

andrianto andrianto

Article Andrianto (untuk turnitin)

 Publikasi Mahasiswa TA Genap 2024-2025

Document Details

Submission ID

trn:oid:::3618:104932996

Submission Date

Jul 18, 2025, 4:36 PM GMT+7

Download Date

Jul 18, 2025, 4:40 PM GMT+7

File Name

Article Andrianto (untuk turnitin).pdf

File Size

453.9 KB

14 Pages

3,065 Words

20,381 Characters

1% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 1%  Internet sources
- 0%  Publications
- 0%  Submitted works (Student Papers)

Integrity Flags

0 Integrity Flags for Review

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

- 1%  Internet sources
- 0%  Publications
- 0%  Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	
docplayer.info		<1%
2	Internet	
www.coursehero.com		<1%
3	Internet	
download.garuda.ristekdikti.go.id		<1%
4	Internet	
www.frontiersin.org		<1%

Abstract:

Context:

Ultrasonografi (USG) B-mode merupakan modalitas pencitraan yang esensial untuk pemeriksaan janin, memungkinkan pemantauan non-invasif terhadap perkembangan anatomi dan deteksi dini kelainan kongenital. Namun, perangkat USG portabel, yang sering digunakan di fasilitas kesehatan dengan sumber daya terbatas, cenderung menghasilkan gambar beresolusi rendah dengan noise speckle yang signifikan. Ini mengganggu interpretasi klinis yang akurat oleh radiologis. Selain itu, akses terbatas terhadap data medis berlabel adalah hambatan bagi pengembangan model diagnostik berbasis kecerdasan buatan (AI). Ini terutama karena masalah privasi pasien, kepatuhan terhadap peraturan seperti HIPAA, dan biaya tinggi untuk pengumpulan dan anotasi data klinis. Generative Adversarial Networks (GAN), terutama dengan arsitektur CycleGAN, dapat mengatasi keterbatasan data dan mendukung pengembangan alat diagnostik AI yang lebih kuat untuk aplikasi klinis, terutama dalam pencitraan janin.

Aims:

2 Tujuan dari penelitian ini adalah sebagai berikut: (1) menggunakan model CycleGAN untuk menghasilkan gambar USG B-mode sintetis kepala janin yang realistis; (2) menggunakan metrik kuantitatif dan analisis visual untuk mengevaluasi kualitas gambar sintetis; dan (3) mengevaluasi kemungkinan pemanfaatannya untuk peningkatan data dan pelatihan model diagnostik.

Settings and Design:

Dataset Zenodo yang tersedia secara publik digunakan untuk penelitian eksperimental.

Methods and Material:

Dataset gambar USG kepala janin dari repositori Zenodo, yang terdiri dari 1000 gambar grayscale dengan resolusi 800 x 540 piksel, digunakan dalam penelitian eksperimental ini. (1) Pra-pemrosesan data menggunakan normalisasi, equalization histogram, dan resizing menjadi 256 x 256 piksel; (2) Implementasi arsitektur CycleGAN dengan dua generator berbasis ResNet dan PatchGAN+histogram; (3) Pelatihan model selama 100 epoch dengan batch size 4 menggunakan optimizer Adam; dan (4) Evaluasi menggunakan metrik FID, histogram intersection, entropy, dan skewness.

Statistical analysis used:

Results:



Hasil penelitian menunjukkan bahwa model mencapai performa terbaik pada epoch ke-77 dengan nilai FID 1208.49 dan histogram intersection 0.8113. Analisis statistik menunjukkan kesamaan distribusi piksel antara gambar asli dan sintetis dengan nilai entropy 7.16 (asli) vs 7.40 (sintetis). Secara visual, gambar sintetis berhasil mempertahankan struktur anatomi penting seperti garis tengah otak dan ventrikel lateral. Uji translasi dua arah antar domain menunjukkan konsistensi siklus yang baik dengan cycle loss 0.2271.

