik Informatika, Universitas Halu Oleo; Kampus Hijau Bumi Tridharma Anduonohu, Jl. H.E.A. Mokodompit, Kendari; Tlp. (0401) 3195287, Fax.(0401) 3190006

Keywords:

Deep Embedded Clustering; EfficientNetV2B2; Klasterisasi Citra; Semi-supervised Learning; Benda Arkeologi.

Correspondent Email:

srirayak@gmail.com

Abstrak. Benda arkeologi di Museum Sulawesi Tenggara berjumlah lebih dari 4.666 koleksi dengan keragaman bentuk, fungsi, dan karakteristik visual yang tinggi. Proses kategorisasi yang selama ini dilakukan secara manual oleh kurator memiliki keterbatasan konsistensi dan efisiensi, khususnya ketika volume koleksi terus bertambah. Penelitian ini bertujuan merancang dan mengimplementasikan sistem klasterisasi citra benda arkeologi berbasis *Semi-supervised Deep Embedded Clustering* (SDEC) dengan *fine-tuning* EfficientNetV2B2 sebagai ekstraktor fitur. Dataset terdiri dari 593 citra yang dibagi ke dalam 10 kategori koleksi museum, dengan skema *semi-supervised* menggunakan 50% data berlabel dan 50% data tidak berlabel. Metode yang diterapkan meliputi *preprocessing* citra, *fine-tuning* dua fase EfficientNetV2B2, pembentukan *head embedding* berdimensi 256, inisialisasi *centroid* berbasis *class-mean*, serta optimasi kluster menggunakan *KL Divergence* dan *Sparse Categorical Cross-Entropy* (SCCE) sebagai *joint loss*. Hasil evaluasi menunjukkan *Acc All* sebesar 86,17%, *Acc Labeled* sebesar 90,91%, *Acc UnLabeled* sebesar 81,42%, dan *Silhouette Score* sebesar 0,1421, dengan peningkatan akurasi data tidak berlabel sebesar 41,89% dibandingkan *baseline classifier* EfficientNetV2B2. Visualisasi t-SNE mengonfirmasi bahwa sebagian besar kategori membentuk kelompok yang cukup terpisah di ruang *embedding*. Sistem diimplementasikan dalam antarmuka berbasis Streamlit sebagai alat bantu digitalisasi koleksi arkeologi di Sulawesi Tenggara.



Copyright © 2026 The Author(s), Published by Jurnal Informatika dan Teknik Elektro Terapan. This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0).

Abstract. The Southeast Sulawesi Museum has more than 4,666 archaeological objects with a high diversity of forms, functions, and visual characteristics. The manual categorization process carried out by curators has limited consistency and efficiency, especially when the collection volume continues to grow. This study aims to design and implement an archaeological object image clustering system based on *Semi-supervised Deep Embedded Clustering* (SDEC) with *EfficientNetV2B2 fine-tuning* as a feature extractor. The dataset consists of 593 images divided into 10 museum collection categories, with a *semi-supervised* scheme using 50% labeled data and 50% unlabeled data. The methods applied include image preprocessing, two-phase fine-tuning of EfficientNetV2B2, formation of a 256-dimensional head embedding, class-mean-based centroid initialization, and cluster optimization using *KL Divergence* and *Sparse Categorical Cross-Entropy* (SCCE) as a joint loss. The evaluation results show an *Acc All* of 86.17%, *Acc Labeled* of 90.91%, *Acc UnLabeled* of 81.42%, and a *Silhouette Score* of 0.1421, with an

increase in unlabeled data accuracy of 41.89% compared to the baseline classifier EfficientNetV2B2. t-SNE visualization confirms that most categories form fairly separate clusters in the embedding space. The system is implemented in a Streamlit-based interface as a tool for digitizing archaeological collections in Southeast Sulawesi.

1. PENDAHULUAN

Indonesia memiliki kekayaan arkeologi yang luar biasa, didukung oleh keberadaan sekitar 469 museum yang tersebar di berbagai wilayah. Menteri Kebudayaan Republik Indonesia pada tahun 2025 menyerukan peningkatan inklusivitas dan integrasi teknologi digital di seluruh museum untuk menjangkau generasi muda [1]. Museum Provinsi Sulawesi Tenggara menyimpan 4.666 benda koleksi dari empat suku asli, yaitu Muna, Buton, Tolaki, dan Moronene, namun hanya sekitar 700 koleksi yang dapat dipajang karena keterbatasan ruang pameran [2]. Kondisi ini menuntut adanya sistem pengelolaan dan digitalisasi koleksi yang lebih efisien.

Proses kategorisasi koleksi arkeologi yang selama ini dilakukan secara manual oleh kurator memiliki keterbatasan signifikan. Pengelompokan berbasis pengamatan visual dan penilaian subjektif cenderung tidak konsisten ketika diterapkan pada ribuan objek dengan karakteristik bentuk, tekstur, material, dan warna yang sangat beragam [3]. Pemberian label terhadap citra benda arkeologi memerlukan keahlian khusus di bidang arkeologi sekaligus pengetahuan budaya lokal yang mendalam, sehingga pendekatan *supervised learning* murni menjadi tidak praktis diterapkan dalam skala penuh koleksi museum [4].

