



Klasifikasi Konsentrasi PM₁₀ Berbasis Gambar Dengan Convolutional Neural Network

Michael Angandowa Boeaya¹, Riska Meyliana Sari², Eris Girasto³, Shafira Husna⁴,
Robert Kurniawan⁵

^{1,2,3,4}Program Studi Statistika, Politeknik Statistika STIS, Jakarta, Indonesia

⁵Program Studi Komputasi Statistik, Politeknik Statistika STIS, Jakarta, Indonesia

¹212112186@stis.ac.id

²212112326@stis.ac.id

³212112024@stis.ac.id

⁴212112361@stis.ac.id

⁵robertk@stis.ac.id

Corresponding author email: 212112186@stis.ac.id

Abstract: Air pollution is a crucial environmental problem. One of the air quality indicators is the concentration of PM₁₀, which is particulate matter less than 10 microns in size. Unfortunately, PM₁₀ monitoring in Indonesia is only available at 15 observation stations. In fact, the availability of PM₁₀ information in real time is important for pollution control and health protection. Therefore, this research focuses on sky image-based PM₁₀ concentration analysis by utilizing photos taken using smartphone cameras. By applying CNN, PM₁₀ concentration estimation can be done in real time. To achieve the goal, a total of 300 image data were retrieved from Beijing tourism web along with PM₁₀ attributes. The images were classified into three categories: 'good', 'moderate', and 'unhealthy'. A total of 80% of the data is used to train six variations of CNN models. Furthermore, the model with the highest accuracy will be selected as the best model. The results show that CNN architecture with Leaky ReLU activation function and average pooling is valid to classify images based on PM₁₀ concentration. The results of this study can be a powerful tools for improving public health and reducing the impact of air pollution.

Keywords: Air Pollution, Particulate Matter 10, Convolutional Neural Network, Image Classification

Abstrak: Polusi udara merupakan masalah lingkungan yang krusial. Salah satu indikator kualitas udara adalah konsentrasi PM₁₀, yakni *particulate matter* berukuran kurang dari 10 mikron. Sayangnya, monitoring PM₁₀ di Indonesia hanya tersedia pada 15 stasiun pengamatan. Padahal, ketersediaan informasi PM₁₀ secara *real time* penting untuk pengendalian polusi dan perlindungan kesehatan. Oleh karena itu, penelitian ini berfokus pada analisis konsentrasi PM₁₀ berbasis gambar langit dengan memanfaatkan foto yang diambil menggunakan kamera *smartphone*. Dengan menerapkan CNN, estimasi konsentrasi PM₁₀ dapat dilakukan secara *real time*. Untuk mencapai tujuan tersebut, sebanyak 300 data gambar diambil dari web pariwisata Beijing beserta atribut PM₁₀. Gambar diklasifikasikan dalam tiga kategori yakni 'baik', 'sedang', dan 'tidak sehat'. Sebanyak 80% data digunakan untuk melatih enam variasi model CNN. Hasil penelitian ini menunjukkan bahwa arsitektur CNN dengan fungsi aktivasi *Leaky ReLU* dan *average pooling* valid untuk mengklasifikasikan gambar berdasarkan konsentrasi PM₁₀. Hasil penelitian ini dapat menjadi instrumen yang lebih maju dalam meningkatkan kesehatan publik dan meminimalisir dampak polusi udara.

Kata kunci: Polusi Udara, Particulate Matter 10, Convolutional Neural Network, Klasifikasi Gambar

I. PENDAHULUAN

Polusi udara merupakan salah satu permasalahan lingkungan yang sangat krusial dan mengkhawatirkan secara global [1]. Era industrialisasi memperburuk polusi udara dan berdampak pada kesehatan secara umum. Polusi udara menyebabkan 7 juta kematian setiap tahun dan merupakan penyebab kematian terbesar kedua di dunia [2] dan peringkat dua di Indonesia sebagai penyebab kematian yang bersumber dari pembakaran bahan bakar padat yang menurunkan kualitas udara di Indonesia [3].

Tidak hanya risiko kematian, beberapa penelitian mengkaji dampak polusi udara terhadap



kesehatan dan sosial ekonomi. Polusi udara berkaitan erat dengan penyakit tidak menular termasuk penyakit kardiovaskular dan pernafasan kronis serta kanker paru-paru [4]. Penelitian yang dilakukan oleh [5] menyebutkan bahwa polusi udara menyebabkan penurunan berat bayi lahir dan berdasarkan hasil diperoleh konsentrasi *particulate matter* (PM) yang meningkat $10 \mu\text{gram}/\text{m}^3$ pada trimester pertama akan menurunkan 4.3 gram berat bayi lahir dan penurunan sebesar 7.6-6 gram per kenaikan sebesar $100 \mu\text{gram}/\text{m}^3$. Penelitian lain menyebutkan bahwa polusi udara sangat berbahaya dan mampu mengakibatkan perubahan pada struktur gen manusia [6]. Disamping itu, [7] juga menyebutkan bahwa polusi udara berdampak pula pembiayaan ekonomi. Akibat pembengkakan pengeluaran negara pada pembiayaan pelayanan kesehatan, terjadi penurunan kemampuan negara dalam membiayai sektor lain. Sejalan dengan itu, kerugian yang diakibatkan polusi udara di Provinsi Jakarta diperkirakan mampu mencapai 2943,42 juta dollar [8].

