

Dilatasi Inkremental Menggunakan Metode CNN Untuk Klasifikasi Tumor Otak Dengan Arsitektur VCG16 dan Resnet50

Tommy Saputra
Faculty of Computer Science
Institut Teknologi dan Sains
Nahdlatul Ulama Sriwijaya
Sumatera Selatan, Palembang,
Indonesia
tommysaputra@uss.ac.id

Muhammad Taufik Roseno
Faculty of Computer Science
Universitas Sumatera Selatan
Palembang, Indonesia
mtroseno@gmail.com

Hadi Syaputra
Faculty of Computer Science
Universitas Sumatera Selatan
Palembang, Indonesia
hadisyaputra@uss.ac.id

Abstrak—Klasifikasi tumor otak adalah tugas yang menantang di bidang pemrosesan citra medis. Teknologi kini telah memungkinkan dokter medis untuk memiliki bantuan tambahan untuk diagnosis. Penelitian ini bertujuan untuk mengklasifikasikan tumor otak menggunakan gambar MRI, yang dikumpulkan dari pasien anonim dan simulator otak buatan. Baru-baru ini, teknik berbantuan komputer seperti menggunakan *deep learning* sebagai ekstraksi fitur, dan teknik klasifikasi digunakan secara intensif untuk mendiagnosis otak pasien untuk memeriksa apakah ada tumor. Dalam penelitian ini diusulkan model klasifikasi tumor otak menggunakan *Convolutional Neural Network* yang dapat mengklasifikasikan tumor otak secara akurat. Data yang digunakan berupa data MRI tumor otak sebanyak 253 data tumor otak. Dataset yang digunakan dibagi menjadi data pelatihan dan pengujian. Penelitian menghasilkan model klasifikasi tumor otak dengan menggunakan arsitektur VCG16 dan Resnet50. Model menghasilkan nilai rata-rata akurasi sebesar 80%, Recall 85% dan Presisi 70%. Penelitian menunjukkan kinerja Resnet50 menunjukkan kemampuan model untuk mengklasifikasikan tumor otak secara akurat.

Kata kunci—Tumor Otak, *Convolutional Neural Network*, VCG16, Resnet50, Klasifikasi

I. PENDAHULUAN

Tumor adalah memiliki massa jaringan abnormal maka akan naik tanpa penyebab yang menjadikan sebuah sel-sel akan tumbuh dan tidak menjadi yang memiliki fungsi yang krusial. Pertumbuhan sel yang secara tidak terkendali akan menjadi peningkatan ukuran tumor. Deteksi tumor otak pada tahap awal dan perawatan yang tepat dapat menyelamatkan pasien dari kerusakan yang merugikan pada otak[1]. Klasifikasi tumor otak adalah tugas yang menantang di bidang pemrosesan citra medis. Teknologi kini telah memungkinkan dokter medis untuk memiliki bantuan tambahan untuk diagnosis. Kami bertujuan untuk mengklasifikasikan tumor otak menggunakan gambar MRI, yang dikumpulkan dari pasien anonim dan simulator otak buatan. Baru-baru ini, teknik berbantuan komputer seperti menggunakan *deep learning* sebagai ekstraksi fitur, dan teknik klasifikasi digunakan secara intensif untuk mendiagnosis otak pasien untuk memeriksa apakah ada tumor.

Pengenalan teknologi informasi dan sistem *e-healthcare* di bidang diagnosis medis telah membantu para profesional klinis dalam menawarkan perawatan kesehatan yang jauh lebih baik bagi pasien. Teknik klasifikasi yang berbeda, terutama *Convolutional Neural Network* (CNN), telah diusulkan dalam beberapa tahun terakhir namun, ini diusulkan teknik telah gagal untuk memperoleh akurasi yang tinggi[2]. Oleh karena itu, ada kebutuhan untuk mengembangkan teknik baru untuk mendeteksi tumor otak. Dalam artikel ini, kami telah mengusulkan masalah klasik dalam mendeteksi tumor dari gambar MRI menggunakan CNN. Pada penelitian tentang citra medis banyak peneliti yang telah mengembangkan dan penelitian dalam bidang ini sangatlah luas. Sumber yang diambil dari penelitian yang terdahulu pada klasifikasi tumor otak.