Beberapa penelitian terdahulu telah menunjukkan potensi besar metode *Deep Embedded Clustering* (DEC) dalam mengelompokkan data berdimensi tinggi. Enguehard dkk. (2019) menunjukkan bahwa *Semi-supervised* DEC (SSLDEC) mencapai akurasi hingga 99,8% pada dataset *benchmark* [5]. Cheng dkk. (2024) melaporkan akurasi 99,2% pada dataset USPS menggunakan varian DEC berbasis stabilitas sampel [6]. Resler dkk. (2021) membuktikan bahwa model berbasis EfficientNetB3 mampu mengklasifikasikan artefak arkeologi dengan akurasi Top-1 mencapai 76,36% pada kategori *broad-period* [7]. Namun, penelitian yang secara spesifik

menerapkan *Semi-supervised* DEC pada citra benda arkeologi di Indonesia, khususnya Sulawesi Tenggara, masih sangat terbatas.

Research gap utama yang diidentifikasi adalah belum adanya penelitian yang menggabungkan *fine-tuning* EfficientNetV2B2 sebagai ekstraktor fitur dengan *Semi-supervised* DEC dan inisialisasi *centroid* berbasis *class mean* untuk klasterisasi citra arkeologi. Penelitian ini hadir untuk mengisi celah tersebut dengan mengusulkan sistem klasterisasi otomatis yang memanfaatkan sebagian kecil data berlabel untuk mengarahkan proses pengelompokan data tidak berlabel secara efektif.

Tujuan penelitian ini adalah: (1) merancang dan mengimplementasikan sistem klasterisasi citra benda arkeologi berbasis *Semi-supervised* DEC dengan *fine-tuning* EfficientNetV2B2; (2) menganalisis efektivitas klaster yang dihasilkan menggunakan metrik *Silhouette Score* dan *Clustering Accuracy* (ACC); serta (3) mengkaji kontribusi sistem terhadap proses digitalisasi koleksi arkeologi di Sulawesi Tenggara. Sistem diimplementasikan dalam antarmuka web berbasis Streamlit untuk memudahkan penggunaan oleh kurator museum.

2. TINJAUAN PUSTAKA

2.1 *Deep Embedded Clustering (DEC)*

Deep Embedded Clustering (DEC) diperkenalkan oleh Xie, Girshick, dan Farhadi (2016) melalui makalah *Unsupervised Deep Embedding for Clustering Analysis* [8]. DEC menggabungkan pembelajaran representasi dan proses klasterisasi dalam satu kerangka *end-to-end* dengan menggunakan *autoencoder* untuk mengekstraksi fitur laten berdimensi rendah, kemudian melakukan soft assignment berbasis distribusi *Student's t* terhadap representasi laten tersebut [9]. Distribusi *soft assignment* diformulasikan sebagai berikut:

$$q_{ij} = \frac{\left(1 + \frac{\|z_i - \mu_j\|^2}{\alpha}\right)^{-\frac{\alpha+1}{2}}}{\sum_{j'} \left(1 + \frac{\|z_i - \mu_{j'}\|^2}{\alpha}\right)^{-\frac{\alpha+1}{2}}} \quad (1)$$

keterangan:

- q_{ij} : probabilitas *soft assignment* bahwa sampel ke-i termasuk dalam kluster j
 z_i : vektor representasi laten dari sampel ke-i
 μ_j : *centroid* kluster ke-j
 α : Parameter derajat kebebasan distribusi *Student's t* (umumnya bernilai 1)

2.2 Semi-supervised Deep Embedded Clustering

Semi-supervised learning memanfaatkan sebagian kecil data berlabel dan sejumlah besar data tidak berlabel secara bersamaan dalam proses pembelajaran [10]. Pada pendekatan *Semi-supervised DEC*, fungsi kerugian tambahan berupa *Sparse Categorical Cross-Entropy* (SCCE) diterapkan pada *output clustering layer* untuk data berlabel sebagai *supervised guidance* [11]. Fungsi kerugian total dirumuskan sebagai berikut:

$$L_{total} = L_c + \lambda L_{SCCE} \quad (2)$$

keterangan:

- L_{total} : fungsi kerugian total yang dioptimalkan
 L_c : *KL Divergence loss* untuk optimasi distribusi kluster
 L_{SCCE} : *Sparse Categorical Cross-Entropy loss* sebagai pengarah *supervised*
 λ : faktor pengatur keseimbangan kedua fungsi kerugian

2.3 EfficientNetV2B2


EfficientNetV2 merupakan generasi kedua dari keluarga EfficientNet yang dirancang menggunakan *Neural Architecture Search* (NAS) untuk mempertimbangkan keseimbangan antara akurasi, kecepatan pelatihan, dan efisiensi parameter [12]. Varian EfficientNetV2B2 yang digunakan dalam penelitian ini memiliki sekitar 8,8 juta parameter dengan *input* berukuran 224×224 piksel dan menghasilkan representasi fitur berdimensi 1408 pada lapisan *Global Average Pooling* (GAP). Dimensi fitur ini selanjutnya

diproyeksikan ke ruang laten 256-dimensi melalui *projection head* yang terdiri dari *Dense* → *BatchNorm* → *Dropout* → *Dense* → *L2 Normalization* [13].