Salah satu tolak ukur tingkat polusi udara yakni konsentrasi *particulate matter* (PM₁₀) atau partikel penyusun udara yang berukuran lebih kecil dari 10 μm . Sumber PM₁₀ antara lain pembakaran solar dan bensin pada mesin mobil, pembakaran batu bara, minyak berat dan biomassa untuk produksi energi rumah tangga dan pabrik, proses pembakaran pada industri dan manufaktur (bahan konstruksi dan bangunan, pertambangan, keramik dan batu bata, serta peleburan) [9]. Pemahaman tentang kadar PM₁₀ dalam udara penting untuk mencegah adanya efek negatif yang ditimbulkan. Menurut [10] dan [11], peningkatan PM₁₀ sebesar $10 \text{ g}/\text{m}^3$ dapat meningkatkan risiko kematian akibat serangan jantung dan penyakit pernapasan lainnya. Penelitian yang dilakukan oleh [12] menyebutkan bahwa peningkatan jumlah kematian di Brazil akibat peningkatan konsentrasi polutan PM₁₀ yang melebihi batas aman WHO ($10 \text{ g}/\text{m}^3$) mencapai sekitar 36 persen.

Meningkatnya angka kematian akibat polusi udara membutuhkan solusi preventif. Oleh karena itu, sangat penting bagi seseorang untuk memperhatikan kualitas udara di lingkungan sekitar dan menggunakan alat pelindung pernapasan seperti masker. Selain itu, kesadaran penuh untuk lebih memperhatikan lingkungan juga mendukung tujuan *Sustainable Development Goals* 13 yaitu *climate action*, salah satu caranya dengan melakukan tindakan preventif.

Pada era digitalisasi, segala bentuk informasi dapat disediakan secara cepat dan *real time*. Saat ini, teknologi sudah banyak diimplementasikan dalam menyelesaikan berbagai permasalahan. Salah satu bentuk pemanfaatan teknologi dalam upaya preventif yakni *monitoring* konsentrasi polutan PM₁₀. Data mengenai kondisi polutan udara yang disajikan secara *real time* akan sangat berguna dalam meningkatkan kualitas kesehatan publik. Namun, sedikitnya stasiun pemantau kualitas udara berakibat pada sedikitnya informasi tentang kualitas udara secara *real time*. Hingga saat ini, hanya terdapat di 15 stasiun pemantauan *Suspended Particulated Matter* (SPM) yang dimiliki oleh Badan Klimatologi, Meteorologi, dan Geofisika (BMKG). Padahal, kondisi udara tidak dapat digeneralisasi, terlebih pada wilayah Indonesia yang memiliki heterogenitas yang tinggi. Selain itu, pengukuran konsentrasi PM₁₀ oleh BMKG masih menggunakan metode penyinaran sinar Beta (*Beta Attenuation Monitoring*) yang kurang efisien dalam biaya dan perawatan.

Untuk memenuhi kebutuhan itu, diperlukan instrumen yang lebih andal dan efisien dalam *monitoring* kualitas udara. Salah satunya dengan pemanfaatan citra digital/gambar. Beberapa penelitian mengenai estimasi konten udara berbasis gambar sudah pernah dilakukan. Namun, kebanyakan penelitian berfokus pada estimasi konsentrasi PM_{2.5} saja. Padahal, *monitoring* konsentrasi PM₁₀ merupakan *screening* awal dalam menggambarkan keparahan polusi udara.

[13] mengestimasi konsentrasi PM_{2.5} dengan memperkenalkan desain baru *Picture-based*



Predictor of PM_{2.5} Concentration (PPPC). Tidak seperti penelitian lainnya, estimasi dilakukan hanya berdasarkan informasi gambar, tanpa menggunakan informasi pendukung. Dalam penelitiannya, terdapat sebelas model yang diajukan. Kesebelas model diklasifikasikan ke dalam empat tipe. Hasil penelitian menunjukkan bahwa model PPPC yang diajukan peneliti memiliki akurasi terbaik dibandingkan ketiga tipe lainnya.

Penelitian yang dilakukan oleh [1] menggunakan 591 gambar untuk mengklasifikasikan kualitas udara di Beijing dengan menggunakan *convolutional neural network*. Kualitas udara diklasifikasikan menjadi tiga kelas, yaitu “Baik”, “Sedang”, dan “Buruk”. Penelitian ini membandingkan tingkat akurasi antara klasifikasi menggunakan metode *Random Forest* menggunakan data numerik PM_{2.5} dan metode *convolutional neural network* dengan data gambar. Hasil penelitian ini menunjukkan bahwa akurasi model CNN yang menggunakan data gambar lebih besar dibanding akurasi model *random forest*, yaitu sebesar 68,74 persen. Namun, penelitian ini menggunakan nilai PM_{2.5} sebagai dasar untuk mengklasifikasikan kualitas udara dan tidak mengambil PM₁₀ sebagai dasar pengklasifikasian. Padahal, seperti yang sudah dijelaskan sebelumnya bahwa monitoring konsentrasi PM₁₀ dapat menjadi *screening* awal dalam menggambarkan keparahan polusi udara.

Dari paparan di atas, diperlukan penelitian yang dapat mengakomodasi kebutuhan *monitoring* kualitas udara yang lebih efisien dan *realtime*. Oleh karena itu, penelitian ini bertujuan untuk menyediakan sistem klasifikasi kualitas udara berdasarkan konsentrasi PM₁₀ yang dapat dilakukan secara *realtime* dan efisien secara biaya. Harapannya, penelitian ini dapat berkontribusi pada pembangunan lingkungan hidup dengan menyediakan instrumen yang lebih maju dalam meningkatkan kesehatan publik dan mengurangi dampak polusi udara.