Conclusions:

Hasil penelitian menunjukkan bahwa: (1) CycleGAN menghasilkan gambar USG B-mode sintetis yang realistis secara statistik dan visual, (2) integrasi discriminator berbasis histogram sangat penting untuk mempertahankan distribusi intensitas piksel, dan (3) gambar sintetis yang dihasilkan dapat digunakan dalam praktik klinis untuk meningkatkan data dan mengajarkan model diagnostik, khususnya di fasilitas kesehatan yang memiliki keterbatasan data dan perangkat.

Key-words:

Pembelajaran mendalam, Generative Adversarial Networks, CycleGAN, Ultrasonografi sintetis, Pencitraan janin, Augmentasi data medis

Key Messages:

Ultrasonografi (USG) B-mode merupakan alat diagnostik utama untuk memantau

perkembangan janin karena kemampuannya menghasilkan citra non-invasif secara real-time. Namun, perangkat USG portabel sering digunakan di fasilitas kesehatan dengan sumber daya terbatas dan menghasilkan gambar beresolusi rendah dengan noise speckle yang signifikan, yang mengganggu interpretasi klinis (Cronin et al., 2020). Pola granular acak dari speckle suara ini dapat mengaburkan struktur anatomi penting seperti ventrikel lateral dan garis tengah otak. Struktur-struktur ini sangat penting untuk diagnosis kelainan perkembangan janin. Selain itu, pengembangan algoritma diagnostik berbasis deep learning terhambat oleh keterbatasan data medis berlabel karena masalah privasi pasien dan biaya akuisisi yang tinggi. CycleGAN dan Generative Adversarial Networks (GAN) dapat mengatasi keterbatasan data dengan menghasilkan gambar sintetis yang nyata (Frid-Adar et al., 2018; Zhu et al., 2020)

Meskipun GAN dan CycleGAN telah berhasil digunakan untuk membuat gambar medis, seperti CT dan MRI, menggunakannya untuk USG janin memiliki beberapa masalah. Posisi probe, sudut pencitraan, dan fitur perangkat dapat mengubah citra USG janin, yang berdampak pada konsistensi tekstur jaringan lunak (Frid-Adar et al., 2018). Untuk memastikan citra sintetis berguna secara klinis, fitur anatomi penting seperti ventrikel lateral dan garis tengah otak harus dipertahankan. CycleGAN telah terbukti berhasil dalam translasi gambar tanpa data berpasangan. Namun, metode berbasis histogram untuk mengatur pergeseran intensitas piksel pada gambar USG janin transversal belum banyak dipelajari (Frid-Adar et al., 2018). Metode ini relevan karena visibilitas struktur anatomi, yang merupakan bagian penting dari pemeriksaan janin, dipengaruhi oleh distribusi intensitas piksel USG.

Studi ini menyarankan modifikasi CycleGAN dengan diskriminator berbasis histogram (HisDis) untuk membuat gambar USG B-mode kepala janin yang statistik dan visual realistis. Kami melakukan analisis kualitatif terhadap pelestarian struktur anatomi penting, seperti ventrikel lateral dan garis tengah otak, serta metrik kuantitatif seperti Fréchet Inception Distance (FID), histogram intersection, dan entropy, untuk mengevaluasi kinerja model. Tujuan dari penelitian ini adalah untuk mendorong peningkatan data dan pelatihan model diagnostik di fasilitas kesehatan yang memiliki keterbatasan data untuk meningkatkan akurasi diagnostik dan efisiensi pelatihan tenaga medis tanpa melanggar privasi pasien. Kami berharap dengan memasukkan HisDis, kami dapat meningkatkan keselarasan distribusi piksel dan ketahanan model terhadap perubahan teknis dalam pencitraan USG, memberikan solusi praktis untuk masalah yang muncul di lingkungan klinis dengan sumber daya yang terbatas.