2.4 Metrik Evaluasi

Silhouette Score (S) mengukur seberapa baik objek dikelompokkan berdasarkan jarak antar kluster, dengan nilai mendekati 1 menandakan pemisahan kluster yang baik [14]. *Clustering Accuracy* (ACC) mengukur kesesuaian hasil kluster dengan label *ground truth* untuk pemetaan permutasi optimal. Evaluasi ACC dibedakan menjadi tiga kelompok: *Acc All* (seluruh data), *Acc Labeled* (data berlabel), dan *Acc UnLabeled* (data tidak berlabel), di mana *Acc UnLabeled* menjadi metrik utama [15].

3. METODE PENELITIAN



Gambar 1. Flowchart

Flowchart pada Gambar 1 menunjukkan alur penelitian yang dimulai dari input citra benda arkeologi, kemudian dilakukan tahap *preprocessing* yang meliputi pembacaan dan konversi citra, perubahan ukuran (*resize*), label masking untuk menentukan data berlabel dan tidak berlabel, augmentasi data, normalisasi nilai piksel, serta *encoding label*. Selanjutnya, citra yang telah diproses digunakan pada tahap *feature learning* dengan melakukan *fine-tuning* EfficientNetV2B2 untuk mengekstraksi fitur yang representatif. Fitur hasil ekstraksi kemudian digunakan pada tahap training

menggunakan *Deep Embedded Clustering* (DEC) untuk mempelajari representasi laten sekaligus melakukan pengelompokan data. Hasil proses tersebut berupa klusterisasi objek arkeologi, yang selanjutnya dievaluasi dan disajikan sebagai hasil akhir penelitian.

3.1 Dataset

Dataset yang digunakan berupa 593 citra digital benda arkeologi yang diperoleh dari koleksi Museum Provinsi Sulawesi Tenggara melalui observasi langsung dan dokumentasi visual. Citra disimpan dalam format HEIC dan dikategorikan ke dalam 10 kelas koleksi museum: Arkeologi (81 citra), Biologi (48 citra), Etnografi (124 citra), Geologi (21 citra), Keramik (112 citra), Kesenian (38 citra), Naskah Kuno (47 citra), Numismatik (50 citra), Senjata (12 citra), dan Teknologika (60 citra). Skema *semi-supervised* diterapkan dengan 50% data dipertahankan sebagai data berlabel (297 citra) dan 50% disembunyikan labelnya (296 citra).



Gambar 2. Dataset Citra Benda Arkeologi

3.2 Preprocessing Citra

Tahap *preprocessing* meliputi: (1) pembacaan dan konversi citra dari BGR ke RGB menggunakan OpenCV; (2) *resize* seluruh citra menjadi 224×224 piksel menggunakan interpolasi LANCZOS; (3) *label masking* dengan *mask_ratio*=0,5 untuk mensimulasikan skenario *semi-supervised*; (4) augmentasi data berupa *RandomFlip* (*horizontal_and_vertical*), *RandomRotation* (*factor*=0,25), *RandomZoom* (*factor*=0,25), *RandomTranslation* (*height*=*width*=0,15), *RandomContrast* (*factor*=0,2), dan *RandomBrightness* (*factor*=0,2); serta (5) normalisasi piksel menggunakan fungsi *preprocess_input* bawaan EfficientNetV2B2 agar nilai piksel sesuai distribusi data ImageNet.

3.3 Fine-tuning EfficientNetV2B2

Proses *fine-tuning* dilakukan dalam dua fase menggunakan *Adam Optimizer*. Fase 1 (*Head Only*): seluruh lapisan *backbone* dibekukan dan hanya *classification head* yang dilatih dengan *learning rate*= 1×10^{-3} selama maksimal 30 *epoch*. Fase 2 (*Fine-tuning*): sebanyak 20 lapisan terakhir *backbone* dibuka dan dilatih ulang dengan *learning rate*= 1×10^{-5} selama maksimal 50 *epoch*. Mekanisme *fallback* otomatis diterapkan apabila akurasi validasi Fase 2 lebih rendah dibandingkan Fase 1.

Kedua fase menggunakan *callback* *EarlyStopping*, *ReduceLROnPlateau*, dan *ModelCheckpoint*. Arsitektur model *fine-tuning* ditampilkan pada Tabel 1.

