

WORKSHOP MACHINE LEARNING KLASIFIKASI TUMOR OTAK PADA CITRA MRI MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN SUPPORT VECTOR MACHINE

Agus Eko Minarno¹, Denar Regata Akbi², Yuda Munarko³

^{1,2,3}Universitas Muhammadiyah Malang

aguseko@umm.ac.id, dnarregata@umm.ac.id, yuda@umm.ac.id

Abstract: *The brain is one of the organs that very important role for humans. Brain tumors can be a threat for humans. So that The researchers developed a Convolutional Neural Network (CNN) method that was tested effective for detecting brain tumors. CNN is a method that is quite popular, in its application it is used for image classification and several other image processing cases. CNN can be used to detect and recognize objects in an image better on an Artificial Neural Network. In addition, many researchers also use the SVM method, SVM can be applied to perform pattern recognition in the case of image processing. Brain tumors can be caused by the spread of cancer in parts of the other body. According to a report by the World Health Organization (WHO) brain cancer accounts for less than 2% of other cancers, but the severe morbidity and resulting complications are enormous. Brain cancer requires multidisciplinary treatment, so a professional standard policy is needed for optimal treatment. This activity proposes a Machine Learning Workshop on Brain Tumor Classification in Magnetic Resonance Imaging (MRI) Imagery using CNN and Support Vector Machine (SVM), in CNN activities can be divided into several parts such as CNN modeling, data preprocessing, building, and implementing CNN models in The SVM teaches how to build a hyperplane. This activity was delivered by expert speakers in their fields from alumni of the University of Muhammadiyah Malang.*

Keywords: *Machine Learning, CNN, SVM, Brain Tumor, MRI.*

PENDAHULUAN

Di tengah pesatnya perkembangan teknologi kecerdasan buatan atau *artificial intelligence* (AI) saat ini (Lu, 2019). Belum banyak orang yang mengetahui bahwa kecerdasan buatan itu terdiri dari beberapa cabang, salah satunya adalah *machine learning* atau pembelajaran mesin. Teknologi *machine learning* (ML) ini merupakan salah satu cabang dari AI yang sangat menarik perhatian karena *machine learning* merupakan mesin yang bisa belajar layaknya manusia. Kecerdasan buatan pada pengaplikasiannya secara garis besar terbagi tujuh cabang, yaitu *machine learning, natural language processing, expert system, vision, speech, planning* dan *robotics*. Percabangan dari kecerdasan buatan tersebut dimaksudkan untuk mempersempit ruang lingkup saat pengembangan atau belajar AI, karena pada dasarnya kecerdasan buatan memiliki ruang lingkup yang sangat luas.

Teknologi *machine learning* (ML) adalah mesin yang dikembangkan untuk bisa belajar dengan sendirinya tanpa arahan dari penggunaannya (Raschka, Patterson and Nolet, 2020). Pembelajaran mesin dikembangkan berdasarkan disiplin ilmu lainnya seperti statistika, matematika dan *data mining* sehingga mesin dapat belajar dengan menganalisa data tanpa perlu di program ulang atau diperintah. Dalam hal ini *machine learning* memiliki kemampuan untuk memperoleh data yang ada dengan perintah ia sendiri. ML juga dapat mempelajari data yang ada dan data yang ia peroleh sehingga bisa melakukan tugas tertentu. Tugas yang dapat dilakukan oleh ML pun sangat beragam, tergantung dari apa yang ia pelajari. Istilah *machine learning* pertama kali dikemukakan oleh beberapa ilmuwan matematika seperti Adrien Marie Legendre, Thomas Bayes dan Andrey Markov pada tahun 1920-an dengan mengemukakan dasar-dasar *machine learning* dan konsepnya. Sejak saat itu ML banyak yang mengembangkan. Salah satu contoh dari penerapan ML yang cukup terkenal adalah Deep Blue yang dibuat oleh IBM pada tahun 1996.

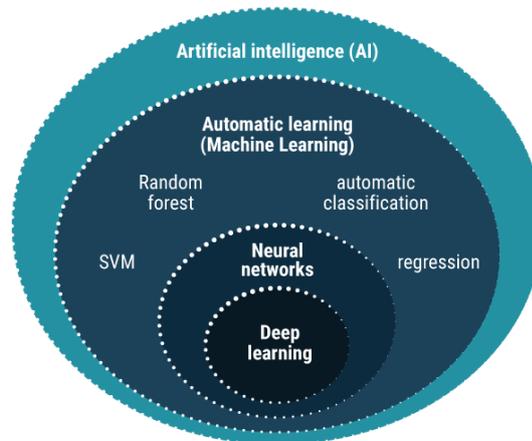
Peran *machine learning* banyak membantu manusia dalam berbagai bidang. Bahkan saat ini penerapan ML dapat dengan mudah ditemukan dalam kehidupan sehari-hari. Misalnya saat menggunakan fitur *face unlock* untuk membuka perangkat *smartphone*, atau saat menjelajah di internet atau media sosial akan sering disuguhkan dengan beberapa iklan. Iklan-iklan yang dimunculkan juga merupakan hasil pengolahan ML yang akan memberikan iklan sesuai dengan pribadi penggunanya. Konsep *Machine Learning* adalah membuat mesin belajar dan berperilaku dengan cara tertentu setelah memasukkan jenis data tertentu sebagai input. *Machine Learning* menawarkan beberapa Teknik untuk menyelesaikan permasalahan pengolahan data, seperti teknik *supervised learning* dan *unsupervised learning*.

