

Komparasi *Deep Learning Convolutional Neural Network* (CNN) dan *Deep Learning CNN- Support Vector Machine* (SVM) untuk Identifikasi Tumor Otak dan Payudara

Siti Nur Khalisha, Pandji Triadyaksa*, Ngurah Ayu Ketut Umiati

Departemen Fisika, Fakultas Sains dan Matematika, Universitas Diponegoro, Jalan Prof Jacob Rais Tembalang, Semarang-50275, Indonesia

Info Artikel

Histori Artikel:

Diajukan: 7 Januari 2026
Direvisi: 5 Mei 2026
Diterima: 31 Juli 2026

Kata kunci:

Identifikasi
Performa
Res-Net-50
Tumor

Keywords:

Identification
Performance
Res-Net-50
Tumor

Penulis Korespondensi:

Pandji Triadyaksa
Email: p.triadyaksa@fisika.fsm.undip.ac.id

ABSTRAK

Identifikasi citra MRI tumor otak dan payudara merupakan aspek penting dalam pengembangan *computer-aided diagnosis* (CAD) yang akurat dan andal. Namun, kedua jenis jaringan ini memiliki karakteristik anatomi dan pola citra yang berbeda heterogen, sehingga memengaruhi kompleksitas pelatihan model. Penelitian ini melakukan analisis komparatif antara model CNN tunggal berbasis ResNet-50 (*end-to-end*) dan model hibrida CNN-SVM (ResNet-50 sebagai *feature extractor* dari *global average pooling* dan SVM sebagai klasifikator). Dataset sekunder diperoleh dari Kaggle, terdiri dari 7.023 citra tumor otak untuk skema klasifikasi multi-kelas (glioma, meningioma, pituitari, dan tanpa tumor) serta 24.024 citra tumor payudara yang di-*undersampling* menjadi 8.410 citra untuk skema klasifikasi biner (*benign* dan *malignant*) guna mengatasi ketidakseimbangan data. Hasil penelitian menunjukkan bahwa pada klasifikasi tumor otak multi-kelas, model hibrida CNN-SVM sedikit lebih unggul dengan akurasi 99,16%, sensitivitas 99,17%, spesifisitas 99,72%, dan presisi 99,14% dibandingkan CNN tunggal, dengan konsekuensi peningkatan marginal waktu inferensi dari 0,0371 s menjadi 0,0518 s per citra. Pada klasifikasi biner tumor payudara, model hibrida CNN-SVM juga menunjukkan keunggulan performa yang lebih tinggi dan stabil dengan akurasi 98,02%, sensitivitas 97,62%, spesifisitas 98,42%, dan presisi 98,40%, dibandingkan CNN tunggal (akurasi 96,83%), dengan waktu inferensi masing-masing sebesar 0,0549 s dan 0,0376 s. Integrasi SVM secara kuantitatif terbukti mengoptimalkan pemisahan *hyperplane* pada fitur kompleks kedua dataset heterogen tersebut dengan tetap mempertahankan efisiensi komputasi *real-time*.

The identification of brain and breast tumor MRI images is a critical aspect in developing accurate and reliable computer-aided diagnosis (CAD) systems. However, these two tissue types exhibit heterogeneous anatomical characteristics and image patterns, heavily influencing model training complexity. This study performs a comparative analysis between an end-to-end single CNN model based on ResNet-50 and a hybrid CNN-SVM model, where ResNet-50 serves as a feature extractor from the global average pooling layer and SVM acts as the final classifier. Secondary datasets were acquired from Kaggle, comprising 7,023 brain tumor images for a multi-class classification scheme (glioma, meningioma, pituitary, and no tumor) and 24,024 breast tumor images, which were balanced via undersampling to 8,410 images for a binary classification scheme (benign and malignant). The results show that for multi-class brain tumor classification, the hybrid CNN-SVM model slightly outperforms the single CNN with an accuracy of 99.16%, sensitivity of 99.17%, specificity of 99.72%, and precision of 99.14%, at the cost of a marginal inference time increase from 0.0371 s to 0.0518 s per image. For binary breast tumor classification, the hybrid CNN-SVM model also demonstrates superior and more stable performance with an accuracy of 98.02%, sensitivity of 97.62%, specificity of 98.42%, and precision of 98.40%, compared to the single CNN (96.83% accuracy), with inference times of 0.0549 s and 0.0376 s, respectively. The integration of SVM quantitatively proves to optimize the hyperplane separation of complex features across both heterogeneous datasets while maintaining real-time computational efficiency.

Copyright © 2026 Author(s). All rights reserved

I. PENDAHULUAN

Tumor merupakan massa sel abnormal yang terbentuk melalui proses tumorigenesis, yaitu proses bertahap yang melibatkan perubahan genetik, epigenetik, dan faktor lingkungan yang mendorong ekspansi klonal sel. Sementara itu, kanker merupakan kondisi ketika tumor mengalami transformasi ganas (*malignant transformation*) sehingga memiliki sifat invasif dan berkembang secara tidak terkendali. Oleh karena itu, istilah tumor dan kanker tidak dapat digunakan secara bergantian karena tidak semua tumor bersifat ganas, sedangkan kanker merupakan bentuk tumor yang telah mengalami keganasan (Zhang et al., 2024).