Tabel 1. Arsitektur Model EfficientNetV2B2

Layer	Type Layer	Output Shape	Parameter
<i>Input</i>	<i>InputLayer</i>	(None, 224, 224, 3)	0
EfficientNet V2B2	<i>Functional</i>	(None, 1408)	8.769.374
fc512	<i>Dense</i>	(None, 512)	721.408
bn1	<i>Batch Normalization</i>	(None, 512)	2.048
drop1	<i>Dropout</i>	(None, 512)	0
fc256	<i>Dense</i>	(None, 256)	131.328
drop2	<i>Dropout</i>	(None, 256)	0
<i>classifier</i>	<i>Dense</i>	(None, 10)	2.570

Dari Tabel 1 dapat dilihat bahwa model memiliki total 9.626.728 parameter dengan 856.330 *trainable* parameter dan 8.770.398 *non-trainable* parameter. Model menerima *input* citra $224 \times 224 \times 3$ dan menghasilkan *embedding* berdimensi 256 untuk proses klusterisasi.

3.4 Pembentukan Head embedding

Setelah *fine-tuning*, lapisan *classifier* dihapus dan model berfungsi sebagai *feature extractor*. Fitur 1408-dimensi dari *backbone* diproyeksikan melalui *projection head* (fc512

→ *BatchNorm* → *Dropout* → *fc256*) menghasilkan *head embedding* z_i berdimensi 256 yang dinormalisasi dengan *L2 Normalization*. Representasi ini bersifat *frozen* selama pelatihan DEC. Proses ekstraksi menghasilkan matriks fitur berukuran (593, 256) sebagai masukan proses klusterisasi.

3.5 Inisialisasi Centroid Berbasis *Class mean*

Centroid kluster diinisialisasi menggunakan *Class-mean Supervised Centroid Initialization*, yaitu rata-rata *head embedding* data berlabel pada masing-masing kelas.

$$\mu_j = \frac{1}{|S_j|} \sum_{i \in S_j} z_i \quad (3)$$

keterangan:

- μ_j : *Centroid* awal kluster ke- j
- S_j : himpunan indeks data berlabel yang termasuk kelas j
- z_i : vektor *head embedding* (256-dim) dari sampel ke- i
- $|S_j|$: jumlah sampel berlabel pada kelas j

S_j adalah himpunan indeks data berlabel kelas j dan z_i adalah vektor *head embedding* 256-dim. Pendekatan menunjukkan bahwa *centroid* kluster j langsung memetakan ke kelas j secara deterministik berdasarkan data berlabel [16].

3.6 Semi-supervised Deep Embedded Clustering (SDEC)

Model DEC menggunakan *ClusteringLayer* yang menyimpan dan memperbarui *centroid* kluster. *Soft assignment* dihitung menggunakan distribusi *Student's t* dengan $\alpha=1,0$ sesuai Persamaan 1. Distribusi target P dihitung untuk memperkuat keyakinan model terhadap kluster yang sudah cenderung benar. Optimasi dilakukan menggunakan *joint loss* (Persamaan 2) dengan $\lambda=1,0$, $dec_lr=0,001$, $batch_size=256$, $update_interval=20$ iterasi, dan $dec_max_iter=500$. Seluruh parameter *backbone* dan *projection head* dibekukan selama pelatihan DEC, sehingga hanya parameter *ClusteringLayer* yang dioptimalkan melalui *Adam Optimizer*.

3.7 Implementasi Sistem

Sistem dikembangkan menggunakan Python 3.10.5 dengan pustaka TensorFlow/Keras, Scikit-Learn, OpenCV, NumPy, Pandas, Matplotlib, dan UMAP-Learn. Pelatihan model dilaksanakan pada Google Colaboratory dengan akselerasi GPU. Model yang telah dilatih diintegrasikan ke dalam aplikasi web berbasis Streamlit yang memungkinkan pengguna mengunggah citra benda arkeologi, memperoleh hasil klusterisasi beserta cluster probability, serta melihat visualisasi t-SNE dan informasi galeri koleksi per kluster.

4. HASIL DAN PEMBAHASAN

4.1 Hasil Fine-tuning Model

Pelatihan Fase 1 (*Head Only*) menghasilkan akurasi validasi terbaik sebesar 86,7% pada *Epoch* 11. *Callback* EarlyStopping menghentikan pelatihan pada *Epoch* 19 karena tidak ada peningkatan *val_accuracy* lebih lanjut. Pada Fase 2 (*Fine-tuning*), model hanya mencapai *val_accuracy* sebesar 84,4%, lebih rendah dibandingkan Fase 1, sehingga mekanisme *fallback* otomatis aktif dan model akhir menggunakan bobot dari Fase 1. *Final Val Acc* model yang digunakan untuk ekstraksi fitur adalah 86,7%.