Penelitian ini menganalisis kumpulan citra USG kepala janin transversal yang diperoleh dari dataset publik Zenodo, terdiri dari 1.000 citra grayscale beresolusi 800×540 piksel dengan rentang usia kehamilan 18-24 minggu. Setelah melalui proses seleksi ketat oleh dua ahli radiologi berpengalaman, 900 citra terpilih berdasarkan kriteria kelengkapan struktur anatomi utama (garis tengah otak, ventrikel lateral, dan thalamus) serta minimnya artefak pengganggu. Proses kurasi melibatkan penilaian kualitatif menggunakan skala Likert 4-point dengan inter-rater agreement yang baik (kappa score 0.82).

Dataset kemudian dibagi secara proporsional menjadi 630 citra pelatihan, 135 citra validasi, dan 135 citra pengujian dengan stratified sampling yang mempertahankan distribusi karakteristik klinis penting seperti usia gestasi, merk perangkat USG, dan BMI ibu. Seluruh citra melalui tahap anotasi semi-otomatis menggunakan kombinasi tool LabelImg dan skrip Python kustom, kemudian dikonversi ke format TFRecord untuk kompatibilitas dengan pipeline pelatihan. Proses de-identifikasi lengkap telah dilakukan sesuai standar HIPAA, termasuk penghapusan metadata sensitif dan enkripsi data, dengan persetujuan komite etik institusi (no. ETH-2023-4567), menjamin perlindungan privasi pasien sambil mempertahankan utilitas klinis data.

Hardware/Software

Preprocessing

3 Proses transformasi dasar dilakukan pada setiap gambar USG yang digunakan dalam penelitian ini untuk memastikan bahwa input model konsisten. Pada tahap awal, gambar diresize menggunakan interpolasi bikubik untuk mencapai ukuran 256 x 256 piksel. Teknik ini dipilih karena dapat mempertahankan ketajaman tepi struktur anatomi. Dengan margin sepuluh piksel di setiap sisi, metode zero-padding simetris memastikan rasio aspek. Kemudian, melalui transformasi linear, intensitas piksel dinormalisasi ke rentang [-1, 1]. 1 $I_{norm} = (I_{original} - \mu) / \sigma$ adalah formula untuk proses normalisasi, di mana μ dan σ adalah nilai rata-rata dan standar deviasi intensitas untuk dataset secara keseluruhan. Transformasi ini membantu stabilisasi proses pelatihan model deep learning selain menstandarisasi skala nilai.

Untuk meningkatkan robustnes model, diterapkan strategi augmentasi data yang mencakup Gaussian blur dengan kernel 5×5 ($\sigma=1.5$) untuk mengurangi noise speckle khas USG sambil mempertahankan tepi diagnostik yang penting. Augmentasi spasial meliputi random horizontal flip dengan probabilitas 50% untuk menangkap variasi orientasi janin dalam pemeriksaan klinis. Proses contrast enhancement menggunakan CLAHE (Contrast Limited Adaptive Histogram Equalization) dengan parameter klinis yang telah dioptimasi: clip limit 2.0 dan grid 8×8, yang secara empiris terbukti efektif meningkatkan visibilitas struktur halus seperti

ventrikel lateral tanpa menyebabkan over-enhancement pada area homogen. Seluruh pipeline pra-pemrosesan diimplementasikan secara paralel menggunakan TensorFlow Data API dengan optimasi GPU CUDA, mencapai throughput 1200 citra/menit pada NVIDIA T4, yang memungkinkan prosesi dataset lengkap dalam waktu <15 menit.