Kompleksitas interpretasi citra MRI secara signifikan berkontribusi pada peningkatan beban kerja radiolog dan potensi terjadinya keterlambatan diagnosis. Radiolog ditugaskan untuk menganalisis citra dalam jumlah banyak yang rumit dan seringkali hingga ribuan. Selain itu, variabilitas antar pemeriksa dapat mengakibatkan diagnosis yang tidak konsisten, hal ini menekankan kebutuhan akan alat yang menstandarisasi dan meningkatkan akurasi diagnosis. *Artificial intelligence* (AI) memiliki potensi untuk mengatasi tantangan ini dengan mengotomatiskan tugas rutin, mengoptimalkan protokol pemindaian, dan membantu dalam interpretasi citra, yang pada akhirnya meningkatkan efisiensi alur kerja dan mengurangi kesalahan diagnosis (Nair et al., 2025).

Pendekatan AI terutama *machine learning* (ML) dan *deep learning* (DL) telah muncul sebagai alat yang menjanjikan untuk membantu klinis dalam klasifikasi tumor. Teknik-teknik ini telah menunjukkan potensi luar biasa untuk klasifikasi tumor secara non-invasif dengan memanfaatkan data pencitraan medis. Penerapan AI di bidang ini telah berkembang pesat, beralih dari pendekatan ML tradisional ke arsitektur DL yang canggih. Metode komputasional ini digunakan untuk menganalisis data pencitraan medis guna mendeteksi pola dan fitur yang melampaui kemampuan sistem visual manusia, yang berpotensi meningkatkan akurasi dan efisiensi diagnosis (Mohsen et al., 2025).

Salah satu metode yang paling menonjol adalah *convolutional neural network* (CNN), yang digunakan dalam deteksi citra medis. CNN dapat secara otomatis mengekstraksi fitur dari citra tanpa membutuhkan rekayasa fitur manual, memungkinkan model untuk mempelajari pola-pola yang sangat kompleks dalam citra medis. Studi menunjukkan bahwa CNN telah terbukti efektif dalam meningkatkan akurasi deteksi kanker payudara pada citra mamografi, CT-scan, dan MRI, memberikan hasil yang lebih baik daripada metode tradisional yang dilakukan oleh dokter (Hwang et al., 2023).

Kemajuan teknologi telah memungkinkan penggunaan teknik pembelajaran mesin dan DL dalam analisis citra medis, termasuk untuk klasifikasi kanker payudara (Rahman et al., 2025). Model CNN telah terbukti efektif dalam mengekstraksi fitur dari citra medis dan melakukan klasifikasi dengan akurasi tinggi. Misalnya, model CNN-LSTM (*convolutional neural network - long short term memory*) hibrida yang dikembangkan oleh Kaddes et al (2025) menunjukkan akurasi hingga 99,90% dalam klasifikasi kanker payudara menggunakan dataset dari Kaggle. Namun, meskipun CNN dapat mengekstraksi fitur spasial dengan baik, model ini kurang efektif dalam menangani data temporal atau urutan, yang penting dalam analisis perkembangan lesi kanker dari waktu ke waktu (Kaddes et al., 2025).

Untuk mengatasi keterbatasan CNN, pendekatan hibrida yang menggabungkan CNN dengan teknik lain, pada *machine learning* seperti *support vector machine* (SVM), telah mulai diterapkan. Model CNN-SVM hibrida memanfaatkan kekuatan CNN dalam ekstraksi fitur dan kemampuan SVM dalam klasifikasi dengan menggunakan citra mamografi, memberikan potensi untuk meningkatkan akurasi dan generalisasi dalam klasifikasi kanker payudara. Penelitian oleh Swathi et al. (2025) menunjukkan bahwa pendekatan hibrida ini memiliki keunggulan dalam klasifikasi dibandingkan dengan penggunaan CNN secara tunggal, karena SVM dapat lebih efektif dalam menangani data dengan dimensi tinggi dan kompleksitas tinggi (Swathi et al., 2025).

Salah satu hambatan yang paling persisten dalam mengembangkan model DL yang efektif adalah ketersediaan data yang terbatas. Dataset seringkali kecil (paling banyak ratusan pasien dalam studi yang dipublikasikan) dibandingkan dengan dimensi tinggi dari citra tersebut. Dalam praktiknya, dataset yang kecil berisiko menyebabkan *overfitting*. Model mungkin menghafal contoh pelatihan alih-alih mempelajari pola yang dapat digeneralisasikan, terutama ketika citra memiliki karakteristik yang


unik. Augmentasi data solusi untuk studi DL menggunakan augmentasi ekstensif untuk memperbesar set pelatihan secara artifisial. Transformasi sederhana yang dilakukan seperti (rotasi, skala, translasi, penyesuaian kontras, deformasi elastis). Augmentasi mengurangi kelangkaan data tetapi tidak sepenuhnya menyelesaikannya data yang ditingkatkan bukanlah informasi baru yang sesungguhnya, tetapi mereka membantu mengekspos model ke rentang variasi yang lebih luas (Wang et al., 2025).