4.2 Hasil Pembentukan *Embedding* dan Inisialisasi *Centroid*

Proses ekstraksi fitur menggunakan *backbone* EfficientNetV2B2 yang telah fine-tuned menghasilkan matriks *embedding* berukuran (593, 1408), yang selanjutnya diproyeksikan melalui *projection head* menjadi *head embedding* (593, 256) yang dinormalisasi L2. Model *ClusteringOnly* memiliki 2.560 parameter yang berasal dari 10 kluster dengan 256 dimensi *embedding* pada setiap *centroid*. Evaluasi awal setelah inisialisasi *centroid* berbasis *class mean* menggunakan 297 sampel berlabel menunjukkan *Acc All*=86,51%, *Acc UnLabeled*=81,08%, dan *Silhouette Score*=0,1423, dengan seluruh 10 kluster terisi. Hasil ini jauh melampaui *baseline classifier* (39,53%) bahkan sebelum proses optimasi DEC dimulai, membuktikan kualitas inisialisasi *centroid* berbasis *class mean*.

4.3 Hasil Klasterisasi SDEC

Proses pelatihan DEC dilakukan selama 500 iterasi. Akurasi data tidak berlabel pada awal pelatihan adalah 81,1% dan cenderung menurun seiring iterasi berlanjut. Oleh karena itu, sistem menerapkan mekanisme *best-weight restoration* dengan mengembalikan bobot model ke kondisi terbaik pada Iterasi 20 (*Acc UnLabeled*=81,42%). Grafik *loss* DEC selama 500 iterasi menunjukkan pola osilasi rapat yang merupakan karakteristik umum pelatihan DEC berbasis *mini-batch*, dengan tren *envelope* nilai *loss* yang menurun secara gradual dari sekitar 2,25 pada iterasi awal menjadi sekitar 1,65 pada akhir pelatihan. Fenomena *cluster drift* yang diamati pada iterasi lanjut mengindikasikan pentingnya mekanisme *best-weight restoration* untuk memilih model akhir yang optimal.

=== DEC TRAINING (ClusteringLayer Only) ===									
Trainable params : 2560									
Max iter : 500									
Update P interval: 20									
Beta CE : 1.0									
Iter	0	Sil=0.1423	AccU=81.1%	AccA=86.5%	Uniq=10	D=0.0000	0s		
Iter	20	Sil=0.1421	AccU=81.4%	AccA=86.2%	Uniq=10	D=0.0152	1s		
Iter	40	Sil=0.1424	AccU=80.7%	AccA=86.0%	Uniq=10	D=0.0354	2s		
Iter	60	Sil=0.1417	AccU=79.7%	AccA=85.3%	Uniq=10	D=0.0236	3s		
Iter	80	Sil=0.1398	AccU=75.3%	AccA=81.6%	Uniq=10	D=0.0506	3s		
Iter	100	Sil=0.1374	AccU=73.3%	AccA=79.1%	Uniq=10	D=0.0388	4s		
Iter	120	Sil=0.1348	AccU=73.0%	AccA=77.7%	Uniq=10	D=0.0236	5s		
Iter	140	Sil=0.1273	AccU=72.6%	AccA=76.2%	Uniq=10	D=0.0287	5s		
Iter	160	Sil=0.1203	AccU=70.6%	AccA=74.0%	Uniq=10	D=0.0337	6s		
Iter	180	Sil=0.1152	AccU=68.2%	AccA=72.0%	Uniq=10	D=0.0236	7s		
Iter	200	Sil=0.1116	AccU=67.9%	AccA=71.5%	Uniq=10	D=0.0118	8s		
Iter	220	Sil=0.1065	AccU=65.5%	AccA=70.0%	Uniq=10	D=0.0169	9s		
Iter	240	Sil=0.1003	AccU=64.9%	AccA=69.3%	Uniq=10	D=0.0152	10s		
Iter	260	Sil=0.0992	AccU=64.5%	AccA=68.8%	Uniq=10	D=0.0101	11s		
Iter	280	Sil=0.0963	AccU=63.9%	AccA=68.0%	Uniq=10	D=0.0101	12s		
Iter	300	Sil=0.0934	AccU=63.2%	AccA=67.5%	Uniq=10	D=0.0051	13s		
Iter	320	Sil=0.0926	AccU=62.2%	AccA=66.9%	Uniq=10	D=0.0051	14s		
Iter	340	Sil=0.0916	AccU=61.5%	AccA=66.4%	Uniq=10	D=0.0084	14s		
Iter	360	Sil=0.0861	AccU=60.1%	AccA=65.6%	Uniq=10	D=0.0101	15s		
Iter	380	Sil=0.0842	AccU=59.5%	AccA=64.6%	Uniq=10	D=0.0118	16s		
Iter	400	Sil=0.0824	AccU=58.4%	AccA=63.7%	Uniq=10	D=0.0118	16s		
Iter	420	Sil=0.0796	AccU=57.8%	AccA=62.7%	Uniq=10	D=0.0118	17s		
Iter	440	Sil=0.0725	AccU=57.8%	AccA=62.2%	Uniq=10	D=0.0051	18s		
Iter	460	Sil=0.0683	AccU=57.4%	AccA=61.4%	Uniq=10	D=0.0101	19s		
Iter	480	Sil=0.0626	AccU=56.4%	AccA=60.4%	Uniq=10	D=0.0101	19s		
Iter	500	Sil=0.0605	AccU=56.4%	AccA=59.9%	Uniq=10	D=0.0051	20s		
[OK] Best weights restored (AccU=81.42%)									
DEC selesai!									