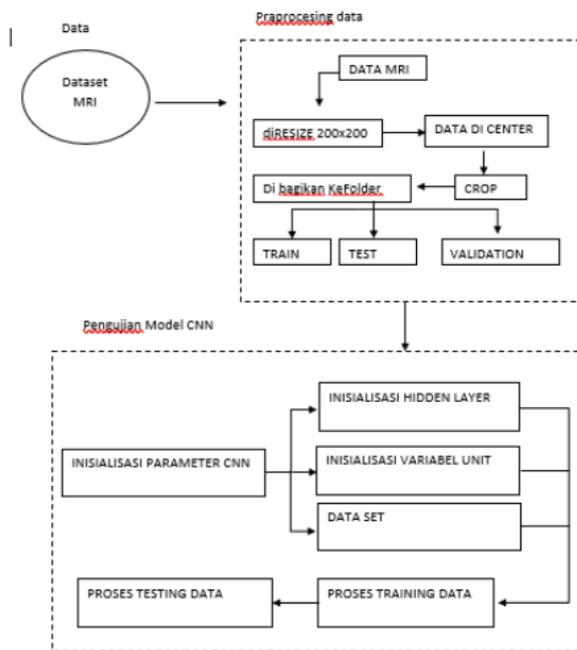
Banyak ditemukan bahwa segmentasi tumor otak yang telah dilakukan . pada penelitian *Deep Neural Network* (DNN) untuk mengklasifikasikan MRI otak ke dalam Arsitektur metodologi baru yang menyerupai arsitektur CNN tetapi membutuhkan spesifikasi perangkat keras yang lebih sedikit dan membutuhkan waktu pemrosesan yang nyaman untuk gambar ukuran besar. Selain itu menggunakan pengklasifikasi DNN menunjukkan akurasi yang tinggi dibandingkan dengan pengklasifikasi tradisional [3]. Optimal Deep Learning(DNN) yang diusulkan dengan pengurangan fitur menunjukkan klasifikasi yang lebih baik dalam kasus gambar CT paru dibandingkan dengan teknik klasifikasi lainnya. Penilaian kanker paru-paru otomatis mengurangi waktu pelabelan manual dan menghindari kesalahan manusia. Melalui teknik pembelajaran mesin, para peneliti berencana untuk mencapai akurasi dan presisi yang lebih besar dalam mengenali gambar paru-paru normal dan abnormal. Berdasarkan hasil eksperimen, teknik yang diusulkan efektif mengklasifikasikan citra paru-paru manusia dalam hal akurasi, sensitivitas dan spesifisitas dengan nilai masing-masing 94,56%, 96,2% dan 94, .2%[4]. Dalam penelitian,CNN dalam yang dimodifikasi diusulkan untuk klasifikasi gambar otak MR. Pendekatan yang diusulkan dianalisis dalam hal akurasi dan kompleksitas komputasi.Peningkatan *True Positive Rate* dan *True Negative Rate* yang cukup baik juga dapat dilihat dari hasil eksperimen. Ini sangat mengurangi kompleksitas komputasi, sehingga cocok untuk aplikasi praktis[5]

II. METODOLOGI

Proses pertama yang dilakukan dapat dilihat pada diagram alir dengan metodologi Langkah demi Langkah dapat dilihat pada gambar 1. Proses *pre-prosesing* data dilakukan dengan gambar MRI dan selanjutnya proses *learning* dengan model CNN.

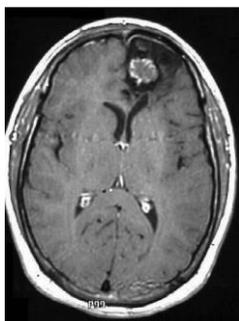
A. Dataset

Datanya anonim atau dibuat secara sintesis dari simulator. Kami memilih irisan dari pemindaian MRI yang berbeda dan menerapkan teknik prapemrosesan yang diperlukan untuk mengonversi gambar ke format JPEG umum untuk menjaga konsistensi di seluruh kumpulan data. Data tersebut dibagi menjadi dua kategori yaitu "Normal" dan "Tumor". Model dilatih dan diuji pada gambar yang dipilih dari sejumlah sumber yang tersedia untuk umum.