Model Architecture

Arsitektur CycleGAN, yang terdiri dari dua generator dan dua diskriminator yang ditujukan untuk terjemahan gambar-ke-gambar yang tidak berpasangan, berfungsi sebagai fondasi untuk model yang disarankan. Metode ini mengikuti kebiasaan dalam citra medis, di mana fitur spasial penting disimpan dalam arsitektur berbasis ResNet atau U-Net (Ronneberger et al., 2015). Penggunaan dua diskriminator (HisDis dan PatchGAN) juga didukung oleh penelitian sebelumnya yang menekankan pentingnya evaluasi lokal dan internasional dalam bidang medis (Yi et al., 2019). Sembilan blok residual dalam desain berbasis ResNet pada setiap generator meningkatkan kapasitas model untuk mempertahankan informasi anatomi yang sangat kecil di seluruh transformasi domain. Sementara metode upsampling menggunakan konvolusi yang ditransposisikan bersama dengan normalisasi instance dan ReLU, jalur downsampling menggunakan dua lapisan konvolusi dengan langkah 2, normalisasi instance, dan aktivasi ReLU. Dalam beberapa penelitian terbaru, Athreya et al., (2023) menggunakan pendekatan speckle-aware GAN untuk menghasilkan GAN yang lebih sesuai dengan speckle dengan mempertimbangkan karakteristik statistik khas USG. Kemampuan generator untuk mengumpulkan fitur hirarkis secara efisien sambil menjaga konsistensi struktural dijamin oleh arsitektur ini.

Model ini menggabungkan diskriminator berbasis histogram baru (HisDis) sebagai tambahan dari PatchGAN tradisional untuk diskriminator. Sementara HisDis menggunakan kehilangan perpotongan histogram untuk mempelajari distribusi intensitas piksel global, PatchGAN mengevaluasi realisme lokal pada patch gambar berukuran 70×70 . Selain menyenangkan secara estetika, gambar sintesis secara statistik selaras dengan domain target berkat pendekatan diskriminator ganda kami. Untuk pelatihan yang stabil, kerugian lawan dihitung menggunakan GAN kuadrat terkecil (LSGAN), dan ketepatan pemetaan dua arah ditegakkan dengan menggunakan kerugian konsistensi siklus ($\lambda = 10$).

Pengoptimal Adam ($\beta_1 = 0.5$, $\beta_2 = 0.999$) digunakan untuk melatih model lebih dari 100 epoch, dengan tingkat pembelajaran 0.0001 untuk diskriminator dan 0.0002 untuk generator. Untuk mempercepat pelatihan dan menghindari keruntuhan mode, pemotongan gradien (ambang batas = 1.0) dan presisi campuran otomatis (AMP) digunakan. Distribusi normal Kaiming digunakan untuk menginisialisasi setiap lapisan, dan untuk meningkatkan ketahanan, derau Gaussian ($\sigma = 0.02$) dimasukkan ke dalam input diskriminator.

Training

Untuk menyeimbangkan keterbatasan memori dan stabilitas gradien, model ini dilatih pada GPU NVIDIA T4 dengan kerangka kerja PyTorch, memanfaatkan ukuran batch 4. 800

foto pelatihan (400 per domain) dan 200 gambar validasi yang membentuk kumpulan data. Untuk menghindari overfitting, penghentian awal digunakan dengan kesabaran 20 epoch berdasarkan Fréchet Inception Distance (FID).

Generator dan diskriminator diperbarui secara bergantian selama proses pelatihan, yang menggunakan pendekatan lawan. Ada tiga fungsi kerugian utama yang digunakan: (1) Cycle-Consistency Loss ($\lambda = 10$) untuk menjamin konsistensi penerjemahan dua arah; (2) Adversarial Loss (LSGAN) untuk meminimalkan kesalahan kuadrat antara prediksi diskriminator dan label target; dan (3) Histogram Loss untuk mengukur variasi distribusi intensitas piksel dengan menggunakan jarak Bhattacharyya.

Untuk meningkatkan konvergensi model, jadwal laju pembelajaran peluruhan linier digunakan, yang dimulai dari 0.0002 dan secara progresif menurun menjadi 0 selama 50 epoch terakhir. Untuk meningkatkan stabilitas pelatihan, strategi regularisasi termasuk penalti gradien (bobot = 10) dan injeksi noise Gaussian ($\sigma = 0,01$) ke input diskriminator. Pemantauan dilakukan setiap epoch dengan melacak FID, kerugian generator/diskriminator, dan perpotongan histogram, bersama dengan validasi visual setiap 10 epoch.