Gambar 3. Hasil Training DEC

4.4 Evaluasi Metrik

Hasil evaluasi akhir model DEC setelah *best-weight restoration* ditampilkan pada Tabel 2.


Tabel 2. Hasil Evaluasi Akhir Model DEC

Metrik Evaluasi	Nilai
Akurasi Total (<i>Acc All</i>)	86,17%
Akurasi Data Berlabel (<i>Acc Labeled</i>)	90,91%
Akurasi Data Tidak Berlabel (<i>Acc UnLabeled</i>)	81,42%
<i>Silhouette Score</i> (256-d)	0,1421
Jumlah Klaster	10
Akurasi <i>Baseline classifier</i> (UnLabeled)	39,53%
Selisih <i>Acc UnLabeled</i> (DEC – Classifier)	+41,89%

Dari Tabel 2 dapat dilihat bahwa model DEC memperoleh *Acc UnLabeled* sebesar 81,42%, meningkat sebesar +41,89% dibandingkan *baseline classifier* EfficientNetV2B2 yang hanya mencapai 39,53%. Peningkatan signifikan ini membuktikan bahwa kombinasi inisialisasi *centroid* berbasis *class mean*, *soft assignment Student's t-distribution*, dan *joint loss (KL Divergence + SCCE)* mampu meningkatkan kemampuan model dalam mengelompokkan data yang tidak pernah diberi label selama pelatihan.

Berdasarkan hasil per klaster, performa model bervariasi antar kategori. Klaster 01 (Biologi) mencapai akurasi 100%, menunjukkan bahwa objek seperti kerang, kepiting, dan fosil memiliki karakteristik visual yang sangat khas. Klaster 04 (Keramik) dan Klaster 06 (Naskah Kuno) masing-masing mencapai akurasi 96,4% dan 97,8%, diikuti Klaster 05 (Kesenian) dan Klaster 07 (Numismatik) dengan akurasi di atas 96%. Klaster 00 (Arkeologi) memperoleh akurasi 88,1%, sedangkan Klaster 02 (Etnografi) dan Klaster 03 (Geologi) masing-masing mencapai 76,9% dan 70,0%. Akurasi terendah diperoleh Klaster 09 (Teknologika) sebesar 67,1%, dipengaruhi oleh variasi bentuk objek yang luas dan jumlah sampel yang relatif sedikit (60 citra).

4.5 Visualisasi t-SNE dan Loss Plot




Gambar 4. Hasil Visualisasi t-SNE

Visualisasi t-SNE dengan judul 'DEC | Mask=50% | AccU=81,4% | Sil=0,1421' menyajikan dua subplot berdampingan: *ground truth* dan hasil klasterisasi DEC. Pada subplot *ground truth*, beberapa kategori membentuk kelompok yang cukup terpisah, seperti kelompok koleksi etnografi dan geologi di sisi kiri atas, serta kelompok koleksi keramik di sisi kanan atas. Namun, beberapa kategori seperti koleksi etnografi, arkeologi, dan teknologika

tampak saling bertumpang tindih di bagian tengah plot, mengindikasikan kemiripan fitur visual yang tinggi antar kategori tersebut.

Subplot hasil klasterisasi DEC (kanan) menunjukkan pola pengelompokan yang secara umum konsisten dengan distribusi *ground truth*, terutama untuk kategori yang terpisah jelas. Tumpang tindih yang tersisa pada bagian tengah plot sejalan dengan nilai *Silhouette Score* yang relatif rendah (0,1421), namun akurasi UnLabeled tetap tinggi (81,4%), menandakan bahwa DEC mampu membedakan kategori secara fungsional meski batas antar klaster tidak sepenuhnya tajam di ruang 2D.



Gambar 5. Hasil Visualisasi *Loss Plot*

Gambar 5 menampilkan hasil visualisasi grafik *loss* DEC sepanjang 500 iterasi pelatihan DEC, sesuai dengan kode pada Gambar 5.26. Sumbu horizontal merepresentasikan iterasi (0 hingga 500), sedangkan sumbu vertikal merepresentasikan nilai total *loss* ($L_c + \lambda \cdot L_{scc}$). Grafik menunjukkan pola osilasi yang sangat rapat pada setiap iterasi, yang merupakan karakteristik umum pelatihan DEC berbasis *mini-batch* karena setiap *mini-batch* memiliki komposisi data berlabel dan tidak berlabel yang berbeda-beda, sehingga nilai *loss_ce* (yang hanya dihitung pada data berlabel dalam *batch* tersebut) bervariasi antar *batch*.