Berdasarkan perkembangan penelitian hingga saat ini, berbagai studi telah menunjukkan keberhasilan penerapan *deep learning* berbasis *Convolutional Neural Network* (DL-CNN) maupun pendekatan hibrida CNN-SVM dalam klasifikasi tumor. Arsitektur ResNet-50 merupakan salah satu model CNN yang banyak digunakan pada citra medis karena mampu mengatasi permasalahan *vanishing gradient* melalui mekanisme *residual connection*, sehingga proses pelatihan jaringan yang dalam menjadi lebih stabil. Selain itu, ResNet-50 memiliki kemampuan ekstraksi fitur yang baik dan telah menunjukkan performa tinggi pada klasifikasi citra MRI tumor otak, sehingga berpotensi mendukung peningkatan akurasi sistem diagnosis berbantuan komputer (Musthafa et al., 2024). Meskipun demikian, penelitian yang membandingkan kinerja ResNet-50 dengan pendekatan hibrida CNN-SVM secara komprehensif pada lebih dari satu jenis tumor dengan karakteristik citra yang berbeda masih terbatas, khususnya pada citra MRI tumor otak dan tumor payudara. Oleh karena itu, penelitian ini melakukan analisis komparatif antara model CNN dengan arsitektur ResNet-50 dan model CNN-SVM yang mengombinasikan proses ekstraksi fitur CNN dengan metode klasifikasi *support vector machine* (SVM).

Pemilihan dua dataset citra MRI, yaitu dataset tumor otak dengan empat subkelas dan dataset tumor payudara dengan dua subkelas, bertujuan untuk mengevaluasi kinerja model pada dua domain klasifikasi yang berbeda. Kedua dataset dipilih karena memiliki perbedaan karakteristik anatomi dan pola visual jaringan pada citra MRI, sehingga dapat digunakan untuk menilai kemampuan generalisasi model pada data yang heterogen. Pernyataan mengenai perbedaan karakteristik anatomi dan visual tersebut didukung oleh (Xia et al., 2025). Kinerja kedua model dianalisis berdasarkan metrik sensitivitas dan presisi melalui visualisasi *confusion matrix* dan waktu inferensi untuk membandingkan efisiensi komputasi, serta kemampuan generalisasi terhadap dataset citra MRI yang telah melalui tahap pra-pemrosesan. Kebaruan penelitian ini terletak pada evaluasi komparatif pendekatan CNN dan CNN-SVM pada dua domain tumor yang berbeda menggunakan citra MRI, sehingga memberikan gambaran empiris mengenai efektivitas masing-masing model dalam mendukung pengembangan sistem *computer-aided diagnosis* (CAD) *real-time* untuk klasifikasi tumor otak dan payudara.


II. METODE

Penelitian ini menggunakan data sekunder berupa citra MRI tumor otak dan tumor payudara yang diperoleh dari repositori *open access* Kaggle. Dataset yang digunakan terdiri atas 7.023 citra MRI tumor otak untuk klasifikasi multi-kelas, yang terdiri dari data *training* dan data *testing*. Data *training* berjumlah 5.712 citra yang terdiri atas glioma (1.321 citra), meningioma (1.339 citra), pituitari (1.457 citra), dan tanpa tumor (1.595 citra). Sementara itu, data *testing* berjumlah 1.311 citra yang terdiri atas glioma (300 citra), meningioma (306 citra), pituitari (300 citra), dan tanpa tumor (405 citra). Contoh citra untuk masing-masing kelas ditunjukkan pada Gambar 1 dan dataset dapat diakses melalui Kaggle MRI Dataset melalui <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset> (Nickparvar, 2024). Dataset MRI tumor payudara terdiri atas 24.024 citra untuk klasifikasi biner, yaitu *benign* dan *malignant*. Dataset ini telah tersedia dalam bentuk data *training*, *validation*, dan *testing*. Data *training* terdiri atas 16.826 citra, masing-masing (8.413 citra) untuk kelas *benign* dan (8.413 citra) untuk kelas *malignant*. Data *validation* terdiri atas 3.594 citra, masing-masing (1.797 citra) untuk kelas *benign* dan (1.797 citra) untuk kelas *malignant*. Data *testing* terdiri atas 3.604 citra, masing-masing (1.802 citra) untuk kelas *benign* dan (1.802 citra) untuk kelas *malignant*. Contoh citra untuk kedua kelas ditunjukkan pada Gambar 2 dan dataset dapat diakses di Kaggle MRI tumor payudara melalui <https://www.kaggle.com/datasets/abenjelloun/breast-mri-tumor-classification-dataset/data> (Benjelloun, 2025). Seluruh dataset diorganisasi dalam struktur folder MATLAB untuk memastikan konsistensi selama proses pelatihan (*training*), validasi (*validation*) dan pengujian (*testing*) model.



Gambar 1 Tumor otak multi-kelas (a) glioma (b) meningioma (c) pituitari (d) tanpa tumor

Gambar 1 menunjukkan contoh citra otak untuk klasifikasi empat kondisi: (a) glioma, (b) meningioma, (c) tumor pituitari, dan (d) tanpa tumor. Tiga gambar pertama memperlihatkan adanya massa abnormal di area berbeda pada otak, sedangkan gambar terakhir menunjukkan struktur otak normal tanpa kelainan.