II. METODE PENELITIAN

Pada bagian ini, akan dijelaskan mengenai tahapan pengerjaan mulai dari pengambilan data, pengolahan data, hingga hasil akhir berupa klasifikasi data gambar untuk menentukan kualitas udara di Jakarta.

II.1. Data

Penelitian ini menggunakan 300 data gambar langit yang diperoleh dari website pariwisata Beijing. Dari website tersebut, diambil gambar beserta atribut konsentrasi PM₁₀ sebagai dasar klasifikasi. Data diambil pada berbagai kondisi cuaca di lokasi dan waktu yang berbeda selama periode Februari 2022 sampai Mei 2024. Gambar yang diambil harus memuat setidaknya objek langit sebesar 50% dari luas gambar dengan catatan objek langit terdapat di bagian atas. Seluruh gambar yang digunakan memiliki resolusi lebih dari 500x500 piksel. Konsentrasi PM₁₀ berada pada *range* 20-226 $\mu\text{gram}/\text{m}^3$ yang diklasifikasikan ke dalam tiga kategori menurut BMKG yakni ‘Baik’, ‘Sedang’, dan ‘Tidak Sehat’. Pada penelitian ini, dilakukan penyesuaian kategori PM₁₀. BMKG mengklasifikasikan konsentrasi PM₁₀ ke dalam lima kategori sebagaimana tertera pada Tabel 1.

Tabel 1. Klasifikasi Konsentrasi PM₁₀

Kategori	Konsentrasi PM ₁₀ ($\mu\text{gram}/\text{m}^3$)
Baik	0-50
Sedang	51-150
Tidak Sehat	151-150
Sangat Tidak Sehat	351-420
Berbahaya	>420



Sumber: BMKG

Namun, dari total sampel yang diambil, tidak terdapat observasi yang memiliki konsentrasi PM_{10} dengan kategori Tidak Baik dan Sangat Tidak Baik. Berdasarkan 15 stasiun pengamatan PM_{10} BMKG, per April 2024, nilai PM_{10} di Indonesia tidak ada yang melebihi nilai baku mutu (230 mikron) atau termasuk kategori Tidak Baik [14]. Oleh karena itu, observasi dikategorikan ke dalam tiga kategori saja sebagaimana ditampilkan pada Gambar 1.



Gambar 1. Perbandingan Gambar dari Tiga Kategori

Dari Gambar 1, langit dengan kategori ‘Baik’ dicirikan oleh warna biru cerah, sedangkan kategori ‘Sedang’ dicirikan oleh warna biru dengan sedikit efek kabut. Sementara itu, kategori ‘Tidak Sehat’ dicirikan oleh warna langit keabu-abuan. Pengolahan data dalam penelitian ini menggunakan *library* keras dengan backend TensorFlow. Pengolahan dilakukan dengan menggunakan *Google Collab*.

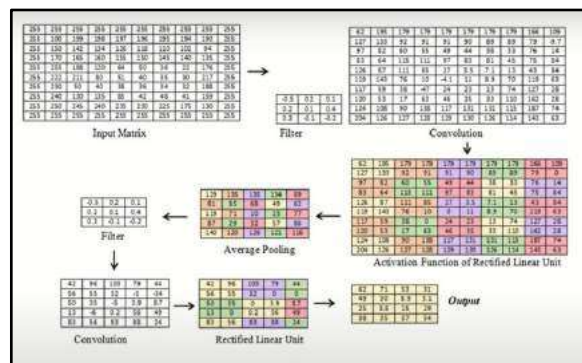
II.2. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan bagian dari *machine learning* yang sering digunakan dalam analisis gambar dan video. CNN tersusun atas beberapa *layer* yang secara otomatis melakukan pembelajaran dan ekstraksi fitur dari input sehingga memiliki akurasi yang lebih baik dibandingkan *traditional neural network* [15]. Secara umum, CNN terdiri atas tiga jenis *layer* yakni *convolutional layer*, *pooling layer*, dan *fully connected layer* [13]. Dalam *convolutional layer*, seluruh input yang masuk (angka atau gambar) akan dikonvolusi sesuai *filter/kernel*, *stride*, *padding*, dan fungsi aktivasi yang digunakan peneliti [13]. *Kernel/filter*, adalah matriks kecil yang digunakan untuk melakukan operasi konvolusi pada gambar input [16]. Kernel bergerak melintasi gambar input untuk mendeteksi fitur seperti tepi, tekstur, dan pola. *Stride*, adalah pergeseran kernel atau jumlah langkah yang diambil kernel saat bergerak melintasi gambar input. Stride satu berarti *kernel* bergerak satu piksel pada setiap langkah, baik secara horizontal maupun vertikal. *Padding*, adalah teknik untuk menambahkan piksel tambahan di sekitar tepi gambar input sebelum melakukan konvolusi sehingga ukuran *output* setelah dikonvolusi tidak berubah. Fungsi Aktivasi merupakan fungsi nonlinier yang bertujuan untuk memproses objek atau data dengan kompleksitas pola yang tinggi sehingga memungkinkan “jaringan saraf” untuk mempelajari pola tersebut [13]. Beberapa fungsi aktivasi nonlinier yang sering digunakan dibedakan menurut fungsinya. Misalnya untuk *hidden layer* meliputi *ReLU*, *Leaky ReLU*, atau *sigmoid* [13]. Untuk klasifikasi, digunakan fungsi aktivasi *softmax (multi-class classification)* atau *sigmoid (binary classification)*. Sementara untuk regresi, digunakan fungsi aktivasi *tanh* [13].