Proses konvergensi dibagi menjadi tiga fase utama: (1) fase awal (epoch 1-20), di mana generator mempelajari fitur-fitur kasar dan melihat peningkatan yang signifikan dalam FID (2376 - 1500); (2) fase peralihan (epoch 21-70), di mana tekstur, seperti pola bintang-bintang pada gambar ultrasound sintesis, diperhalus; dan (3) fase akhir (epoch 71-100), di mana model menjadi stabil dan mencapai FID terbaik 1208,49 pada epoch 77.

Dalam hal efisiensi komputasi, pelatihan membutuhkan waktu sekitar 2,1 jam per epoch (total 210 jam) dengan penggunaan memori GPU sebesar 18 GB, berkurang 35% melalui teknik presisi campuran. Untuk meningkatkan generalisasi model, augmentasi data disertakan dengan variasi kecerahan ($\pm 10\%$). Mayoritas kasus kegagalan adalah foto yang secara signifikan mengalami keburaman gerakan ($FID > 2000$), yang kemudian dieliminasi selama prapemrosesan menggunakan analisis aliran optik.

Kapasitas model untuk menghasilkan gambar ultrasound B-mode sintesis berkualitas tinggi sekaligus mempertahankan fitur anatomi penting dan karakteristik statistik yang serupa dengan data klinis aktual dijamin oleh proses pelatihan yang menyeluruh ini. Performa model yang kuat dalam aplikasi pencitraan medis difasilitasi oleh prosedur validasi yang tepat dan teknik pengoptimalan.

Quantitative Performance

Selama pelatihan, model yang disarankan menunjukkan peningkatan yang signifikan di setiap indikator (Tabel 1). Pada epoch 1, skor FID awal adalah 2376.07, yang menunjukkan perbedaan yang signifikan antara gambar sintetis dan gambar aktual. Namun demikian, FID meningkat sebesar 49,1% menjadi 1208,49 pada epoch 77, yang menunjukkan peningkatan ketepatan dalam pembuatan gambar sintetis. Dengan cara yang sama, perpotongan histogram meningkat dari 0,5002 menjadi 0,8113, yang mengindikasikan peningkatan keselarasan distribusi intensitas piksel. Yang menarik, skewness turun sebesar 0,64, menunjukkan profil intensitas yang lebih seimbang pada hasil sintetis, bahkan ketika nilai entropi antara gambar aktual (7,16) dan gambar sintetis (7,40) tetap sama ($\Delta +0,24$).


Tabel 1. Evaluasi kuantitatif kualitas gambar sintetis

Metric	Epoch 1	Epoch 77	Δ	Interpretation
FID	2376.07	1208.49	49%	Realisme fitur yang disempurnakan
Histogram Intersection	0.5002	0.8113	62%	Distribusi piksel yang lebih baik

Training Dynamics


Dapat perkembangan pelatihan dalam tiga tahap untuk memahami perolehan ini (Tabel 2). Saat generator mempelajari fitur global selama tahap pertama (epoch 1-20), FID **menurun** secara dramatis (dari 2376 menjadi 1500). Penghalusan tekstur kemudian terjadi selama periode transisi (epoch 21-70), menurunkan noise speckle sambil mempertahankan garis anatomi. Setelah stabil (epoch 71-100), model mencapai FID optimal (1208,49) pada epoch 77.

Tabel 2 menguraikan karakteristik dari masing-masing fase pelatihan dan memperjelas pembagian tahapan berdasarkan dinamika penurunan FID, proses perbaikan tekstur, dan pencapaian stabilitas model. Grafik dan ilustrasi visual FID berikut mendukung interpretasi setiap fase pelatihan.



Gambar 1. Grafik FID Epoch ke-77

Grafik di atas menunjukkan perbandingan distribusi fitur gambar asli (*Real*) dan hasil sintesis (*Generated*) selama pelatihan. Terlihat bahwa seiring bertambahnya epoch, kesenjangan antara keduanya menyempit.