Gambar 2 Tumor payudara 2 kelas (biner) (a) *benign* (b) *malignant*

Gambar 2 menunjukkan klasifikasi tumor payudara biner yaitu (a) *benign* (lesi jinak) dan (b) *malignant* (yang mengindikasikan keganasan).

Dataset pada penelitian ini dibagi menjadi data *training*, *validation*, dan *testing* untuk mencegah *data leakage* serta memastikan evaluasi model yang objektif. Seluruh pembagian data dilakukan sebelum proses pelatihan dan augmentasi. Proses pelatihan dilakukan secara terpisah untuk masing-masing dataset, yaitu dataset MRI tumor otak dan dataset MRI tumor payudara. Pemisahan ini dilakukan karena kedua dataset memiliki karakteristik anatomi, pola visual, serta skema klasifikasi yang berbeda.

Pada dataset MRI tumor otak yang terdiri atas 7.023 citra, digunakan skema klasifikasi multi-kelas dengan empat kelas, yaitu glioma, meningioma, pituitari, dan tanpa tumor. Dataset tersedia dalam bentuk data *training* dan *testing*. Data *training* kemudian dibagi kembali menjadi 85% data *training* dan 15% data *validation* menggunakan fungsi *splitEachLabel* pada MATLAB. Data *testing* digunakan secara terpisah dan tidak terlibat dalam proses pelatihan maupun validasi model.

Pada dataset MRI tumor payudara yang terdiri atas 24.024 citra, digunakan skema klasifikasi biner dengan dua kelas, yaitu *benign* dan *malignant*. Untuk mengurangi ketidakseimbangan data, dilakukan *undersampling* acak dengan mempertahankan 35% data pada masing-masing subset *training*, *validation*, dan *testing* sehingga jumlah data yang digunakan menjadi 8.410 citra. Selanjutnya, augmentasi data diterapkan hanya pada data *training* melalui refleksi horizontal serta translasi acak pada arah horizontal dan vertikal untuk meningkatkan keragaman data dan kemampuan generalisasi model. Proses augmentasi dilakukan selama pelatihan sehingga tidak menambah jumlah citra secara permanen. Data *validation* dan *testing* tidak mengalami augmentasi dan hanya melalui tahap pra-pemrosesan dasar agar tetap dapat digunakan sebagai data evaluasi yang independen.

Pra-pemrosesan citra dilakukan dengan menyesuaikan seluruh citra ke ukuran input ResNet-50 yaitu 224×224 piksel. Karena citra MRI bersifat *grayscale*, seluruh citra dikonversi ke format RGB menggunakan fungsi *gray2rgb* agar kompatibel dengan arsitektur ResNet-50 yang memerlukan masukan berukuran $224 \times 224 \times 3$ (Xiang et al., 2024). Seluruh tahapan pra-pemrosesan dan augmentasi diimplementasikan menggunakan *augmentedImageDatastore* pada MATLAB.

Setelah proses pelatihan CNN ResNet-50, model digunakan sebagai *feature extractor* dengan mengambil fitur dari lapisan *global average pooling* yang menghasilkan 2.048 fitur untuk setiap citra (Habeeb et al., 2025). Ekstraksi fitur dilakukan menggunakan fungsi *activations* pada MATLAB dan hasilnya direstrukturisasi ke dalam bentuk matriks dua dimensi. Fitur dari data *training* digunakan untuk


melatih model SVM, fitur data *validation* digunakan untuk menentukan parameter terbaik, sedangkan fitur data *testing* digunakan untuk mengevaluasi kinerja model hibrida CNN-SVM.

Proses klasifikasi dilakukan menggunakan dua pendekatan, yaitu CNN tunggal berbasis ResNet-50 dengan lapisan *Softmax* dan model hibrida CNN-SVM. ResNet-50 dimodifikasi pada lapisan klasifikasi terakhir agar sesuai dengan jumlah kelas pada masing-masing dataset dan dilatih menggunakan *optimizer* Adam selama 20 *epoch*. Pada pendekatan hibrida, fitur hasil ekstraksi CNN diklasifikasikan menggunakan SVM dengan *kernel* RBF dan parameter yang dipilih berdasarkan performa pada data *validation* (Khairandish et al., 2022), (Guido et al., 2024). Evaluasi kinerja dilakukan pada data *testing* menggunakan metrik akurasi, sensitivitas, spesifisitas, dan presisi yang disajikan melalui *confusion matrix* (Bahba et al., 2025), (Yu et al., 2025), serta analisis waktu inferensi untuk membandingkan efisiensi komputasi kedua pendekatan.

Seluruh eksperimen dilakukan menggunakan MATLAB dengan lisensi akademik Universitas Diponegoro. Proses komputasi dijalankan pada komputer portabel dengan sistem operasi Windows, prosesor AMD Ryzen 7000 Series, RAM 16 GB, dan media penyimpanan SSD 512 GB.