Gambar 1. Alur Penelitian

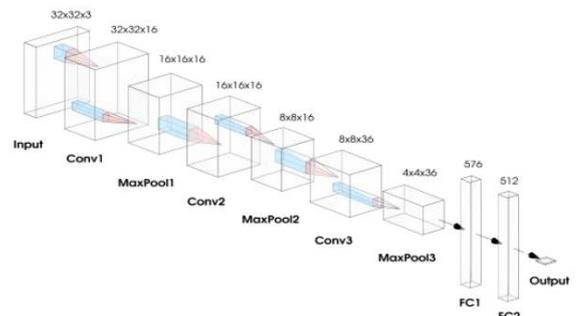
Pada gambar 1 diatas dalam alur penelitian melalui beberapa tahap yaitu praprocessing data dan pengujian model CNN dan pada gambar 2 merupakan contoh pada data MRI tumor otak dibawah ini:



Gambar 2. Data MRI Tumor Otak

B. Convolutional Neural Network

CNN dirancang untuk mengekstrak sebagian besar informasi dari gambar per layer konvolusi. Dalam kasus ini, menerapkan layer konvolusi 3 3 memungkinkan network untuk menangkap karakteristik yang lebih detail karena 3 3 adalah filter terkecil untuk menangkap kiri/kanan, atas/bawah, dan tengah dari gambar. Alih-alih menggunakan filter konvolusi besar seperti 5 5 untuk mendeteksi fitur kasar seperti bentuk dan kontur, kami menggunakan dilatasi di layer konvolusi, dan ini memungkinkan model untuk mendeteksi fitur kasar tersebut tanpa *overhead* komputasi tambahan menggunakan filter yang lebih besar seperti 5 5. Untuk menganalisis kinerja dibandingkan dengan Basic CNN dan Simple ANN, kami menggunakan arsitektur CNN yang sama seperti yang digambarkan pada gambar 3, tetapi tanpa menerapkan pelebaran pada layer konvolusi.



Gambar 3. CNN ukuran 32x32

1) Layer Convolutional

Tiga layer *convolutional* digunakan secara berurutan dalam arsitektur yang diusulkan. Output dari layer konvolusi kedua dan ketiga memberikan fitur tingkat yang lebih tinggi. Input pertama adalah nilai intensitas citra input dan input kedua adalah koefisien filter.

2) Layer Pooling

Digunakan untuk mengurangi resolusi peta fitur yang dihasilkan. Layer ini umumnya ditempatkan di antara layer konvolusi. Untuk menjaga arsitektur model tetap sederhana dan membuat model lebih bergantung pada parameter laju pelebaran, kami telah menggunakan layer *MaxPooling* sederhana dengan ukuran $pool\ 2 \times 2$. Tiga pooling layer yaitu *MaxPool1*, *MaxPool2* dan *MaxPool3*. *Layer Flattening* dan *Dense*. Setelah peta fitur dibuat, model perlu dilatih dalam penalaran tingkat tinggi. Peta fitur diratakan ke dimensi vektor 1 dimensi. Layer bentuk yang terhubung sepenuhnya ditambahkan, dengan batas simpul 15%. Layer yang padat dapat dengan mudah menjadi bias, dan putus sekolah mencegah model dari *overfitting* dataset. Fungsi aktivasi ReLU digunakan untuk memberikan hasil *non-linear*.

3) Activation Functions

Semua Layer tersembunyi menggunakan fungsi aktivasi ReLU. Fungsi aktivasi ReLU memberikan sensitivitas yang lebih besar terhadap jumlah aktivasi dan menghindari kelelahan yang mudah. Ini terlihat dan bertindak seperti fungsi linier, tetapi sebenarnya adalah fungsi nonlinier yang memungkinkan network untuk mempelajari hubungan nonlinier yang kompleks. Ini adalah fungsi linier fragmentaris yang linier untuk satu setengah dari domain input dan non-

linier untuk setengah lainnya. Layer terakhir memprediksi output dari klasifikasi biner. Sigmoid

dipilih karena memiliki beberapa keunggulan dibandingkan fungsi Step dan fungsi aktivasi Tanh. Fungsi sigmoid memiliki karakteristik kurva "berbentuk S". Untuk layer terakhir dari masalah klasifikasi biner, fungsi aktivasi sigmoid memberikan gradien yang lebih halus. Gambar MRI ke dalam 2 folder yang berisi total 253 gambar MRI otak karena gambar MRI berisi informasi pribadi dan memerlukan bantuan khusus dari dokter untuk pelabelan, kami juga menggunakan gambar otak simulasi. *Brainwave Brain Simulator* menyediakan simulasi otak 3D berdasarkan berbagai parameter yang ditentukan pengguna.