Salah satu manfaat dari *Machine Learning* saat ini adalah teknologi ini mampu mengklarifikasi tumor pada otak. Pada saat ini mayoritas diagnosis penyakit pada seseorang pasti melibatkan teknologi sebagai media penunjang pemeriksaan oleh tenaga medis. Hal tersebut dilakukan karena faktor keakuratan teknologi yang ada saat ini sangatlah baik dan tingkat kemajuan teknologi juga sangat pesat. Teknologi yang biasa digunakan untuk mendiagnosis penyakit kanker otak adalah dengan menggunakan MRI (Azad *et al.*, 2022). MRI adalah salah satu metode pencitraan yang paling kuat dan serbaguna dalam pengobatan klinis. Fungsi dari teknologi ini adalah untuk mengambil potongan gambar organ pada tubuh pasien dengan menggunakan daya magnet kuat disekitar anggota tubuh pasien. Selama tiga dekade terakhir terdapat banyak sekali pengembangan terhadap MRI yang dapat menghasilkan informasi fungsional dan kuantitatif seperti jaringan mikroarsitektur dan aliran perfusi (Castillo, Lakshminarayanan and Rodríguez-Álvarez, 2021).

MRI digunakan untuk mendiagnosis penyakit tumor otak karena menurut penelitian teknologi ini tidak berbahaya kepada orang yang sakit jika dibandingkan dengan *CT Scan* (Xue *et al.*, 2019). Selain itu, kualitas gambar yang diperoleh juga dapat lebih baik sehingga dapat mempermudah diagnosis penyakit lebih awal (Chen *et al.*, 2020a). Sejak adanya teknologi ini, citra MRI yang tersedia di internet menjadi semakin banyak sehingga dapat memudahkan peneliti untuk membuat produk yang dapat membantu pekerjaan pekerja medis. Pada saat proses diagnosis oleh paramedis, pengambilan keputusan dan kesimpulan terhadap pasien tumor otak cenderung memakan waktu yang cukup lama (Chen *et al.*, 2020b). Sedangkan penanganan pasien tumor otak membutuhkan waktu yang sesegera mungkin agar mendapatkan perawatan yang sesuai dengan tumor yang diderita (Le *et al.*, 2020). Oleh karena itu dengan adanya banyak sumber yang menyediakan citra MRI penderita tumor otak membuat banyak peneliti lain yang menggunakannya untuk membuat sistem yang dapat melakukan klasifikasi tumor otak (Fei *et al.*, 2021). Dengan menggunakan metode *machine learning* dan *deep learning* yang saat ini sering dipakai untuk membuat sistem klasifikasi (Hao *et al.*, 2020), proses diagnosis yang dilakukan dengan menggunakan citra MRI tersebut dapat berjalan lebih singkat dan hasil yang akurat (Niyas *et al.*, 2021). Metode *machine learning* yang paling sering digunakan saat ini adalah KNN, *Neural Network*, SVM dan *Random Forest*. Sedangkan algoritma *deep learning* yang paling sering digunakan adalah *Convolution Neural Network* (CNN).

Artificial Intelligence (AI), merupakan topik yang lebih luas dimana mencakup *Machine Learning* dan *Deep Learning*, Gambar 1 menunjukkan hubungan antara AI, ML, dan DL (Lu, 2019). Terdapat dua kata pada *Artificial Intelligence*, *Artificial* berarti sesuatu yang diciptakan oleh manusia, *Intelligence* (kecerdasan) merupakan kemampuan untuk memahami sesuatu (Zhang and Tao, 2021). AI merupakan kecerdasan buatan yang

diterapkan pada suatu mesin, dimana memungkinkan mesin tersebut untuk bisa memahami sesuatu seperti yang dilakukan oleh manusia (Lu, 2019).



Gambar 1. Hubungan antara Artificial Intelligence, Machine Learning dan Deep Learning

Machine Learning merupakan bagian dari AI, dengan ML memungkinkan mesin untuk mengambil keputusan berdasarkan data. Algoritma ML dirancang agar dapat belajar dan kemampuan dari mesin tersebut dapat meningkat seiring waktu ketika terdapat data baru, tanpa diprogram ulang secara eksplisit. Sistem pendeteksi penyakit jantung berdasarkan rekaman elektrokardiogram (EKG) merupakan salah satu contoh penerapan dari ML (Raschka, Patterson and Nolet, 2020).

Deep Learning (DL), merupakan jenis dari ML yang dilatarbelakangi dari fungsi sel otak manusia yang disebut *neuron*, oleh karena hal tersebut muncul konsep yang dinamakan *Neural Network* (NN) (Zhou, Ruan and Canu, 2020). Pada domain DL, NN memiliki lebih dari dua layer. Terdapat beberapa hal yang bisa menjadi evolusi dari NN pada domain DL, diantaranya, dimungkinkan untuk mempunyai neuron lebih banyak dari jaringan sebelumnya, kompleksitas untuk menghubungkan neuron, dapat dimungkinkan ekstraksi fitur dilakukan secara otomatis. Pada arsitektur model deep learning belum terdapat panduan baku untuk penentuan jumlah hidden layer (Rawat and Wang, 2017).

Perbedaan algoritma ML dengan DL, Pada algoritma ML ekstraksi fitur menghasilkan vektor fitur, kemudian diklasifikasikan menggunakan algoritma ML, sedangkan pada DL, ekstraksi fitur dan klasifikasi dilakukan oleh dilakukan oleh *Neural Network*.

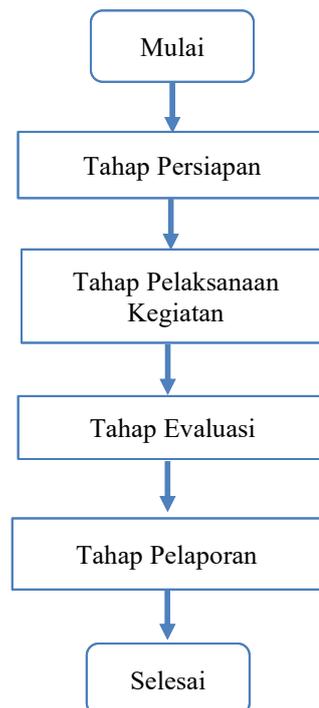
METODE

Kegiatan pengabdian ini dilakukan untuk memberikan pengetahuan terkait implementasi *machine learning* pada kasus tumor otak dengan sentuhan teknologi kecerdasan buatan atau AI. Bentuk kegiatan pengabdian ini dilakukan dengan mengadakan workshop machine learning klasifikasi tumor otak pada citra MRI menggunakan metode CNN dan SVM (Pisner and Schnyer, 2020). Kegiatan dilakukan secara daring.