III. HASIL DAN DISKUSI

3.1 Tumor Otak




Gambar 3 (a) *Confusion matrix* CNN tunggal tumor otak (b) *Confusion matrix* hibrida CNN-SVM tumor otak

Berdasarkan *confusion matrix* tumor otak pada Gambar 3, model CNN tunggal mencapai akurasi 99,01%, sedangkan model Hibrida CNN-SVM sedikit lebih tinggi dengan akurasi 99,08%. Dominasi nilai diagonal yang kuat, khususnya pada kelas tanpa tumor (401 sampel terklasifikasi benar), menunjukkan bahwa model mampu mengenali perbedaan karakteristik citra MRI antar kelas dengan baik. Dari perspektif pencitraan MRI, setiap jenis tumor memiliki karakteristik intensitas sinyal, tekstur, dan bentuk anatomi yang berbeda. Glioma umumnya menunjukkan heterogenitas sinyal yang tinggi akibat adanya nekrosis dan edema, meningioma cenderung memiliki batas lesi yang lebih jelas dan homogen, sedangkan tumor pituitari memiliki lokasi anatomis yang khas pada daerah *sella turcica*. Perbedaan karakteristik tersebut menghasilkan pola visual yang dapat diekstraksi oleh CNN sebagai fitur pembeda antar kelas. Pada kelas tanpa tumor, tidak adanya massa abnormal maupun perubahan intensitas sinyal yang signifikan menyebabkan model dapat mengidentifikasi kelas ini dengan tingkat ketepatan yang tinggi.

Penggunaan SVM sebagai pengklasifikasi akhir pada model hibrida terbukti mampu meningkatkan performa klasifikasi dibandingkan lapisan *softmax* standar. Hal ini menunjukkan bahwa fitur yang diekstraksi oleh ResNet-50 memiliki tingkat keterpisahan yang baik sehingga SVM dapat membentuk *hyperplane* yang lebih optimal untuk memisahkan kelas-kelas yang memiliki kemiripan karakteristik visual. Pada citra MRI, beberapa jenis tumor dapat menunjukkan pola intensitas dan tekstur yang saling tumpang tindih, sehingga penggunaan SVM membantu meningkatkan kemampuan diskriminasi pada ruang fitur berdimensi tinggi.

Ditinjau dari aspek kecepatan pemrosesan per citra, model CNN tunggal mencatat rata-rata waktu inferensi sebesar 0,0371 s, sedangkan model Hibrida CNN-SVM memerlukan waktu sedikit lebih lama, yaitu 0,0518 s per citra. Tambahan waktu sebesar 0,0147 s berasal dari proses klasifikasi

menggunakan SVM setelah tahap ekstraksi fitur CNN. Meskipun demikian, waktu inferensi model hibrida masih berada dalam rentang yang efisien untuk aplikasi *real-time*. Hasil ini menunjukkan bahwa peningkatan performa klasifikasi tidak hanya dipengaruhi oleh kemampuan algoritma dalam mempelajari fitur citra, tetapi juga oleh adanya perbedaan karakteristik anatomi dan biologis jaringan yang tercermin pada pola intensitas sinyal dan tekstur citra MRI, sehingga dapat dimanfaatkan secara efektif oleh model untuk membedakan masing-masing kelas tumor.




Gambar 4 Grafik batang perbandingan metrik kinerja identifikasi tumor otak

Berdasarkan hasil pengujian perbandingan metrik kinerja identifikasi tumor otak yang ditunjukkan pada Gambar 4, model Hibrida CNN-SVM menunjukkan performa yang sedikit lebih baik dibandingkan CNN tunggal dengan akurasi 99,16%, sensitivitas 99,17%, spesifisitas 99,72%, dan presisi 99,14%. Keunggulan ini mengindikasikan bahwa kombinasi ekstraksi fitur CNN dan klasifikasi SVM mampu memanfaatkan karakteristik citra MRI secara lebih efektif dalam membedakan berbagai jenis tumor otak. Dari aspek pencitraan MRI, glioma, meningioma, dan tumor pituitari memiliki karakteristik intensitas sinyal, tekstur, bentuk, serta lokasi anatomis yang berbeda. Glioma umumnya menunjukkan heterogenitas intensitas yang tinggi akibat adanya nekrosis, edema, dan infiltrasi jaringan sekitar, sedangkan meningioma cenderung memiliki batas lesi yang lebih tegas dan kontras yang relatif homogen. Tumor pituitari memiliki karakteristik anatomi yang khas karena berada pada area *sella turcica*. Perbedaan karakteristik tersebut menghasilkan pola kontras dan tekstur yang dapat diekstraksi oleh CNN sebagai fitur diskriminatif untuk proses klasifikasi.

Peningkatan kinerja pada model hibrida menunjukkan bahwa fitur-fitur yang berkaitan dengan variasi intensitas sinyal, tekstur jaringan, dan karakteristik anatomi tumor dapat dipisahkan dengan lebih baik oleh SVM pada ruang fitur berdimensi tinggi. Dengan demikian, model tidak hanya memanfaatkan perbedaan visual antar kelas, tetapi juga informasi yang secara tidak langsung merepresentasikan perbedaan biologis dan morfologis jaringan tumor yang terekam pada citra MRI.