Dalam kasus inputan gambar, yang dikonvolusi adalah piksel-piksel dari gambar tersebut [16]. Piksel-piksel dari suatu gambar sebenarnya adalah sebuah matriks yang berisi nilai-nilai fitur/atribut yang melekat pada gambar tersebut [16]. Fitur-fitur yang melekat pada sebuah gambar contohnya

adalah warna (RGB atau grayscale), sehingga matriks dari gambar tersebut berisi nilai-nilai derajat RGB atau *grayscale* dari setiap warna pada piksel gambar tersebut [17]. Setelah input selesai dikonvolusi, input tersebut akan dimasukkan kedalam *pooling layer*.


Pada *pooling layer*, akan dilakukan *down sampling* pada matriks hasil konvolusi sehingga ukuran matriks akan tereduksi. Tujuannya untuk memperkecil ukuran spasial input sehingga dapat meningkatkan daya komputasi [13]. Nilai-nilai yang diperoleh dari *down sampling* matriks konvolusi kemudian disusun kembali (*pooling*) kedalam sebuah matriks yang ukurannya lebih kecil dibanding matriks konvolusi [17]. Prinsip kerjanya mirip dengan *convolutional layer*, bedanya *pooling layer* memproses setiap *channel* (misalnya RGB) secara terpisah. Proses *pooling* dapat dilakukan berulang kali, tergantung pada seberapa banyak *pooling layer* yang dibentuk. Terdapat banyak jenis *pooling*, namun yang paling umum digunakan adalah *max pooling* dan *average pooling* [13]. Sesuai namanya, *max pooling* akan mencari nilai terbesar dari setiap matriks, sedangkan *average pooling* akan menghitung nilai rata-rata dari setiap matriks. Proses konvolusi dan *pooling* yang dilakukan pada *convolutional layer* dan *pooling layer* secara ringkas dapat dilihat pada Gambar 2.



Gambar 2. Proses Konvolusi dan Pooling

Setelah proses *pooling* selesai dilakukan, akan terbentuk *output* yang berupa matriks berukuran $n \times n$ yang berisi nilai-nilai hasil *pooling* dari matriks konvolusi [17]. Matriks-matriks tersebut kemudian akan di-*flatten* menjadi satu dimensi, kemudian hasil *flatten* ini akan dimasukkan kedalam *fully connected layer* sebagai input [16]. Nilai hasil *flatten* akan menjadi data *training* untuk melatih model CNN.

Fully connected layer bekerja dengan menghubungkan setiap piksel input dengan output. Pada *fully connected layer*, setiap layer akan saling terhubung menjadi satu membentuk sebuah “jaringan saraf” (neuron) [17]. Di dalam neuron, setiap hasil *flatten* akan masuk dalam operasi matematika yang kompleks untuk menghasilkan *output* berupa klasifikasi atau estimasi model regresi [17]. Operasi matematis yang dilakukan dalam neuron secara sederhana dapat kita lihat pada gambar 3.



Gambar 3. Operasi Matematika Dalam Neuron

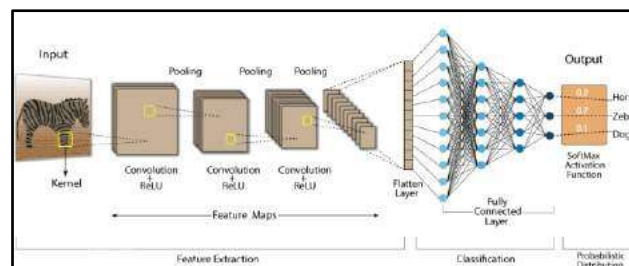
Input pada ilustrasi di gambar 3 merupakan hasil *flatten* pada pooling layer. Setiap nilai kemudian diberi penimbang dan dijumlahkan [16]. Hasil penjumlahan ini akan digunakan untuk mengestimasi nilai output \hat{y} . Estimasi nilai output dilakukan dengan formula seperti pada gambar 4.

$$\hat{y} = g \left(w_0 + \sum_{i=1}^m x_i w_i \right)$$

Gambar 4. Formula Matematis untuk Estimasi Output

Setelah proses estimasi, maka akan dihasilkan *output* berupa estimasi kategori untuk klasifikasi atau estimasi model untuk regresi. Namun, tidak semua parameter akan diestimasi. Dalam *fully connected layer* yaitu pada bagian *dense*, akan dilakukan *dropout* pada beberapa parameter yang tidak perlu diestimasi [16] sehingga tidak terjadi *overfitting* [13].

Pada dasarnya, CNN terdiri dari dua tahapan utama, yaitu *Feature Extraction* dan *Classification* atau *Modelling* [16]. *Feature extraction* bertujuan menangkap pola pada gambar atau data sebagai dasar klasifikasi atau estimasi model pada tahap *classification/modelling*. Urutan *layer* dalam masing-masing tahapan dapat bervariasi. Namun biasanya, *feature extraction* terdiri atas *convolutional layer* dan *pooling layer*. Sedangkan *classification/modelling* merupakan kombinasi dari *fully connected layer*. Selain itu, pada setiap tahapan juga dapat berisi kombinasi dari berbagai fungsi aktivasi non linier [16]. Arsitektur CNN secara umum dapat dilihat pada gambar 5.