Target utama dari kegiatan pengabdian ini memberikan pengetahuan dan pelatihan *machine learning* yang dapat berguna untuk berbagai bidang kehidupan, salah satunya adalah bidang kesehatan, beberapa tahapan pelaksanaan kegiatan diantaranya:

1. Tahap persiapan, pelaksanaan pengabdian ini diawali dengan koordinasi dengan tim pengabdian, untuk mempersiapkan bahan terkait topik *machine learning* dengan pokok bahasan klasifikasi data tumor otak pada citra MRI.

2. Tahap pelaksanaan kegiatan, mekanisme pelaksanaan kegiatan pengabdian ini dilakukan dengan metode ceramah yang dipaparkan oleh alumni Universitas Muhammadiyah Malang yang mempunyai kompetensi pada bidang *machine learning*. Konten materi yang dipaparkan terkait dengan bagian – bagian utama dalam CNN model, *data preprocessing*, pembangunan dan pengaplikasian model CNN.
3. Tahap evaluasi, kegiatan evaluasi dilakukan untuk mengetahui apakah materi yang telah dipaparkan dapat diterima dengan baik oleh peserta workshop. Kegiatan ini dilakukan dengan melakukan diskusi dan diselingi dengan pertanyaan dari pematiri.
4. Tahap Pelaporan, kegiatan pelaporan merupakan tahapan untuk mempersiapkan penyusunan laporan kegiatan pengabdian sebagai bukti bahwa kegiatan pengabdian telah terlaksana.

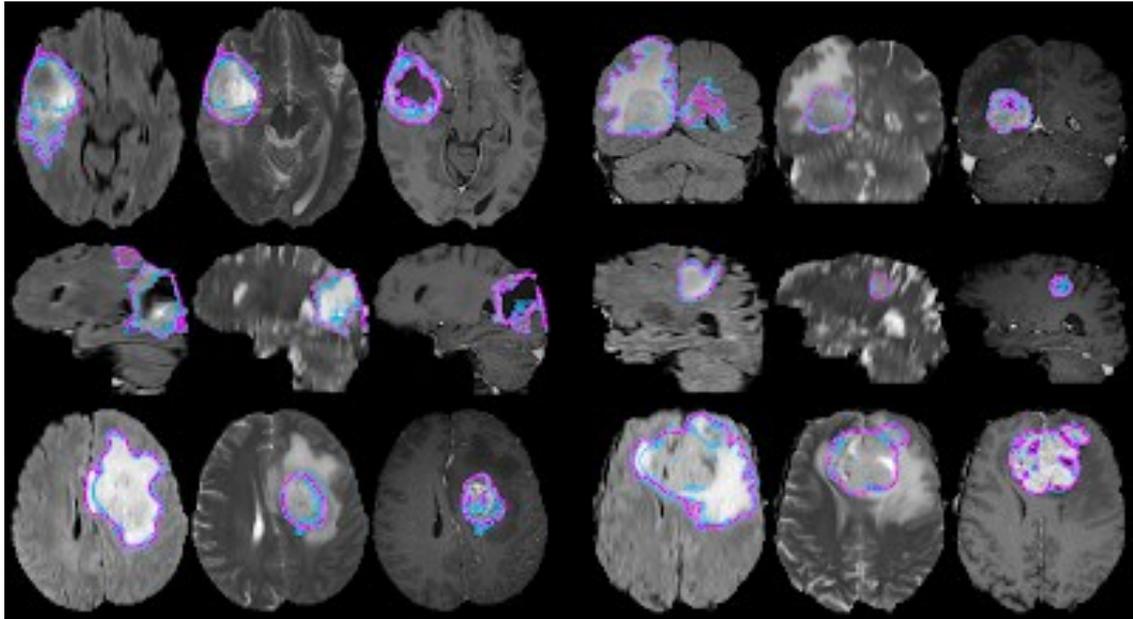


Gambar 2. Tahapan Pelaksanaan Pengabdian

HASIL KARYA UTAMA DAN PEMBAHASAN

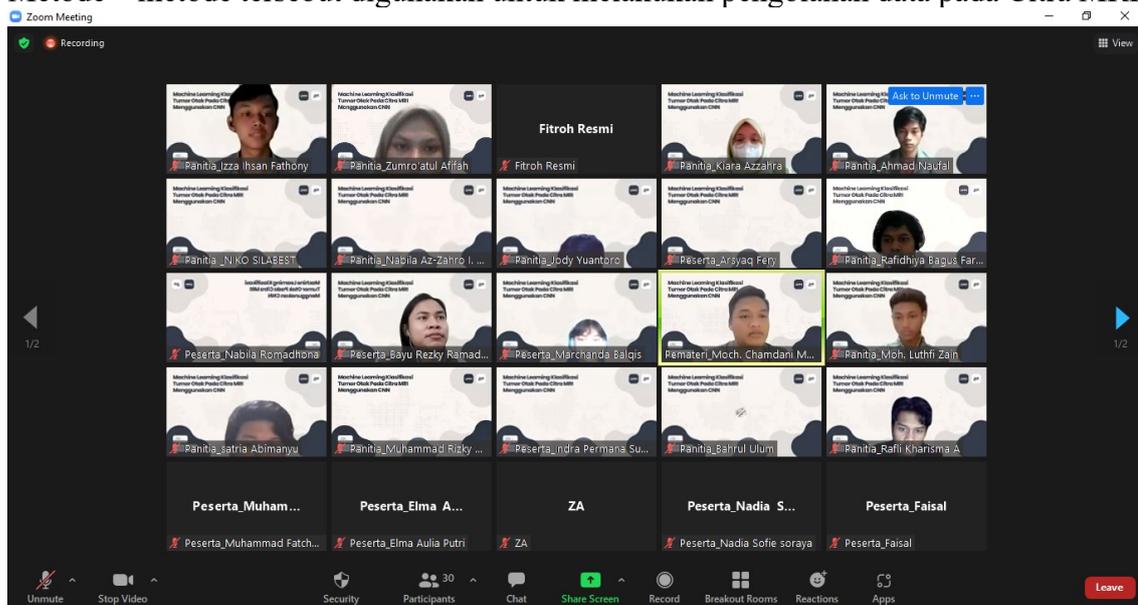
Organ tubuh yang berperan penting bagi manusia adalah otak. Penyakit tumor otak merupakan ancaman bagi manusia. Pelaksanaan pengabdian ini memerlukan data tumor otak, data yang digunakan pada pengabdian ini diambil dari data public, BraTS 2015. Gambar 3.