Dari sisi efisiensi komputasi, integrasi SVM meningkatkan rata-rata waktu inferensi menjadi 0,0518 s per citra dibandingkan CNN tunggal sebesar 0,0371 s. Namun, selisih waktu sebesar 0,0147 s tersebut tergolong sangat kecil dan tidak mengurangi efisiensi sistem secara signifikan. Hasil ini menunjukkan bahwa pendekatan hibrida CNN-SVM mampu meningkatkan performa klasifikasi dengan tetap mempertahankan kecepatan pemrosesan yang memadai untuk mendukung pengembangan sistem *computer-aided diagnosis* (CAD) berbasis MRI pada identifikasi tumor otak.

3.2 Tumor Payudara




Gambar 5 (a) *Confusion matrix* CNN tunggal tumor payudara (b) *Confusion matrix* hibrida CNN-SVM tumor payudara

Berdasarkan data *confusion matrix* tumor payudara pada Gambar 5, model hibrida CNN-SVM menunjukkan performa klasifikasi yang lebih unggul dibandingkan CNN tunggal dalam membedakan tumor payudara *benign* dan *malignant*. Model hibrida berhasil mengidentifikasi 621 sampel *benign* (meningkat dari 613 pada CNN tunggal) dan 616 sampel *malignant* (meningkat dari 609 pada CNN tunggal) secara akurat. Penggunaan SVM sebagai pengklasifikasi akhir terbukti efektif menekan angka kesalahan prediksi, di mana jumlah *misclassification* pada kelas *malignant* turun dari 22 sampel menjadi hanya 15 sampel. Hal ini mengindikasikan bahwa model hibrida memiliki tingkat keandalan yang lebih tinggi dalam mendeteksi tumor payudara.

Peningkatan performa klasifikasi tersebut tidak hanya dipengaruhi oleh kemampuan algoritma, tetapi juga berkaitan dengan karakteristik fisika pencitraan MRI dan sifat biologis jaringan tumor. Pada citra MRI payudara, tumor *malignant* umumnya memiliki karakteristik yang lebih heterogen dibandingkan tumor *benign* akibat tingginya proliferasi sel, angiogenesis, infiltrasi jaringan di sekitarnya, serta kemungkinan adanya area nekrosis. Kondisi tersebut menghasilkan variasi intensitas sinyal dan tekstur citra yang lebih kompleks. Sebaliknya, tumor *benign* cenderung memiliki struktur jaringan yang lebih homogen, batas lesi yang lebih jelas, serta distribusi intensitas sinyal yang relatif seragam. Perbedaan karakteristik ini menciptakan pola visual yang dapat dimanfaatkan sebagai fitur pembeda oleh model *deep learning*.

Lapisan konvolusi pada ResNet-50 mampu mengekstraksi informasi spasial dari citra MRI berupa variasi tekstur, kontras jaringan, bentuk lesi, dan distribusi intensitas sinyal. Pada kasus tumor *malignant*, batas lesi yang tidak beraturan dan heterogenitas sinyal yang lebih tinggi menghasilkan pola fitur yang berbeda dibandingkan jaringan *benign*. Fitur-fitur tersebut kemudian dipetakan ke dalam ruang fitur berdimensi tinggi sehingga memungkinkan SVM membentuk *hyperplane* pemisah yang lebih optimal antara kedua kelas. Hal ini menjelaskan mengapa model CNN-SVM mampu mengurangi kesalahan klasifikasi dan meningkatkan sensitivitas maupun spesifisitas dibandingkan CNN tunggal.

Dari sisi kecepatan pemrosesan, model CNN tunggal memiliki rata-rata waktu inferensi sebesar 0,0376 detik per citra. Sementara itu, model Hibrida CNN-SVM memerlukan waktu sedikit lebih lama yaitu 0,0549 detik per citra, atau terdapat selisih sebesar 0,0173 detik. Meskipun integrasi SVM menambah sedikit beban komputasi, durasi tersebut masih sangat efisien karena berada jauh di bawah satu detik. Secara keseluruhan, peningkatan akurasi yang signifikan pada model hibrida menunjukkan bahwa kombinasi CNN dan SVM tidak hanya mampu memanfaatkan karakteristik visual citra MRI secara efektif, tetapi juga relevan dengan prinsip pencitraan medis yang membedakan jaringan *benign* dan *malignant* berdasarkan variasi intensitas sinyal, tekstur, dan karakteristik anatomi jaringan. Oleh karena itu, model hibrida CNN-SVM memiliki potensi yang kuat untuk diimplementasikan pada sistem *computer aided diagnosis* (CAD) berbasis MRI secara *real-time*.



Gambar 6 Grafik batang metrik kinerja identifikasi tumor payudara

Berdasarkan hasil pengujian metrik kinerja identifikasi tumor payudara pada Gambar 6 ditampilkan bahwa model hibrida CNN-SVM menunjukkan performa yang lebih unggul dibandingkan CNN tunggal pada seluruh metrik evaluasi klasifikasi tumor payudara. CNN tunggal memperoleh akurasi 96,83%, sensitivitas 96,51%, spesifisitas 97,15%, dan presisi 97,13%, sedangkan model Hibrida CNN-SVM meningkat menjadi akurasi 98,02%, sensitivitas 97,62%, spesifisitas 98,42%, dan presisi 98,40%. Peningkatan ini menunjukkan bahwa integrasi SVM mampu mengoptimalkan proses klasifikasi fitur yang diekstraksi oleh CNN sehingga menghasilkan pemisahan kelas *benign* dan *malignant* yang lebih akurat.