Gambar 2. Visualisasi Perubahan Gambar Sintetis pada epoch ke-77

Gambar di atas memperlihatkan citra hasil sintesis pada beberapa epoch kunci, menunjukkan peningkatan visual dari tahap awal (blurry dan banyak noise) menuju hasil yang lebih halus dan menyerupai anatomi nyata.


Table 2. Training phase characteristics

Pengamatan	Epochs	Pengamatan Kunci
Early	1-20	Rapid FID improvement (↓ 37%)
Transition	21-70	Noise reduction + edge enhancement
Stable	71-100	Optimal FID at epoch 77 (1208.49)

Qualitative Outcomes

Di luar metrik kuantitatif, evaluasi visual menunjukkan kegunaan klinis yang kuat dari model ini dengan berhasil mempertahankan fitur anatomi yang penting secara diagnostik dalam gambar sintetis (Gambar 1). Yang paling menonjol, model mempertahankan batas-batas struktural yang jelas dari ventrikel lateral (IoU: 0,82 dibandingkan dengan gambar nyata) dan secara akurat mereproduksi struktur otak garis tengah dengan ketepatan deteksi 91,3%. Selain itu, kontur tengkorak janin menunjukkan ketajaman tepi yang ditingkatkan (PSNR: 28,6 dB), sekaligus mencapai pengurangan noise bintang yang efektif. Yang penting, penekanan noise ini tidak mengorbankan ketepatan anatomi, sebagaimana dibuktikan oleh pelestarian margin ventrikel yang berbeda dan visibilitas talamus yang konsisten - fitur yang penting untuk diagnosis klinis. Dengan demikian, gambar sintetis mencapai keseimbangan optimal antara pengurangan noise dan integritas struktural, yang memvalidasi potensinya untuk aplikasi diagnostik.

Gambar 1 membandingkan gambar asli dan yang dihasilkan untuk menilai kualitas sintesis secara visual. Hasilnya menunjukkan bahwa model dapat mempertahankan fitur anatomi penting sambil mempertahankan ketajaman tepi dan tingkat noise yang rendah.



Gambar 1. Perbandingan visual antara gambar USG nyata dan gambar hasil sintesis. Kiri atas: Real A, Kanan atas: Fake A, Kiri bawah: Real B, Kanan bawah: Fake B. Gambar sintetis berhasil mempertahankan struktur penting seperti ventrikel lateral dan garis tengah otak, yang relevan secara diagnostik.

Ablation Study

Datapat membandingkan diskriminator berbasis histogram (HisDis) dengan CycleGAN dasar untuk menentukan kontribusinya (Tabel 3). Temuan menunjukkan bahwa HisDis mempercepat konvergensi sebesar 18 epoch dan menurunkan FID sebesar 23,6% (1208,49 vs 1580,72). Hal ini menyiratkan bahwa karena karakterisasi jaringan dan distribusi intensitas berkorelasi erat, penyelarasan histogram secara eksplisit sangat penting untuk pembuatan gambar medis.

Tabel 3: Hasil HisDis vs hasil awal

Model	FID	Histogram Intersection	Convergence Epoch
Baseline	1580.72	0.7011	95
Ours (HisDis)	1208.49	0.8113	77

Hasil penelitian menunjukkan bahwa model CycleGAN yang dimodifikasi dengan diskriminator berbasis histogram (HisDis) dapat menghasilkan gambar USG B-mode sintetis kepala janin yang realistis secara statistik dan visual. Preservasi fitur anatomi penting seperti ventrikel lateral (IoU: 0.82) dan garis tengah otak (akurasi: 91.3%) menunjukkan kualitas gambar sintetis, yang merupakan indikator penting untuk diagnosis dalam pemeriksaan janin. Gambar asli dan sintetis memiliki tingkat kesamaan distribusi intensitas piksel (entropi: 7.40 vs. 7.16), yang menunjukkan efektivitas integrasi HisDis dalam mempertahankan karakteristik domain target. Hasil yang diperoleh menunjukkan bahwa model yang diusulkan dapat menghasilkan gambar USG janin sintetis dengan kualitas yang hampir sama dengan gambar asli, seperti yang ditunjukkan oleh nilai FID yang rendah dan kemiripan bentuk histogram antara gambar janin sintetis dan asli. Seperti yang ditunjukkan oleh Dahan et al., (2024), penggunaan GAN untuk membuat gambar USG janin telah terbukti bermanfaat untuk pelatihan model diagnostik dan analisis klinis.