Dataset BraTS 2015 merupakan dataset segmentasi citra tumor otak, yang terdiri dari 220 MRI glioma tingkat tinggi (HGG), 54 glioma tingkat rendah (LGG). Empat modalitas MRI adalah T1, T1c, T2, dan T2FLAIR. Segmentasi "Ground Truth" menyediakan sekitar empat kelas intra-tumoral diantaranya edema, tumor peningkat, tumor non-peningkat, dan nekrosis (Menze *et al.*, 2014).



Gambar 3. Sampel data tumor otak

Metode pengolahan data pada pengabdian ini menggunakan CNN dan SVM. Metode – metode tersebut digunakan untuk melakukan pengolahan data pada Citra MRI.

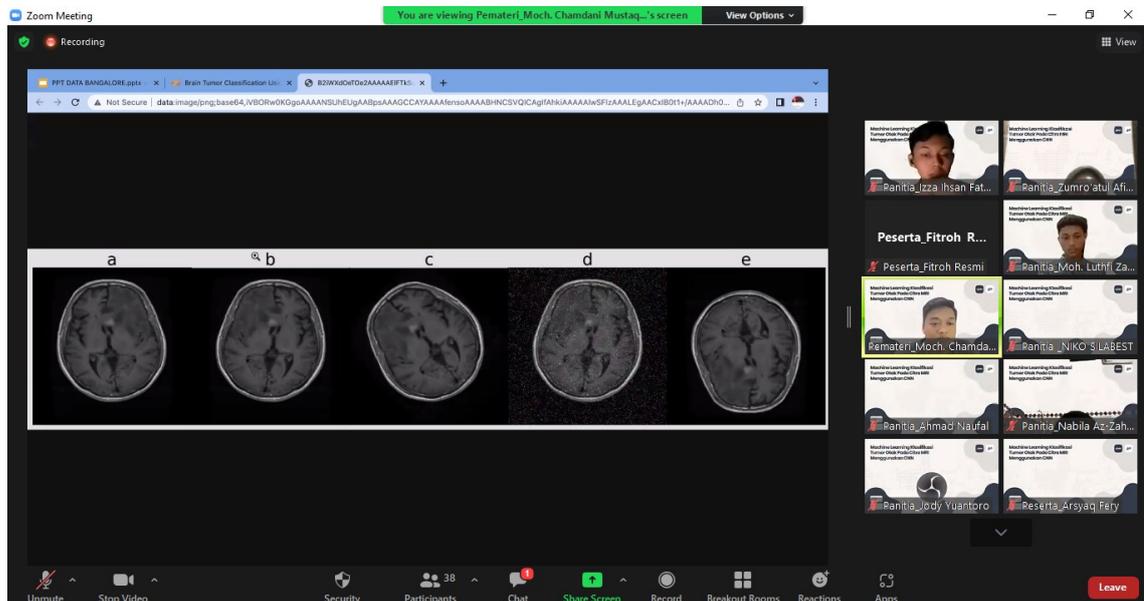


Gambar 4. Opening kegiatan *Workshop*

Hasil karya kegiatan pengabdian ini adalah memberikan pengetahuan dan pelatihan *machine learning* pada peserta pelatihan. Pelatihan yang dilakukan mengambil kasus pada bidang Kesehatan dengan objek yang diolah adalah data tumor otak. Peserta pelatihan diberikan wawasan, penggunaan *machine learning* dapat mempermudah proses analisis ataupun deteksi pada tumor otak. Data tumor otak diberikan pada suatu *machine* dan *machine* diminta untuk mempelajari data tersebut, semakin banyak data yang diberikan maka *machine* bertambah pintar, jika hal tersebut dilakukan dapat berdampak pada keakuratan proses analisis ataupun deteksi tumor pada otak. Penerapan *machine learning* tidak terbatas hanya pada bidang Kesehatan, tetapi bisa diterapkan pada berbagai bidang kehidupan.

Pelaksanaan pelatihan diawali dengan pembukaan, mulai dari tata tertib pelaksanaan pelatihan, pengenalan instruktur pelatihan, materi yang akan dipelajari, data yang digunakan, serta outcome yang didapat dari kegiatan pelatihan ini. Gambar 4.

Tahap selanjutnya peserta diberikan materi terkait klasifikasi secara umum kemudian dikaitkan dengan data tumor pada otak manusia. Kegiatan ini dimulai dengan pengenalan dasar klasifikasi, dimana terdapat penjelasan yang memaparkan pada dasarnya klasifikasi merupakan proses membagi sekumpulan data sehingga setiap data menjadi anggota suatu kategori atau kelas. Keanggotaan setiap data pada sebuah kelas bersifat *mutually exclusive* dimana setiap data hanya dapat menjadi anggota sebuah kelas saja. Sebuah data tidak boleh menjadi anggota lebih dari satu kelas atau tidak menjadi anggota suatu kelas sama sekali.