Hasil penelitian ini sejalan dengan penelitian Swathi et al. (2025) yang melaporkan bahwa pendekatan hibrida CNN-SVM mampu meningkatkan performa klasifikasi kanker payudara dibandingkan penggunaan CNN secara tunggal karena SVM memiliki kemampuan yang baik dalam membentuk batas keputusan (*decision boundary*) pada ruang fitur berdimensi tinggi. Selain itu, Khairandish et al. (2022) juga menunjukkan bahwa kombinasi CNN dan SVM efektif meningkatkan akurasi klasifikasi tumor pada citra MRI karena fitur yang diekstraksi oleh CNN dapat dipisahkan secara lebih optimal oleh SVM dibandingkan lapisan klasifikasi konvensional berbasis softmax.

Jika dibandingkan dengan penelitian Kaddes et al. (2025) yang menggunakan arsitektur CNN-LSTM untuk klasifikasi kanker payudara dan memperoleh akurasi yang sangat tinggi, penelitian ini menawarkan pendekatan yang lebih sederhana dengan kompleksitas model yang lebih rendah. CNN-LSTM dirancang untuk memanfaatkan informasi spasial dan sekuensial secara bersamaan, sedangkan pada penelitian ini fitur spasial yang diekstraksi oleh ResNet-50 dikombinasikan dengan kemampuan klasifikasi SVM. Meskipun menggunakan arsitektur yang lebih sederhana, model CNN-SVM tetap mampu menghasilkan akurasi sebesar 98,02%, menunjukkan bahwa pendekatan ini memiliki kemampuan generalisasi yang baik pada dataset MRI tumor payudara yang digunakan.

Perbedaan utama penelitian ini dibandingkan studi sebelumnya terletak pada evaluasi komparatif dua pendekatan, yaitu CNN tunggal dan CNN-SVM, pada domain pencitraan MRI tumor yang berbeda, yakni tumor otak multikelas dan tumor payudara biner. Yang mana sebagian besar penelitian terdahulu hanya berfokus pada satu jenis tumor atau satu pendekatan klasifikasi tertentu. Oleh karena itu, hasil penelitian ini memberikan gambaran yang lebih komprehensif mengenai efektivitas model CNN dan CNN-SVM pada karakteristik citra MRI yang heterogen, sehingga dapat menjadi referensi dalam pengembangan sistem *computer-aided diagnosis* (CAD) berbasis *deep learning*.

Meskipun penggunaan SVM meningkatkan waktu inferensi dari 0,0376 detik menjadi 0,0549 detik per citra, selisih sebesar 0,0173 detik tersebut masih tergolong sangat kecil dan tetap berada dalam batas efisiensi untuk implementasi sistem *real-time*. Dengan demikian, pendekatan hibrida CNN-SVM terbukti lebih efektif dan andal dalam mendukung pengembangan sistem CAD untuk identifikasi tumor payudara berbasis citra MRI.

IV. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, baik model CNN berbasis ResNet-50 maupun model hibrida CNN-SVM mampu mencapai performa klasifikasi yang tinggi pada citra MRI tumor otak dan tumor payudara. Pada klasifikasi multi-kelas tumor otak yang terdiri atas glioma, meningioma, pituitari, dan tanpa tumor, model hibrida CNN-SVM mencapai akurasi sebesar 99,16%. Sementara itu, pada klasifikasi biner tumor payudara yang terdiri atas kelas *benign* dan *malignant*, model yang sama mencapai akurasi sebesar 98,02%.

Hasil komparasi menunjukkan bahwa model hibrida CNN-SVM secara konsisten memperoleh nilai akurasi, sensitivitas, spesifisitas, dan presisi yang lebih tinggi dibandingkan model CNN tunggal pada kedua dataset. Selain itu, model hibrida juga mampu mengurangi jumlah kesalahan klasifikasi dengan peningkatan waktu inferensi yang relatif kecil dan masih berada dalam batas yang efisien. Berdasarkan hasil pada dataset dan konfigurasi model yang digunakan dalam penelitian ini, pendekatan hibrida CNN-SVM menunjukkan kinerja yang sedikit lebih baik dibandingkan CNN tunggal dalam identifikasi tumor berbasis citra MRI. Temuan ini menunjukkan bahwa pendekatan hibrida CNN-SVM memiliki potensi untuk diterapkan sebagai alternatif dalam pengembangan sistem *computer-aided diagnosis* (CAD) berbasis citra MRI.