Gambar 5. Grafik Arsitektur CNN

Dalam perkembangannya, CNN memiliki banyak variasi arsitektur jika dibandingkan dengan *Basic CNN* [13]. Beberapa variasi arsitektur CNN saat ini antara lain AlexNet, VGGNet, ResNet, DenseNet, Inception, dan lain sebagainya [13]. Secara umum, perbedaan antara *Basic CNN* dengan variasi CNN lainnya terletak pada ada tidaknya *base model* [13]. *Basic CNN* tidak menggunakan *base model* dalam arsitekturnya, sehingga arsitektur *Basic CNN* hanya terdiri dari tiga layer utama.

II.3. Langkah-Langkah Penelitian

Penelitian ini menggunakan metode *Basic Convolutional Neural Network (Basic CNN)* untuk mengklasifikasikan kualitas udara di Beijing dengan data citra. Secara umum terdapat empat langkah-langkah penerapan CNN ini adalah sebagai berikut [18]:

1. Data collection

Pada tahap ini, dilakukan pengambilan data gambar beserta atribut konsentrasi PM_{10} dari



website pariwisata Beijing sebanyak 300.

2. *Pre-processing*

Pada tahap ini, dilakukan pelabelan data gambar ke dalam tiga kategori konsentrasi PM₁₀. Dari 300 data yang digunakan, selanjutnya dilakukan pemilihan secara acak dari setiap kategori untuk menyusun data training dan data testing dengan rasio 80% dan 20%.

3. *Model training*

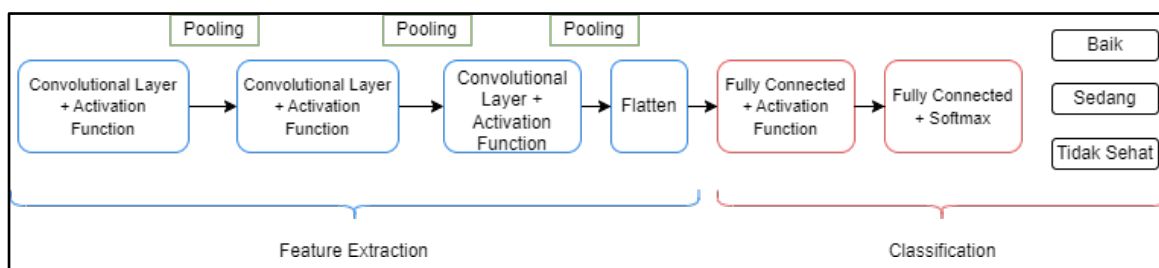
Pada tahap ini, data train digunakan untuk melatih model CNN yang dibangun. Dalam penelitian, digunakan model CNN dasar dengan variasi pada fungsi aktivasi dan pooling. Terdapat tiga fungsi aktivasi yang digunakan yakni *Rectified Linear Unit (ReLU)*, *Leaky ReLU*, dan *hyperbolic tangent (tanh)*, sedangkan pooling yang digunakan ada dua yakni max pooling dan average pooling. Dengan demikian, terdapat enam kombinasi arsitektur CNN yang digunakan dalam penelitian ini. Penjelasan arsitektur CNN terdapat pada bagian selanjutnya.

4. *Model evaluation*

Pada tahap ini, dilakukan evaluasi dengan *confusion matrix* untuk mengetahui akurasi model dalam mengklasifikasikan gambar. Setelah itu, dilakukan perbandingan pada keenam model agar diperoleh model dengan akurasi terbaik.

Arsitektur CNN yang dibangun dalam penelitian ini menggunakan tiga *convolutional layer* dan tiga *pooling layer*, sehingga akan dilakukan tiga kali konvolusi dan tiga kali *pooling*. Ukuran kernel pada konvolusi pertama sebesar 32x32 piksel, kemudian pada konvolusi kedua ukuran kernel ditingkatkan menjadi 64, lalu ditambah lagi menjadi 128 pada konvolusi ketiga. *Stride* yang digunakan sebesar satu dan sama untuk setiap konvolusi. Semua konvolusi dalam arsitektur ini tidak menggunakan *padding*. Dimensi input yang dimasukkan ke dalam arsitektur ini sebesar 150x150 piksel dengan menggunakan *channel* RGB berukuran tiga (*red, green, blue*).

Setelah proses konvolusi dan *pooling* selesai, data akan di-*flatten* dan masuk dalam tahap *classification*. Dalam tahap ini, dibentuk dua buah *hidden layer* pada *fully connected layer*-nya dengan jumlah neuron *hidden layer* pertama dan kedua sebanyak 200 dan 500 neuron. Fungsi aktivasi yang digunakan pada setiap *hidden layer* sama dengan fungsi aktivasi yang digunakan pada proses konvolusi. Pada *dense* di dalam *fully connected layer*, dilakukan *dropout* pada kedua *hidden layer*. Pada *hidden layer* pertama, dropout yang dilakukan sebanyak 0,3, sedangkan pada *hidden layer* kedua dilakukan sebanyak 0,5. Pada tahap terakhir pembuatan klasifikasi, digunakan fungsi aktivasi *softmax* yang dapat mengakomodasi *multi-class classification* dengan jumlah kategori sebanyak 3 (tiga). Arsitektur CNN dalam penelitian ini dirangkum dalam diagram alur pada gambar 6.