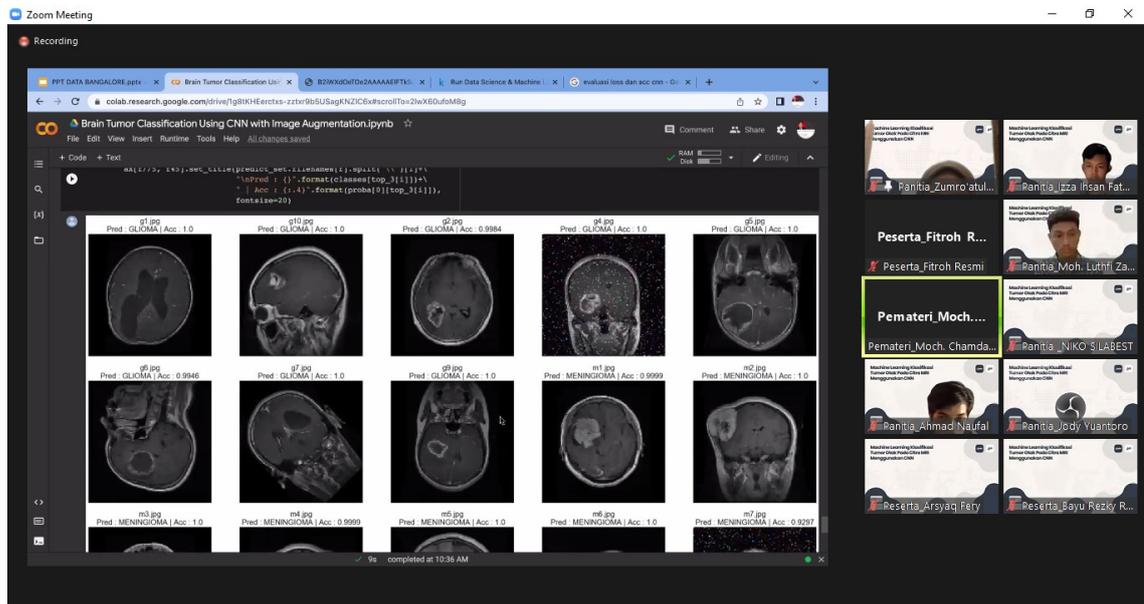


Gambar 5. Klasifikasi tumor otak pada manusia

Berbagai kasus pengambilan keputusan atau pengelompokan dapat diformulasikan sebagai permasalahan klasifikasi yaitu menempatkan sebuah objek atau orang kedalam sebuah kelas atau kategori tertentu. Berbagai metode klasifikasi menggunakan pendekatan yang mirip untuk menentukan kelas dari suatu data. Setiap teknik klasifikasi menggunakan sebuah algoritma pembelajaran untuk membentuk suatu model yang menjelaskan relasi antara variabel dan kelas dari data yang telah diketahui kelasnya. Model yang dihasilkan seharusnya mampu mengenali pula kelas dari suatu data baru yang belum diketahui kelasnya. Dengan demikian, tujuan utama dari sebuah algoritma klasifikasi adalah membentuk model yang memiliki generalisasi yang baik.

Penjelasan dasar terkait klasifikasi tersebut diberikan agar peserta memiliki gambaran terkait dasar klasifikasi, setelah itu peserta diberikan gambaran implementasi dasar klasifikasi pada data tumor otak, Gambar 5. Setelah mendapatkan dasar dari klasifikasi, peserta pelatihan diberikan wawasan hasil dengan menerapkan metode – metode klasifikasi CNN dan SVM. Pada kegiatan ini peserta diminta untuk menjalankan kode – kode dari metode CNN dan SVM yang diterapkan pada data tumor otak yang diambil dari BriTS 2015, setelah itu peserta diminta untuk melihat dan melakukan analisis hasil pengolahan data yang telah dilakukan menggunakan metode – metode tersebut. Peserta pada tahap ini tidak diminta untuk membuat kode – kode sendiri, dikarenakan

target utama dari tahap ini adalah peserta dapat mendapatkan gambaran terkait penerapan metode CNN dan SVM pada data tumor otak. Gambar 6.



Gambar 6. Hasil klasifikasi tumor otak manusia

Tahap selanjutnya, peserta diberikan teori dasar terkait metode CNN dan SVM. Teori dasar ini diberikan setelah peserta melihat dan melakukan analisis hasil dari klasifikasi data tumor otak menggunakan metode – metode tersebut pada tahap sebelumnya, hal ini dilakukan untuk menambah antusias dari peserta untuk mempelajari metode CNN dan SVM. Gambar 7.

Konsep metode SVM yang diberikan diawali dengan penjelasan bagaimana SVM berusaha menemukan *hyperplane* terbaik pada *input space*, *linear classfier* merupakan prinsip dasar dari SVM, dengan perkembangan yang ada SVM juga bisa diterapkan pada problem *non-linear classfier*. *Hyperplane* terbaik digunakan sebagai pemisah antara dua buah kelas pada *input space*. Pada penjelasan metode SVM ini peserta ditekankan bahwa pada metode SVM untuk mendapatkan *hyperplane* terbaik dilakukan dengan mengukur margin dari *hyperplane* tersebut. Margin adalah jarak antara *hyperplane* dengan *pattern* terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*.

Konsep metode CNN yang diberikan diawali dengan pengenalan CNN, dimana CNN merupakan jenis neural network khusus untuk memproses data yang memiliki topologi grid, data grid merupakan data citra, citra merupakan data grid piksel 2 dimensi. CNN menggunakan operasi matematika yang disebut konvolusi, serta memiliki tiga jenis layer utama: *convolution layer*, *pooling layer*, dan *fully-connected layer*.