Data dalam irisan 3D dan kita dapat memilih kumpulan irisan tertentu untuk ditambahkan ke kumpulan data. Karena simulasi ini didasarkan pada model anatomi otak yang sehat, simulasi ini berfungsi sebagai kebenaran dasar untuk setiap prosedur analitis. Sumber daya lain yang digunakan adalah Harvard Brain Simulator, yang menyediakan banyak gambar MRI otak simulasi yang telah dipilih dengan cermat dan ditambahkan ke kumpulan data. Tahap selanjutnya adalah preprocessing citra. Tujuan kami adalah untuk menghapus data tambahan yang mengelilingi pemindaian otak MRI utama, memastikan bahwa semua gambar memiliki jenis yang sama, dan fokus hanya pada bagian tengah otak. Untuk melakukan pra-pemrosesan di atas, kami menggunakan metode yang cukup umum menggunakan titik ekstrem kontur. Prosedur langkah demi langkah sederhana yang ditunjukkan pada Gambar 2, dikombinasikan dengan beberapa metode pemrosesan gambar seperti skala abu-abu gambar, ambang batas, dan pembukaan, seperti yang ditunjukkan di bawah dalam Algoritma 1, memastikan bahwa otak berada dalam fokus di setiap gambar.

Akhirnya, menggunakan titik ekstrim sebagai topeng. Saat menyiapkan data untuk pelatihan, kita perlu membuat kumpulan data umum karena algoritme pembelajaran mendalam sangat didorong oleh data. Ini berarti bahwa set yang tidak seimbang dan fitur gambar terdistorsi lainnya di kelas tertentu akan membuat model menjadi bias dan menyebabkan kesalahan klasifikasi. Dataset otak MRI. mengalami dua masalah utama, pertama dengan ukuran dataset dan kedua, tidak ada satu pun bentuk struktural otak manusia yang benar. Setiap otak manusia memiliki bentuk yang unik dan sedikit berbeda satu sama lain. Menggunakan Generator Data Gambar Keras.

a) Network VGG16

Pelatihan ekstensif yang telah dialami network VGG-16, network ini memberikan akurasi yang sangat baik bahkan saat kumpulan data gambar kecil. Network VGG-16 terdiri dari 16 layer konvolusi dan memiliki bidang reseptif kecil 3×3 . Ini memiliki layer Max Pooling berukuran 2×2 dan memiliki total 5 layer seperti itu. Ada 3 layer yang terhubung sepenuhnya setelah layer penyatuan Max terakhir. Ini diikuti oleh tiga layer yang terhubung sepenuhnya. Ini menggunakan pengklasifikasi softmax sebagai layer terakhir. Aktivasi ReLu diterapkan ke semua hidden layer[6].

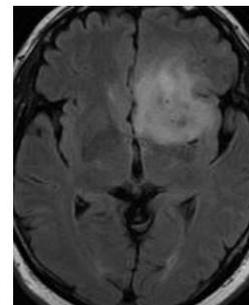
b) Network ResNet50

ResNet50 adalah dengan bentuk network yang memiliki 50 layer dibanding dengan VGG-16 bahwa Resnet50 memiliki kemampuan pemetaan identitas tambahan. ResNet

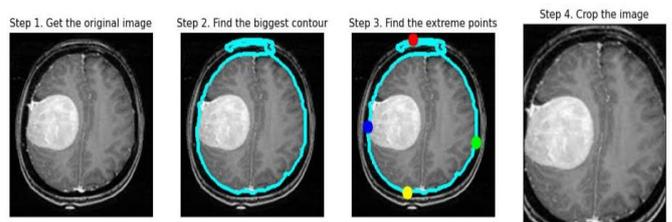
memprediksi delta yang diperlukan untuk mencapai final. Prediksi dari satu layer ke layer berikutnya. ResNet mengurangi masalah gradien menghilang dengan mengizinkan jalur pintasan sehingga memiliki jalur alternatif ini agar gradien mengalir. Pemetaan identitas yang digunakan di ResNet memungkinkan model melewati layer bobot CNN jika layer saat ini tidak diperlukan. Ini membantu dalam menghindari masalah pemasangan yang berlebihan pada set pelatihan. ResNet50 memiliki 50 layer[6].