Secara keseluruhan, dapat diamati tren umum (*envelope*) dari grafik: pada iterasi awal (0-50), nilai *loss* berada pada rentang yang relatif tinggi dan lebar (sekitar 1,8 hingga 2,25), kemudian menyempit dan menurun pada iterasi 50-150 menjadi sekitar 1,9 hingga 2,0, sebelum akhirnya pada iterasi 150 ke atas *envelope* tersebut justru melebar kembali dan trennya menurun secara gradual, dengan batas bawah mencapai sekitar 1,65 dan batas atas tetap mendekati 2,0 pada akhir iterasi (iterasi 500). Pola ini sejalan dengan fenomena penurunan akurasi dan *Silhouette Score* yang teramati pada Gambar 3, yang mengindikasikan bahwa meskipun nilai *loss* total cenderung menurun, hal tersebut tidak selalu berbanding lurus


dengan peningkatan kualitas klasterisasi (*Cluster drift*), sehingga mekanisme *best-weight restoration* berdasarkan AccU pada iterasi tertentu (Iter 20) menjadi penting untuk memilih model akhir.

4.6 Implementasi Interface



Gambar 6. Halaman Utama


Halaman utama klasterisasi merupakan halaman awal yang digunakan pengguna untuk melakukan proses pengelompokan citra benda arkeologi secara otomatis. Pada halaman ini tersedia menu navigasi yang terdiri dari Klasterisasi, Hasil Klasterisasi, dan Informasi Klaster untuk memudahkan pengguna mengakses berbagai fitur yang tersedia. Bagian utama halaman menyediakan fitur unggah gambar yang mendukung format JPG, JPEG, PNG, dan HEIC sebagai *input* sistem. Setelah citra diunggah, sistem akan melakukan *Preprocessing*, ekstraksi fitur menggunakan EfficientNetV2B2, dan proses klasterisasi menggunakan metode *Semi-supervised Deep Embedded Clustering* (DEC). Selain itu, halaman ini juga menampilkan petunjuk penggunaan untuk membantu pengguna dalam melakukan proses klasterisasi secara mudah dan terarah.



Gambar 7. Halaman Hasil Klasterisasi

Halaman hasil klasterisasi digunakan untuk menampilkan hasil pengelompokan citra benda arkeologi yang telah diproses oleh model *Semi-supervised Deep Embedded Clustering* (DEC). Pada halaman ini ditampilkan informasi klaster yang diperoleh, yaitu Klaster II yang

dikaitkan dengan kategori Koleksi Biologi berdasarkan hasil pemetaan kluster. Selain itu, sistem menampilkan citra yang diunggah pengguna sebagai objek yang dianalisis. Pada bagian kanan halaman tersedia visualisasi distribusi data menggunakan proyeksi dua dimensi yang menunjukkan posisi data terhadap kluster-kluster lain pada ruang *embedding*. Visualisasi ini membantu pengguna memahami hubungan kemiripan antara citra yang diuji dengan koleksi museum lainnya.



Gambar 8. Halaman Informasi Kluster

Halaman informasi kluster digunakan untuk menampilkan deskripsi dan karakteristik setiap kluster yang terbentuk dari proses *Semi-supervised Deep Embedded Clustering* (DEC). Pada halaman ini, setiap kluster disajikan dalam bentuk kartu informasi yang memuat nama kluster, kategori koleksi museum yang diwakili, deskripsi singkat mengenai karakteristik koleksi, contoh objek yang termasuk dalam kluster tersebut, serta beberapa contoh citra koleksi. Selain itu, pengguna dapat melihat jumlah data yang termasuk dalam masing-masing kluster melalui tombol koleksi yang tersedia. Halaman ini bertujuan untuk membantu pengguna memahami makna dan isi dari setiap kluster sehingga hasil pengelompokan yang dihasilkan sistem dapat diinterpretasikan dengan lebih mudah.

4.7 Analisis Kelebihan dan Keterbatasan

Kelebihan utama metode SDEC yang diterapkan antara lain: (1) kemampuan memanfaatkan data tidak berlabel secara efektif, terbukti dari peningkatan *Acc UnLabeled* sebesar 41,89% dibandingkan baseline; (2) inisialisasi *centroid* berbasis *class mean* memberikan titik awal yang representatif sehingga konvergensi lebih stabil; (3) sistem dapat digunakan oleh kurator museum tanpa keahlian teknis mendalam melalui antarmuka Streamlit. Keterbatasan utama meliputi: (1) nilai *Silhouette Score* yang relatif rendah

(0,1421) menunjukkan masih adanya tumpang tindih di ruang *embedding*, khususnya pada kategori dengan kemiripan visual tinggi; (2) kategori dengan jumlah sampel sedikit seperti Senjata (12 citra) dan Geologi (21 citra) memperoleh akurasi yang lebih rendah; (3) model tidak dapat belajar dari kategori baru tanpa proses pelatihan ulang.