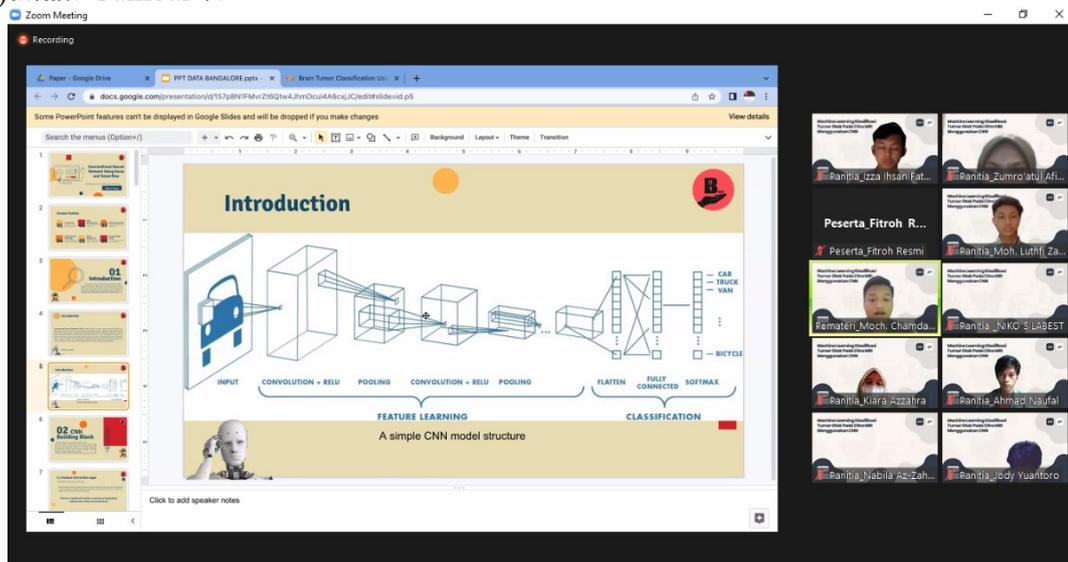
Convolution layer, merupakan layer inti dari CNN, dimana sebagian besar komputasi terjadi pada layer ini. Terdapat beberapa komponen penting diantaranya input data, *kernel (filter)*, serta *feature map*. Pada teori ini peserta dijelaskan contoh dari input data, yang mana data citra yang digunakan akan diinputkan pada bagian ini. *Kernel (filter)* bagian ini merupakan bagian dimana operasi konvolusi terjadi, proses operasi konvolusi yang terjadi adalah *kernel (filter)* akan bergerak melintasi citra dan melakukan operasi dot antara input dan nilai dari *filter* sehingga menghasilkan sebuah output yang disebut dengan *feature map*.

Pada bagian *Convolution layer*, peserta pelatihan diberikan materi lanjutan terkait *filter*, dimana *filter* merupakan array dua dimensi, *filter* mempunyai nilai yang disebut dengan *weight* atau bobot yang dapat diupdate saat proses *training* data. Terdapat beberapa hyperparameter yang mempengaruhi ukuran dari *feature map*, diantaranya:

1. Jumlah *filter*, jumlah dari *filter* dapat mempengaruhi kanal output. Sebagai contoh terdapat dua *filter* yang berbeda akan menghasilkan dua *feature map* berbeda, sehingga *output* memiliki dua kanal
2. *Stride*, merupakan jarak perpindahan saat proses konvolusi. Semakin besar nilai *stride*, maka semakin kecil ukuran *output* yang dihasilkan.
3. *Padding*, merupakan penambahan nilai pada elemen terluar citra. Nilai yang biasa ditambahkan adalah 0. *Padding* mempunyai tiga tipe:
 - a. *Valid padding* atau biasa disebut dengan tanpa *padding*. Pada *padding* ini, *feature map* yang dihasilkan pada proses *convolution* akan lebih kecil dibandingkan dengan *input*.
 - b. *Same padding*, pada *padding* ini ukuran *feature map* yang dihasilkan pada proses *convolution* sama dengan *input*.
 - c. *Full padding*, pada *padding* ini ukuran *feature map* yang dihasilkan pada proses *convolution* lebih besar dibandingkan dengan *input*.

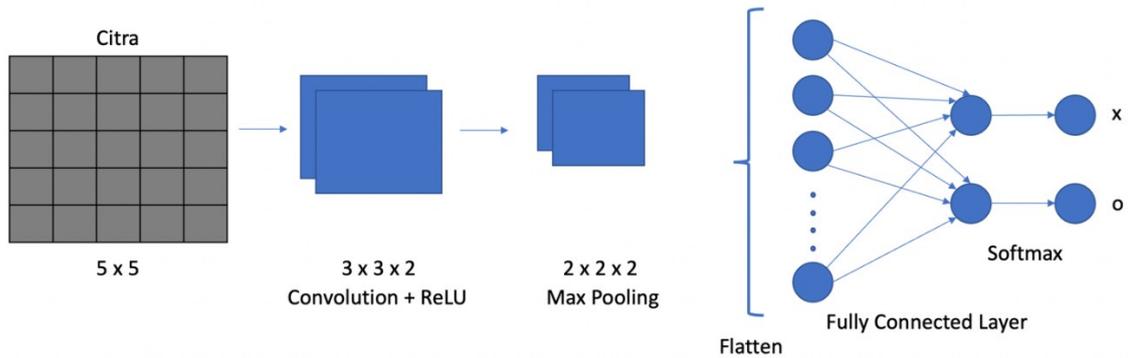
Pooling layer, berfungsi untuk mengurangi dimensi dan jumlah parameter, biasa disebut dengan *downsampling*, selain itu fungsi lain adalah untuk mengekstraksi fitur dominan. Peserta pelatihan dikenalkan dua jenis *pooling* yang sering digunakan yaitu: *max pooling* dan *average pooling*, perbedaan dari kedua jenis *pooling* tersebut adalah *max pooling*, mengembalikan nilai maksimum dari data citra yang dicakup oleh *kernel*, sedangkan *average pooling*, mengembalikan nilai rata – rata dari data citra yang dicakup oleh *kernel*.

Proses konvolusi yang terjadi pada *kernel (filter)* menghasilkan *feature map* dalam bentuk *multidimensional array*, sehingga proses *reshape* harus dilakukan agar menjadi vektor sehingga bisa digunakan sebagai input dari *fully-connected layer*. Proses yang terjadi pada *fully-connected layer* memanfaatkan suatu *activation function* untuk melakukan klasifikasi, pada bagian ini peserta pelatihan dikenalkan dengan *activation function softmax*. Gambar 7.