III. PRE-PROSESING DATA

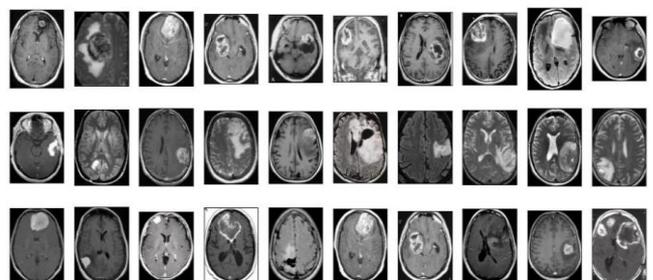
Preprocessing adalah yang dilakukan untuk menyajikan persiapan data dengan mengambil informasi sangat penting dan menghapus yang tidak diinginkan. Pada proses awal penting dalam sebuah visi komputer, terutama dalam untuk analisis sebuah citra medis, di mana input jika tidak akurat dapat menurunkan kinerja pengklasifikasi yang sangat efektif. Pada proses ini yang digunakan untuk preprocessing data ada tiga tahap preprocessing, resize citra MRI, augmentasi, dan normalisasi piksel global, sebelum mengalokasikannya ke tahap kasifikasi menggunakan CNN.



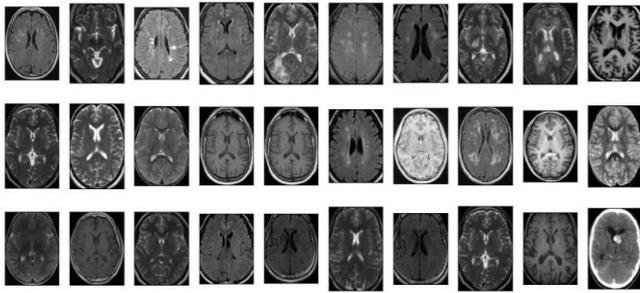
Gambar 4. Data MRI sudah di Olah



Gambar 5. Proses CROP



Gambar 6. Data pada tumor : YES=TUMOR



Gambar 7. Data pada tumor :NO=NORMAL

hasil yang diperoleh dari rasio pelatihan, tes, dan validasi masing-masing 75%, 20%, dan 5%

IV. HASIL PERCOBAAN DAN DISKUSI

A. Hasil Proses Learning

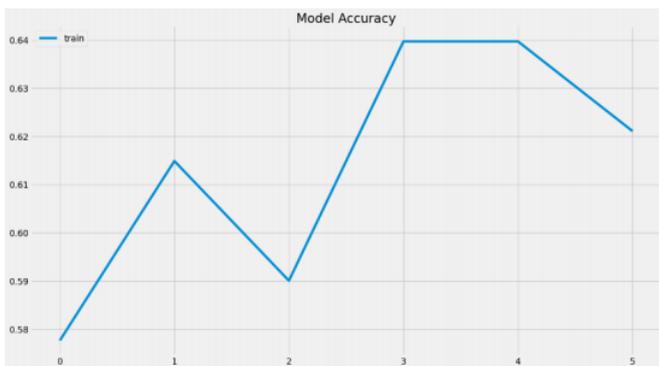
Pada data tabel 1 didapat hasil yang menggunakan Algoritma VGG16, dan ResNet 50 sebesar 70% dan 80% akurasi didapat dengan menggunakan data test di uji dengan model yang telah di training dengan data train selanjut dapat dijelaskan dibawah ini:

TABEL 1. HASIL PERCOBAAN

Arsitektur	Nilai Akurasi	Recall	Pesisi
VCG 16	70%	80%	60%
Resnet 50	80%	85%	70%

Pada tahap selanjutnya akan menghasilkan sebuah nilai keakurasian yang dihasilkan dari nilai output. untuk menghasilkan proses model yang terdapat pada feature extraction layer dimana masih berbentuk array maka selanjutnya melkukan flatten/reshape feature map diubah menjadi vector agar dapat digunakan sebagai inputan dari fully connected kemudian ditambahkan fuction danse sebagai fungsi untuk menambahkan fully connected. Diketahui pada tahap ini, dense yang disederhanakan menjadi 128 node. Hasil tersebut digunakan pada hidden

layer yang jumlah nilainya diantara node input dan node output yang menggunakan aktivasi ReLU. Hal ini dilakukan untuk hal transformasi data supaya bisa klasifikasi secara linier. Dalam pembahasan ini akan membahas bagaimana interface yang di desain, dengan adanya interface ini maka mempermudah dalam melakukan input serta output yang dihasilkan setelah melakukan training data.