DAFTAR PUSTAKA

- Bahba, A., Amine, M., Khemiri, R., & Ezahra, F. (2025). Results in Engineering Composite-metric deep learning for pathological complete response prediction from breast MRI. *Results in Engineering*, 28, 107241. <https://doi.org/10.1016/j.rineng.2025.107241>.
- Benjelloun, A. (2025). Breast MRI Tumor Classification Dataset. Kaggle. <https://doi.org/10.34740/kaggle/ds/7580524>
- Guido, R., Ferrisi, S., Lofaro, D., & Conforti, D. (2024). An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review. *Information*, 15(4). <https://doi.org/10.3390/info15040235>
- Habeeb, Z. Q., Vuksanovic, B., & Alzaydi, I. Q. (2025). Modified ResNet model for medical image-based lung cancer detection. *Image and Vision Computing*, 163(September), 105752. <https://doi.org/10.1016/j.imavis.2025.105752>
- Hwang, I. C., Trivedi, H., Brown-Mulry, B., Zhang, L., Nalla, V., Gastounioti, A., Gichoya, J., Seyyed-Kalantari, L., Banerjee, I., & Woo, M. J. (2023). Impact of multi-source data augmentation on performance of convolutional neural networks for abnormality classification in mammography. *Frontiers in Radiology*, 3(June), 1–9. <https://doi.org/10.3389/fradi.2023.1181190>
- Kaddes, M., Ayid, Y. M., Elshewey, A. M., & Fouad, Y. (2025). Breast cancer classification based on hybrid CNN with LSTM model. *Scientific Reports*, 15(1), 1–14. <https://doi.org/10.1038/s41598-025-88459-6>
- Khairandish, M. O., Sharma, M., Jain, V., Chatterjee, J. M., & Jhanjhi, N. Z. (2022). A Hybrid CNN-SVM Threshold Segmentation Approach for Tumor Detection and Classification of MRI Brain Images. *IRBM*, 43(4), 290–299. <https://doi.org/10.1016/j.irbm.2021.06.003>
- Mohsen, S., Abdel-aziz, & S. O. M. (2025). Deep Learning and Machine Learning for Brain Tumor Detection : A Review , Challenges , and Future Directions. *Archives of Computational Methods in Engineering*, 33(3), 3931-3955. <https://doi.org/https://doi.org/10.1007/s11831-025-10416-3>
- Musthafa, M., Mahesh, T. R., V, V. K., & Guluwadi, S. (2024). Enhancing brain tumor detection in MRI images through explainable AI using Grad - CAM with Resnet 50. *BMC Medical Imaging*, 24, 1–19. <https://doi.org/10.1186/s12880-024-01292-7>
- Nair, A., Ong, W., Lee, A., Leow, N. W., Makmur, A., Ting, Y. H., Lee, Y. J., Ong, S. J., Jiong, J., Tan, H., Kumar, N., Thomas, J., & Decourcy, P. (2025). Enhancing Radiologist Productivity with Artificial Intelligence in Magnetic Resonance Imaging (MRI): A Narrative Review, 15,1146. <https://doi.org/10.3390/diagnostics15091146>
- Nickparvar, M. (2024). Brain Tumor MRI Dataset. Kaggle. <https://doi.org/10.34740/kaggle/dsv/14832123>

- Rahman, M. A., Khan, M. S. H., Watanobe, Y., Prioty, J. T., Annita, T. T., Rahman, S., Hossain, M. S., Aitijjo, S. A., Taskin, R. I., Dhruvo, V., Hanip, A., & Bhuiyan, T. (2025). Advancements in Breast Cancer Detection: A Review of Global Trends, Risk Factors, Imaging Modalities, Machine Learning, and Deep Learning Approaches. *BioMedInformatics*, 5,46. <https://doi.org/10.3390/biomedinformatics5030046>
- S.K.Swathi, Nirmala, R.S.Sujatha, V. R. (2025). Breast Cancer Classification Using CNN and SVM: A Hybrid Approach. *International Journal for Research in Applied Science and Engineering Technology*, 13(8), 889–894. <https://doi.org/10.22214/ijraset.2025.73626>
- Wang, L., Wang, L., Wu, P., & Ding, L. (2025). Cardiovascular Magnetic Resonance imaging analysis using neural networks. *Journal of Radiation Research and Applied Sciences*, 18(4), 101874. <https://doi.org/10.1016/j.jrras.2025.101874>
- Xia, Y., Ling, Z., & Chen, H. (2025). Evaluation of the diagnostic value of magnetic resonance imaging combined with ultrasound and mammography for breast cancer using array spatial sensitivity encoding technique. *Frontiers in Oncology*, 03 November, 1–14. <https://doi.org/10.3389/fonc.2025.1596803>
- Xiang, Q., Li, D., Hu, Z., Yuan, Y., Sun, Y., Zhu, Y., Fu, Y., Jiang, Y., & Hua, X. (2024). Quantum classical hybrid convolutional neural networks for breast cancer diagnosis. *Scientific Reports*, 14(1), 1–13. <https://doi.org/10.1038/s41598-024-74778-7>
- Yu, L., Cui, L., Cui, J., Qu, A., Yu, D., & Wu, Q. (2025). Computerized Medical Imaging and Graphics Multi-representational deep transfer learning for classifying hemorrhagic metastases and non-neoplastic intracranial hematomas in multi-modal brain MRI scans. *Computerized Medical Imaging and Graphics*, 126(April), 102661. <https://doi.org/10.1016/j.compmedimag.2025.102661>
- Zhang Shaosen, Xiao Xinyi, Yi Yonglin, Wang Xinyu, Zhu Lingxuan, Shen Yangrong, Lin Dongxin, W. C. (2024). Tumor initiation and early tumorigenesis: molecular mechanisms and interventional targets. 9(January), 1–36. <https://doi.org/10.1038/s41392-024-01848-7>