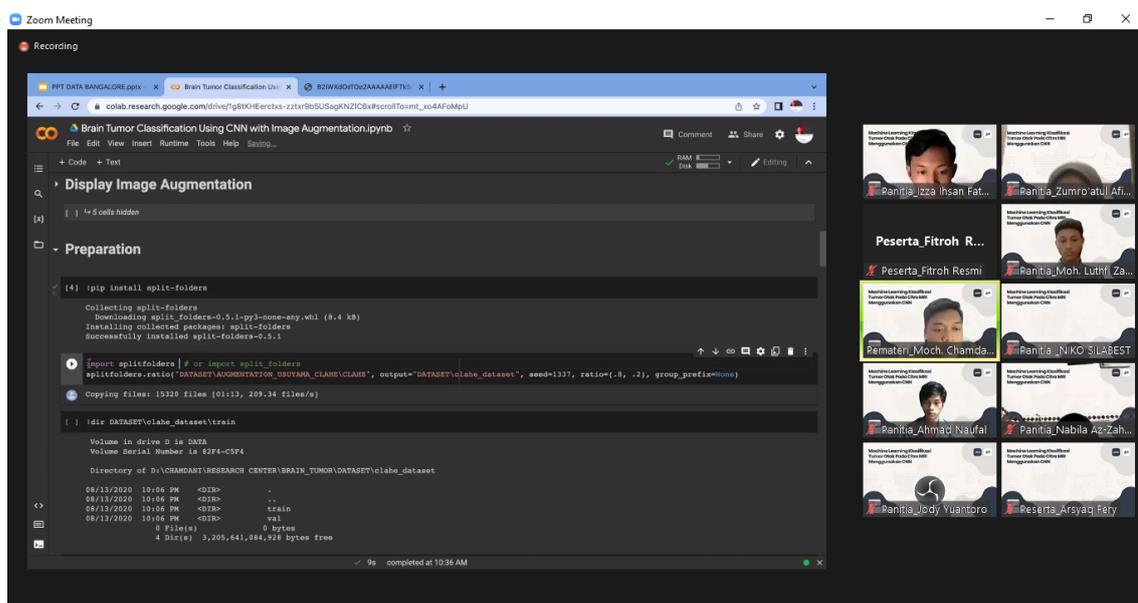
Gambar 7. Pengenalan simple model CNN kepada peserta

Ilustrasi sederhana dari proses yang terjadi pada CNN dipilih oleh pemateri agar peserta dapat lebih memahami proses – proses yang terjadi pada CNN.

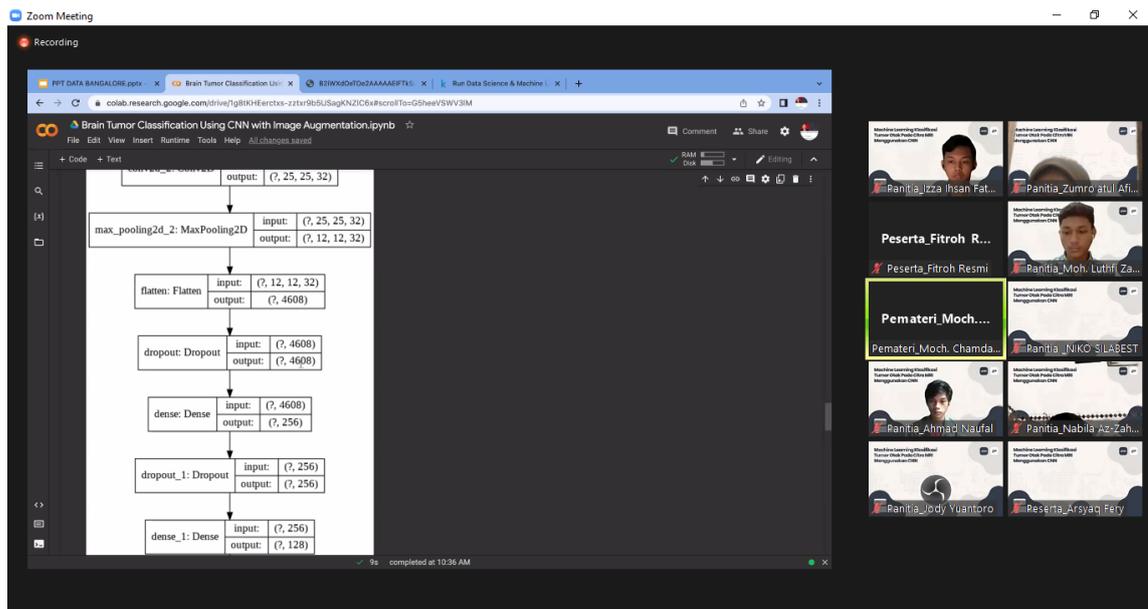


Gambar 8. Gambaran Arsitektur CNN

Pada Gambaran Arsitektur CNN, Gambar 8, dijelaskan pada peserta pelatihan dimana CNN digunakan untuk melakukan klasifikasi bentuk citra terhadap dua kelas, kelas x dan kelas o. Input yang digunakan merupakan citra 5 x 5, kemudian dilakukan proses convolution, kemudian proses selanjutnya adalah menerapkan activation menggunakan ReLU, *activation* ini diterapkan untuk meningkatkan non-linieritas pada citra. Tahapan pada proses selanjutnya adalah *pooling layer* menggunakan *max pooling* dengan *kernel* berukuran 2 x 2 dan *stride* 1, *max pooling* dilakukan pada *feature map* yang merupakan hasil dari proses *convolution* dan ReLU pada tahapan sebelumnya. *Feature map* diubah dari multidimensional *array* menjadi *vector (flatten)* agar bisa digunakan sebagai input dari *fully-connected layer*. Gambar 8, menunjukkan hasil *flatten* dihubungkan ke dua *neuron*, setiap koneksi pada *neuron* terdapat *weights* yang terkait, nilai *weights* didapat saat proses *training*. Kemudian peserta dijelaskan activation function softmax diterapkan pada 2 neuron tersebut untuk menghitung probabilitas dari kelas, setelah itu akan terlihat nilai probabilitas yang paling besar terletak pada kelas x atau kelas o, nilai probabilitas yang paling besar menunjukkan bahwa CNN memprediksi citra input pada suatu kelas tersebut.