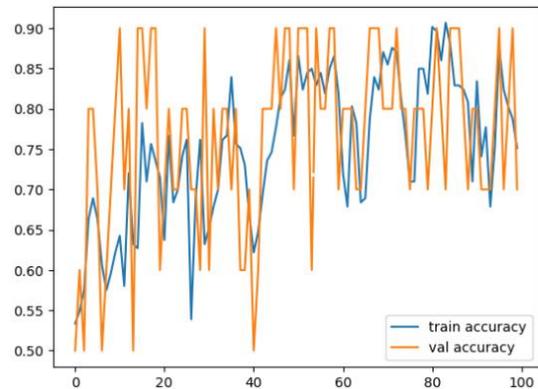
Gambar 8. Model Akurasi VGG16

Akurasi: Akurasi pada tahap ini adalah probabilitas dari kelas buah yang dihasilkan dari softmax dimana softmax memiliki probabilitas output dari 0 hingga 1 dan jumlah keseluruhan probabilitas output adalah 1. Cuplikan dari Akurasi yang didapatkan oleh model CNN dalam proses learning yang telah dilakukan ditunjukkan pada gambar 8.

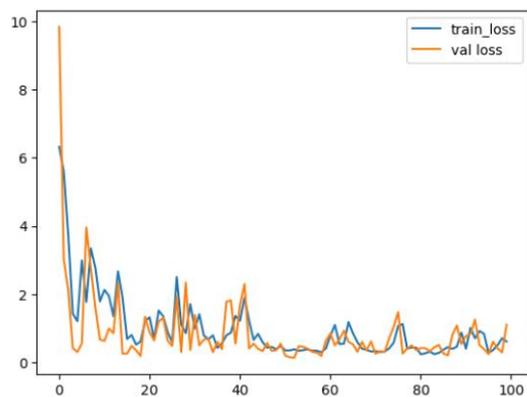


Gambar 9. Model Loss VGG16

Loss: Loss adalah fungsi yang menggambarkan kerugian yang berkaitan dengan probabilitas yang dihasilkan oleh model CNN. Loss function yang digunakan dalam penelitian ini adalah categorical cross-entropy. Salah satu syarat categorical crossentropy dapat digunakan adalah pada proses klasifikasi menggunakan fungsi aktivasi softmax. Categorical cross-entropy digunakan saat hanya terdapat satu hasil yang benar. Categorical cross-entropy akan membandingkan distribusi dari probabilitas prediksi dengan distribusi dari kelas yang benar (target), dimana probabilitas dari kelas yang benar diset dengan 1 dan untuk kelas yang lain.