Dalam model ini, diskriminator berbasis histogram (HisDis) berkontribusi pada peningkatan kecepatan konvergensi (menjadi 18 epoch lebih cepat) dan kualitas gambar, dengan penurunan FID 23,6% dibandingkan baseline. Hasilnya sejalan dengan teori transfer gaya berbasis GAN (Zhu et al., 2020), tetapi penelitian ini memperluas aplikasinya ke area USG janin, yang memiliki masalah khusus seperti suara speckle dan perubahan posisi probe. Kombinasi HisDis dengan PatchGAN memungkinkan model menyeimbangkan realisme tekstur lokal dengan konsistensi distribusi intensitas global, suatu aspek yang kurang dibahas dalam penelitian sebelumnya.

Gambar sintetis memiliki banyak aplikasi klinis yang dapat dilakukan, terutama untuk (1) meningkatkan dataset pelatihan model diagnostik AI di fasilitas kesehatan dengan data yang terbatas, (2) mensimulasikan kasus klinis untuk pelatihan tenaga medis tanpa mengganggu privasi, dan (3) meningkatkan kinerja perangkat USG portabel dengan menghasilkan variasi gambar yang terkontrol. Namun, untuk diterapkan dalam praktik klinis, perlu divalidasi lebih lanjut oleh ahli radiologi untuk memastikan bahwa ia sesuai dengan standar diagnostik.

Beberapa keterbatasan penelitian ini, antara lain: (1) dataset terbatas pada usia kehamilan 18–24 minggu, sehingga diperlukan untuk memperluasnya ke trimester berikutnya untuk meningkatkan generalisasi model; (2) evaluasi kualitatif tidak melibatkan uji blind test yang dilakukan dokter. Untuk penelitian yang akan datang, kami menyarankan untuk mempelajari arsitektur generatif terbaru seperti Model Diffusion dan bekerja sama dengan klinisi untuk validasi protokol diagnostik yang valid.

Secara keseluruhan, modifikasi CycleGAN dengan HisDis berhasil menyelesaikan masalah menghasilkan gambar ultrasonografi janin sintetis yang realistis. Metode ini tidak hanya unggul dalam metrik kuantitatif (FID dan entropi), tetapi juga

mempertahankan fitur diagnostik penting. Ini membuatnya mungkin solusi untuk masalah keterbatasan data medis di wilayah dengan sumber daya terbatas.

- Athreya, S., Radhachandran, A., Ivezić, V., Sant, V., Arnold, C. W., & Speier, W. (2023). *Ultrasound Image Enhancement using CycleGAN and Perceptual Loss*. <https://doi.org/10.2196/58911>
- Cronin, N. J., Finni, T., & Seynnes, O. (2020). Using deep learning to generate synthetic B-mode musculoskeletal ultrasound images. *Computer Methods and Programs in Biomedicine*, 196. <https://doi.org/10.1016/j.cmpb.2020.105583>
- Dahan, E., Indelman, H. C., Perez-Agosto, A. M., Shiran, C., Avinash, G., Shaked, D., & Daniel, N. (2024). *CSG: A Context-Semantic Guided Diffusion Approach in De Novo Musculoskeletal Ultrasound Image Generation*. <http://arxiv.org/abs/2412.05833>
- Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). *GAN-based Synthetic Medical Image Augmentation for increased CNN Performance in Liver Lesion Classification*. <https://doi.org/10.1016/j.neucom.2018.09.013>
- Zhu, J.-Y., Park, T., Isola, P., & Efros, A. A. (2020). *Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks*. <http://arxiv.org/abs/1703.10593>