5. KESIMPULAN

Sistem klusterisasi citra benda arkeologi berbasis *Semi-supervised Deep Embedded Clustering* (SDEC) berhasil dirancang dan diimplementasikan menggunakan *backbone* EfficientNetV2B2 yang menghasilkan *head embedding* berdimensi 256 dengan final validation accuracy 86,7%. Inisialisasi *centroid* berbasis *class mean* memberikan pengelompokan awal yang representatif, dan optimasi DEC dengan *joint loss* (*KL Divergence* + SCCE) berhasil meningkatkan *Acc UnLabeled* menjadi 81,42%, meningkat sebesar 41,89% dibandingkan *baseline classifier* EfficientNetV2B2 yang hanya mencapai 39,53%. Hasil *Acc All* sebesar 86,17% dan *Acc Labeled* sebesar 90,91% membuktikan efektivitas pendekatan *semi-supervised* dalam memanfaatkan data berlabel terbatas untuk meningkatkan kualitas klusterisasi citra arkeologi.

Sistem telah diimplementasikan dalam antarmuka Streamlit yang memungkinkan kurator museum mengelompokkan dan memvisualisasikan koleksi benda arkeologi secara interaktif, sehingga berkontribusi nyata dalam mendukung proses digitalisasi koleksi arkeologi di Sulawesi Tenggara.

Penelitian selanjutnya disarankan untuk memperluas dataset, mengeksplorasi *backbone* alternatif seperti Vision Transformer (ViT), serta mengintegrasikan metadata arkeologi ke dalam sistem untuk memperkaya informasi yang tersedia bagi kurator dan peneliti

DAFTAR PUSTAKA

- [1] S. Zulaikha and A. R. Fahky, "Menbud: Museum Indonesia tingkatkan inklusivitas dengan teknologi," 2025, [Online]. Available: <https://www.antaranews.com/berita/4826685/menbud-museum-indonesia-tingkatkan-inklusivitas-dengan-teknologi>
- [2] A. Senong, AbduRidlo, M., Baihaqi, I.,

- Anshori, A., Yunita, I., & Laely and E. Sukarelawati, "Museum Provinsi Sultra miliki 7.000 koleksi benda bersejarah," 2024, [Online]. Available: <https://www.antaranews.com/berita/4359307/museum-provinsi-sultra-miliki-7000-koleksi-benda-bersejarah>
- [3] M. Ridlo, I. Baihaqi, A. Anshori, I. Yunita, and O. Laely, "Pendampingan Digitalisasi Berbasis Katalog Museum Alas Trik Desa Kedungbocok Kecamatan Tarik Kabupaten Sidoarjo," pp. 33–41.
- [4] T. Winterbottom, A. Leone, and N. Al Moubayed, "OPEN A deep learning approach to fight illicit trafficking of antiquities using artefact instance classification," *Sci. Rep.*, no. 0123456789, pp. 1–12, 2022, doi: 10.1038/s41598-022-15965-2.
- [5] J. Enguehard and S. Member, "Semi-Supervised Learning With Deep Embedded Clustering for Image Classification and Segmentation," *IEEE Access*, vol. 7, pp. 11093–11104, 2019, doi: 10.1109/ACCESS.2019.2891970.
- [6] Z. Cheng, F. Li, J. Wang, and Y. Qian, "Deep Embedding Clustering Driven by Sample Stability".
- [7] A. Resler, R. Yeshurun, F. Natalio, and R. Giryes, "and archaeological community detection," no. 2021, doi: 10.1057/s41599-021-00970-z.
- [8] J. Xie, R. Girshick, A. Farhadi, A. L. I. Cs, and W. Edu, "Unsupervised Deep Embedding for Clustering Analysis," vol. 48, 2016.
- [9] B. Ghogh, A. Ghodsi, A. L. I. Ghodsi, U. Ca, and M. Crowley, "with Gaussian and Student-t Distributions : Tutorial and Survey," pp. 1–14.
- [10] Y. Wang *et al.*, "USB: A Unified Semi-supervised Learning Benchmark for Classification," no. NeurIPS, pp. 1–24, 2022.
- [11] J. Enguehard, P. O'Halloran, and A. Gholipour, "Semi Supervised Learning with Deep Embedded Clustering for Image Classification and Segmentation.," *IEEE access Pract. Innov. open Solut.*, vol. 7, pp. 11093–11104, 2019, doi: 10.1109/ACCESS.2019.2891970.
- [12] M. Tan and Q. V Le, "EfficientNetV2 : Smaller Models and Faster Training," 2021.
- [13] C. Szegedy and S. G. Com, "Batch Normalization : Accelerating Deep Network Training by Reducing Internal Covariate Shift," vol. 37, 2015.
- [14] G. Vardakas, "D EEP C LUSTERING U SING THE S OFT S ILHOUETTE S CORE :," 2024.
- [15] Y. Qin, S. Ding, L. Wang, and Y. Wang, "Research Progress on Semi-Supervised Clustering," *Cognit. Comput.*, vol. 11, no. 5, pp. 599–612, 2019, doi: 10.1007/s12559-019-09664-w.
- [16] G. Legate, L. Caccia, N. Bernier, E. Oyallon, and E. Belilovsky, "Guiding The Last Layer in Federated Learning with Pre-Trained Models," no. NeurIPS, pp. 1–17, 2023.