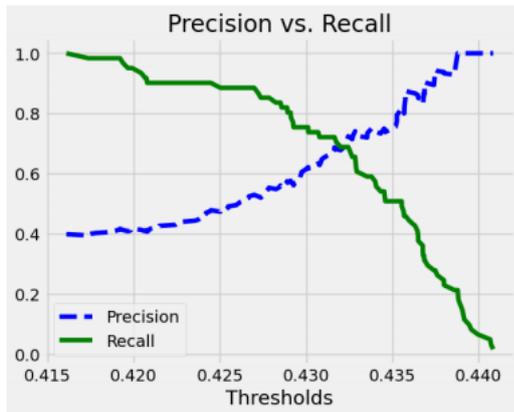
Gambar 10. Akurasi Model Resnet50



Gambar 11. loss Model Resnet50

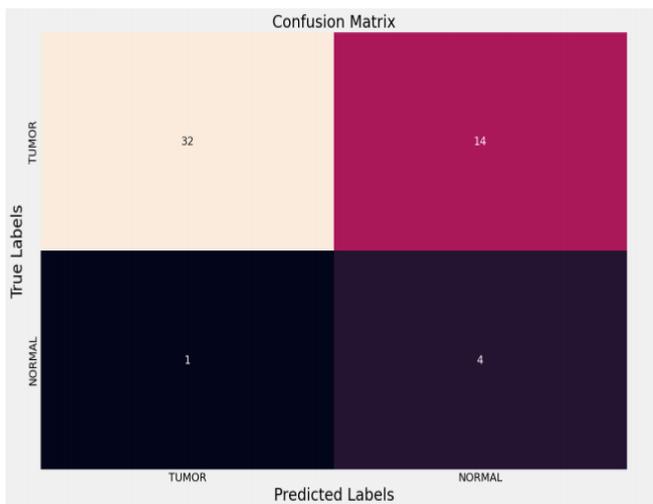
B. Hasil Proses Testing

Proses testing pada penelitian ini menggunakan 40 citra testing yang terdiri dari 20 citra YES(tumor) dan 20 citra NO(Normal). Proses testing dilakukan untuk menguji performa dari model CNN yang telah diperoleh dari proses learning. Variabel yang akan dinilai pada proses testing adalah 'Tumor' dan 'Normal' dari klasifikasi citra yang dihasilkan dari CNN.



Gambar 12. Presisi vs Recall

Pada gambar 12 ditampilkan data presisi vs recall dimana nilai presisi dapat dilihat pada nilai negatif pada confusion matrix pada gambar 13 sedangkan nilai recall yaitu nilai positif dapat dilihat pada gambar 13.



Gambar 13. Confusion Matrix

V. KESIMPULAN

Pada model CNN yang digunakan algoritman VGG16 dan RESNET50 Klasifikasi menunjukan hasil yang baik dengan

dataset MRI Tumor Otak. pendekatan klasifikasi mengurangi waktu pelabelan manual dan menghindari kesalahan manusia. Melalui teknik pembelajaran mesin, para peneliti berencana untuk mencapai presisi yang lebih baik dan akurasi dalam mengenali gambaran otak normal dan abnormal. Menurut percobaanhasil, teknik yang diusulkan efektif untuk klasifikasi gambar otak manusia dalam hal akurasi, sensitivitas, dan spesifisitas dengan nilai 70%, dan 80%. Tingkat akurasi telah terbukti dengan jelas bahwa algoritma yang diusulkan sangat baik dalam mengenali bagian yang terkena tumor dalam gambar MRI otak manusia.

REFERENSI

- [1] [1] Y. Dai and P. Zhuang, "Compressed sensing MRI via a multi-scale dilated residual convolution network," *Magn. Reson. Imaging*, vol. 63, no. March, pp. 93–104, 2019, doi: 10.1016/j.mri.2019.07.014.
- [2] [2] S. S. Roy, N. Rodrigues, and Y. H. Taguchi, "Incremental dilations using CNN for brain tumor classification," *Appl. Sci.*, vol. 10, no. 14, 2020, doi: 10.3390/app10144915.
- [3] [3] H. Mohsen, E.-S. A. El-Dahshan, E.-S. M. El-Horbaty, and A.-B. M. Salem, "Classification using deep learning neural networks for brain tumors," *Futur. Comput. Informatics J.*, vol. 3, no. 1, pp. 68–71, 2018, doi: 10.1016/j.fcij.2017.12.001.
- [4] [4] S. K. Lakshmanaprabu, S. N. Mohanty, K. Shankar, N. Arunkumar, and G. Ramirez, "Optimal deep learning model for classification of lung cancer on CT images," *Futur. Gener. Comput. Syst.*, vol. 92, pp. 374–382, 2019, doi: 10.1016/j.future.2018.10.009.
- [5] [5] D. Jude Hemanth, J. Anitha, A. Naaji, O. Geman, D. E. Popescu, and L. Hoang Son, "A Modified Deep Convolutional Neural Network for Abnormal Brain Image Classification," *IEEE Access*, vol. 7, pp. 4275–4283, 2019, doi: 10.1109/ACCESS.2018.2885639.
- [6] D. Theckedath and R. R. Sedamkar, "Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks," *SN Comput. Sci.*, vol. 1, no. 2, pp. 1–7, 2020, doi: 10.1007/s42979-020-0114-9.