Gambar 6. Diagram Alur Arsitektur CNN

Dalam *training* model, dilakukan *tuning* parameter untuk menghasilkan model terbaik dengan



tingkat akurasi yang tinggi. *Tuning* parameter dilakukan dengan memodifikasi *learning rate* pada *optimizer* menjadi 0,00001. *Optimizer* yang digunakan dalam penelitian ini adalah *Adaptive Moment Estimation* (Adam). *Loss* yang digunakan dalam *training* model adalah *categorical cross entropy*. Dalam *training* model dilakukan *epoch* sebanyak 100 kali dengan *steps per epoch* sebanyak 20 kali. Pengukuran kebaikan model untuk melihat model terbaik di antara keenam model yang sudah dibentuk dilakukan dengan membandingkan tingkat akurasi.

III. HASIL DAN PEMBAHASAN

III.1. Penentuan Model CNN Terbaik

Arsitektur CNN yang digunakan dalam penelitian ini terdiri atas tiga fungsi aktivasi, yaitu ReLU, *Leaky ReLU*, dan tanh serta dua metode *pooling* yaitu *Max Pooling* dan *Average Pooling*. Sehingga akan terbentuk enam model yang akan dibandingkan tingkat akurasinya. Nilai akurasi dari setiap model dapat dilihat pada tabel di bawah.

Tabel 2. Perbandingan Akurasi Model

Model	Fungsi Aktivasi	Pooling	Akurasi (%)
Model 1	ReLU	<i>Max Pooling</i>	55
Model 2	ReLU	<i>Average Pooling</i>	62
Model 3	<i>Leaky ReLU</i>	<i>Max Pooling</i>	54
Model 4	<i>Leaky ReLU</i>	<i>Average Pooling</i>	63
Model 5	Tanh	<i>Max Pooling</i>	33
Model 6	Tanh	<i>Average Pooling</i>	33

Sumber: Hasil Olahan

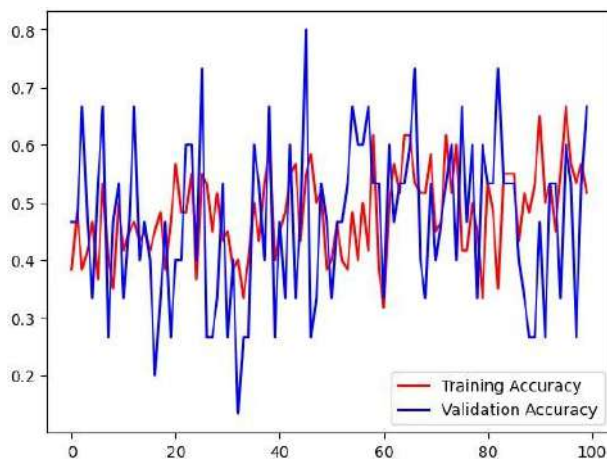
Berdasarkan tabel 2, model terbaik yang diperoleh adalah model 4 karena memiliki nilai akurasi terbesar dibandingkan model lainnya, yaitu sebesar 63 persen. Model 5 dan model 6 memiliki tingkat akurasi yang paling kecil yaitu sebesar 33 persen, terpaut cukup jauh jika dibandingkan dengan tingkat akurasi keempat model lainnya yang mencapai angka di atas 50 persen. Hal ini disebabkan oleh fungsi aktivasi yang digunakan pada kedua model ini, yaitu fungsi aktivasi Tanh. Fungsi aktivasi Tanh adalah fungsi aktivasi yang digunakan dalam pemodelan regresi. Sehingga, apabila dilakukan untuk estimasi model selain regresi (dalam kasus ini, untuk klasifikasi) maka akurasinya akan menjadi sangat kecil. Oleh karena itu, fungsi aktivasi ini kurang tepat apabila digunakan untuk klasifikasi dan hal ini terbukti dalam penelitian ini.

Berdasarkan tabel 2, metode *pooling* yang paling baik dalam kasus ini adalah *average pooling*. Hal ini dapat kita lihat dari perbandingan tingkat akurasi antara fungsi aktivasi yang menggunakan *max pooling* dan *average pooling*. Pada fungsi aktivasi ReLU, tingkat akurasi model yang menggunakan *average pooling* sebesar 62 persen, jauh lebih tinggi daripada fungsi aktivasi ReLU yang menggunakan *max pooling* dimana akurasinya hanya sebesar 54 persen. Hal yang sama juga terjadi pada fungsi aktivasi *Leaky ReLU*. Akurasi model yang menggunakan *average pooling* sebesar 63 persen sedangkan model yang menggunakan *max pooling* akurasinya hanya sebesar 55 persen.