Gambar 9. Kegiatan penyampaian Materi *Workshop*



Gambar 10. Kegiatan penyampaian Materi *Workshop*

Penjelasan teori CNN dilanjutkan dengan pemateri meminta peserta untuk melakukan percobaan implementasi kode – kode CNN pada data tumor otak. Pada proses ini peserta sudah disediakan kode – kode dari CNN dan menjalankannya pada google colab, sehingga peserta tidak perlu membuat kode dari awal, hal ini dilakukan untuk meminimalisir terjadinya error pada penulisan kode CNN, sehingga target pada tahapan ini adalah peserta diminta untuk melakukan analisis kode dan analisis hasil yang didapatkan dari proses klasifikasi tumor otak, selain itu pada tahapan ini pemateri juga membuka sesi pertanyaan jika terdapat peserta yang masih mengalami kendala pada analisis kode dan analisis hasil dari implementasi kode CNN yang telah diberikan. Gambar 9. Penjelasan teori pada Gambar 8, diimplementasikan pada Gambar 10, pemateri menginstruksikan pada peserta pelatihan untuk melakukan analisis terhadap arsitektur CNN dengan parameter yang disesuaikan dengan kasus tumor otak yang digunakan pada saat pelatihan ini dilakukan.

Kegiatan pelatihan ini diikuti oleh 25 mahasiswa dengan 50% peserta memiliki pengetahuan aljabar dan algoritma dan struktur data tingkat dasar. Berdasarkan hasil evaluasi kegiatan bahwa kemampuan aljabar dasar sangat mempengaruhi kemampuan berfikir dan merancang alur program. Mahasiswa yang memiliki pengetahuan dasar algoritma dan struktur data memiliki kemampuan menulis kode program machine learning dengan bahasa pemrograman Python lebih baik.

KESIMPULAN

Seluruh rangkaian kegiatan acara *Workshop* Machine Learning Klasifikasi Tumor Otak pada Citra MRI Menggunakan *Convolutional Neural Network* dan *Support Vector Machine* ini 100% dapat berjalan dengan baik. Setelah mengikuti pelatihan ini mahasiswa memiliki kemampuan melakukan klasifikasi menggunakan *machine learning* menggunakan data tumor otak dan mampu melakukan modifikasi kode program menggunakan data sendiri. Kemampuan peserta meningkat tampak dari beberapa tantangan dalam melakukan modifikasi kode program menggunakan kasus dataset yang lain.

DAFTAR PUSTAKA

- Azad, R. *et al.* (2022) “Medical Image Segmentation on MRI Images with Missing Modalities: A Review.” Available at: <http://arxiv.org/abs/2203.06217>.
- Castillo, D., Lakshminarayanan, V. and Rodríguez-Álvarez, M.J. (2021) *MRI Images, Brain Lesions and Deep Learning*.
- Chen, C. *et al.* (2020a) “Robust Multimodal Brain Tumor Segmentation via Feature Disentanglement and Gated Fusion.” Available at: <http://arxiv.org/abs/2002.09708>.
- Chen, C. *et al.* (2020b) “Robust Multimodal Brain Tumor Segmentation via Feature Disentanglement and Gated Fusion.” Available at: <http://arxiv.org/abs/2002.09708>.
- Fei, Y. *et al.* (2021) *Deep Learning based Multi-modal Computing with Feature Disentanglement for MRI Image Synthesis*.
- Hao, R. *et al.* (2020) *A Transfer Learning Based Active Learning Framework for Brain Tumor Classification*.
- Le, N. *et al.* (2020) “A Multi-task Contextual Atrous Residual Network for Brain Tumor Detection & Segmentation.” Available at: <http://arxiv.org/abs/2012.02073>.
- Lu, Y. (2019) “Artificial intelligence: a survey on evolution, models, applications and future trends,” *Journal of Management Analytics*, 6(1), pp. 1–29. doi:10.1080/23270012.2019.1570365.
- Menze, B.H. and J. *et al.* (2014) “The multimodal brain tumor image segmentation benchmark (BRATS),” *IEEE transactions on medical imaging*, 34, pp. 1993–2024.
- Niyas, S. *et al.* (2021) “Medical Image Segmentation with 3D Convolutional Neural Networks: A Survey.” Available at: <http://arxiv.org/abs/2108.08467>.
- Pisner, D.A. and Schnyer, D.M. (2020) “Chapter 6 - Support vector machine,” in Mechelli, A. and Vieira, S. (eds) *Machine Learning*. Academic Press, pp. 101–121. doi:<https://doi.org/10.1016/B978-0-12-815739-8.00006-7>.
- Raschka, S., Patterson, J. and Nolet, C. (2020) “Machine Learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence.” Available at: <http://arxiv.org/abs/2002.04803>.
- Rawat, W. and Wang, Z. (2017) “Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review,” *Neural Computation*, 29(9), pp. 2352–2449. doi:10.1162/neco_a_00990.
- Xue, Y. *et al.* (2019) “A multi-path 2.5 dimensional convolutional neural network system for segmenting stroke lesions in brain MRI images.” Available at: <http://arxiv.org/abs/1905.10835>.
- Zhang, J. and Tao, D. (2021) “Empowering Things With Intelligence: A Survey of the Progress, Challenges, and Opportunities in Artificial Intelligence of Things,” *IEEE Internet of Things Journal*, 8(10), pp. 7789–7817. doi:10.1109/JIOT.2020.3039359.
- Zhou, T., Ruan, S. and Canu, S. (2020) “A review: Deep learning for medical image segmentation using multi-modality fusion.” doi:10.1016/j.array.2019.100004.