Sebaliknya, tidak ada perbedaan yang signifikan antara model yang menggunakan *pooling* yang sama namun menggunakan fungsi aktivasi yang berbeda. Dari tabel 2, model 2 dan model 4 sama-sama menggunakan *average pooling* namun menggunakan fungsi aktivasi yang berbeda, dimana model 2 menggunakan fungsi aktivasi ReLU dan model 4 menggunakan fungsi aktivasi *Leaky ReLU*. Model 2 memiliki akurasi sebesar 62 persen, sedangkan model 4 memiliki akurasi sebesar 63 persen. Perbedaan tingkat akurasi kedua model ini hanya terpaut satu persen saja. Artinya, pemodelan dengan

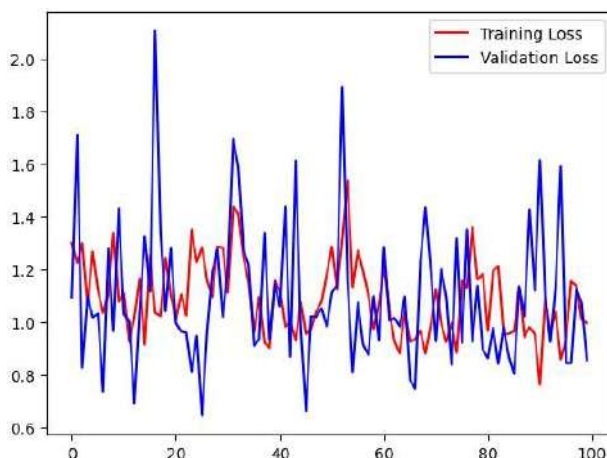


menggunakan fungsi aktivasi ReLU juga memberikan hasil yang baik dalam melakukan pengklasifikasian, namun dengan catatan *pooling* yang digunakan adalah *average pooling*. Dengan demikian, model 4 terpilih sebagai model terbaik karena memiliki tingkat akurasi yang paling tinggi. Grafik akurasi untuk model 4 dapat dilihat pada gambar 7. bawah ini.



Gambar 7. Grafik Akurasi Model 4

Berdasarkan Gambar 7, terlihat bahwa pola data *testing/validation* (garis warna biru) sebagian besar sudah mengikuti pola data training (garis warna merah). selain itu, terlihat bahwa semakin banyak iterasinya (sumbu-X) maka nilai akurasinya (sumbu-Y) juga semakin tinggi, meskipun masih cenderung fluktuatif. Hal ini membuktikan bahwa model 4 sudah mampu mengklasifikasikan sebagian besar gambar dengan tepat sesuai kategori aslinya. Hal yang sama juga dapat dilihat pada grafik *validation loss* pada gambar 8.



Gambar 8. Grafik *Validation Loss* Model 4

Gambar 8 menunjukkan seberapa banyak kesalahan prediksi (*loss*) yang dilakukan oleh model. Berdasarkan Gambar 8, terlihat bahwa semakin banyak iterasinya (sumbu-X) maka jumlah *validation loss*-nya (sumbu-Y) juga semakin kecil meskipun masih cenderung fluktuatif. Hal ini mendukung penjelasan sebelumnya yang menyatakan bahwa model 4 sudah mampu mengklasifikasikan sebagian besar gambar dengan tepat sesuai kategori aslinya.

Berdasarkan hasil analisis di atas, baik menggunakan nilai numerik (tingkat akurasi) maupun



menggunakan visualisasi (grafik akurasi dan grafik *validation loss*), diketahui bahwa model terbaik yang diperoleh adalah model 4. Model 4 menggunakan arsitektur CNN berupa fungsi aktivasi *Leaky ReLU* dan *average pooling* dalam melakukan klasifikasi kualitas udara di Beijing menggunakan data gambar. Tingkat akurasi yang diperoleh sebesar 63 persen menunjukkan bahwa model sudah mampu mengklasifikasikan sebagian besar gambar dengan tepat sesuai kategori aslinya.

Keunggulan *Leaky ReLU* dibandingkan fungsi *ReLU* standar yakni dapat membantu meningkatkan kinerja jaringan saraf dalam dengan mengatasi masalah *dying ReLU*. Dengan memperkenalkan kemiringan kecil untuk nilai x negatif, sehingga semua neuron di jaringan dapat berkontribusi pada keluaran, sekalipun memiliki input negatif. Hal ini sejalan dengan penelitian [19] yang membandingkan beberapa arsitektur CNN untuk klasifikasi dataset CIFAR-10. Hasilnya, *Leaky ReLU* memberikan rata-rata error terkecil dibandingkan fungsi aktivasi lainnya.

III.2. Klasifikasi PM_{10} Pada Area Lokal

Model terbaik yang diperoleh pada bagian sebelumnya kemudian diujicobakan untuk mengklasifikasikan konsentrasi PM_{10} pada lingkungan sekitar. Sebanyak dua belas sampel gambar diambil selama periode tujuh hari sekitar pukul 10.00-16.00 WIB (tidak sekuensial) pada kondisi cuaca cerah. Gambar 9 menunjukkan hasil perbandingan klasifikasi gambar yang diambil pada area lokal dengan data *train*.



Gambar 9. Perbandingan Hasil Klasifikasi di Tempat Lokal dan Data Asli

Hasil klasifikasi menunjukkan bahwa ketujuh gambar diklasifikasikan dalam kategori ‘Sedang’ yakni konsentrasi PM_{10} pada rentang $51-150 \mu\text{gram}/\text{m}^3$. Hasil tersebut diperjelas dengan Gambar 10 yang menunjukkan perbandingan hasil klasifikasi gambar yang diambil pada area pengamatan dengan gambar klasifikasi gambar asli yang pada website pariwisata Beijing. Dari gambar tersebut, terlihat bahwa terdapat kemiripan warna di antara keduanya.

Validasi hasil tersebut diperkuat dengan waktu pengambilan gambar. Pada waktu tersebut, mobilitas kendaraan di jalanan sekitar Politeknik Statistika STIS sedang tinggi. Tingginya arus kendaraan meningkatkan emisi serta debu dan aerosol di udara. Hasil ini juga dijelaskan pada penelitian [20] yang menyebutkan bahwa kualitas udara di DKI Jakarta didominasi oleh kategori sedang. Dengan demikian, hasil penelitian ini menunjukkan bahwa metode yang digunakan valid untuk mengklasifikasikan konsentrasi PM_{10} . Sejalan dengan penelitian yang dilakukan oleh [21] yang



menyebutkan bahwa klasifikasi kualitas udara dengan metode *deep learning* menggunakan gambar lebih akurat jika dibandingkan dengan metode analisis konvensional yang menggunakan angka numerik (misalnya, *random forest*, *support vector regression*, dan lainnya). Hasil penelitian ini sangat penting bagi upaya pembangunan lingkungan hidup yang lebih *advance* sehingga dapat meningkatkan kualitas kesehatan publik dan meminimalisir dampak polusi udara.

IV. KESIMPULAN

Hasil penelitian menunjukkan bahwa arsitektur CNN terbaik dalam mengklasifikasikan kualitas udara berdasarkan konsentrasi PM₁₀ adalah arsitektur dengan fungsi aktivasi *Leaky ReLU* dan *Average Pooling*. Model ini mampu mengklasifikasikan kualitas udara di Beijing dengan hanya menggunakan gambar/citra kedalam tiga kategori, yaitu Sehat, Sedang, dan Tidak Sehat dengan akurasi yang cukup baik. Dengan demikian, model ini mampu untuk mengklasifikasikan kualitas udara di daerah lain (terutama di Indonesia) hanya menggunakan gambar atau foto langit dengan tingkat akurasi yang cukup baik.

Penelitian ini masih terbatas pada klasifikasi gambar menggunakan fitur warna. Oleh karena itu, penelitian selanjutnya dapat mengembangkan klasifikasi yang tidak hanya berbasis pada warna saja, tetapi juga menggunakan fitur-fitur lain yang terdapat dalam gambar. Penggunaan variasi arsitektur CNN lain seperti AlexNet, VGGNet, ResNet, DenseNet, Inception, atau variasi lainnya juga dianjurkan untuk meningkatkan akurasi.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada semua pihak yang telah membantu dalam penyusunan tulisan ini.

REFERENSI

1. Chakma, A., Vizena, B., Cao, T., Lin, J., & Zhang, J. (2017). Image-Based Air Quality Analysis Using deep Convolutional Neural Network. IEEE.
2. Aghorru, R., & Koprari, M. (2023). RANCANG BANGUN SISTEM PEMANTAU KUALITAS DAN POLUSI UDARA PM2.5 YANG TERINTEGRASI DENGAN PLATFORM IOT. *Technologia : Jurnal Ilmiah*.
3. A'yun, Indanazulfa Qurrota and Umaroh, Rodhiah (2022) "Polusi Udara dalam Ruang dan Kondisi Kesehatan: Analisis Rumah Tangga Indonesia," *Jurnal Ekonomi dan Pembangunan Indonesia*: Vol. 22: No. 1, Article 2. DOI: 10.21002/jepi.2022.02
4. Abbafati, C., Abbas, K. M., Kangevari, M. A., Abdullah, F., Abdelalim, A., Abdollahi, M., Abdollahpour, I., Abegaz, K. H., Abolhassani, H., & Aboyans, V. (2020). Global burden of 87 risk factors in 204 countries and territories, 1990–2019: a systematic analysis for the Global Burden of Disease Study 2019. *The Lancet*, 396, 1223-1249. [https://doi.org/10.1016/S0140-6736\(20\)30752-2](https://doi.org/10.1016/S0140-6736(20)30752-2)
5. Qian, N., Yu, H., Cai, R., Ming, H., Qian, Y., & Wang, C. (2016). Association Between Maternal Air Pollution Exposure During First Trimester and Birth Weight in Shanghai. *Journal of Environmental and Occupational Medicine*, 827-832. <http://dx.doi.org/10.13213/j.cnki.jeom.2015.16123>
6. Sram, R. J., Binkova, B., Dostal, M., Dostalova, M. M., Libalova, H., Micova, A., Jr., P. R., Rossnerova, A., Schmuczerova, J., Svecova, V., Tapinka, J., & Votavova, H. (n.d.). Health impact of air pollution to children. *Elsevier*, 216, 533-540. <https://doi.org/10.1016/j.ijheh.2012.12.001>
7. Lanzi, E., Dellink, R., & Chateau, J. (2018). The sectoral and regional economic consequences of outdoor air pollution to 2060. *Energy Economics*, 71, 89–113. doi:10.1016/j.eneco.2018.01.014
8. Syuhada, G., Akbar, A., Hardiawan, D., Pun, V., Darmawan, A., Heryati, S. H. A., Siregar, A. Y. M., Kusuma, R. R., Driejana, R., Ingole, V., Kass, D., & Mehta, S. (2023). Impacts of Air Pollution on Health and Cost of Illness in Jakarta, Indonesia. MDPI. <https://doi.org/10.3390/ijerph20042916>



9. Singh, N., Singh, S., & Mall, R. K. (2020). Urban ecology and human health: implications of urban heat island, air pollution and climate change nexus. Elsevier, 317-334. <https://doi.org/10.1016/B978-0-12-820730-7.00017-3>
10. Khaniabadi, Y. O., Goudarzi, G., Daryanoosh, S. M., Borgini, A., Tittarelli, A., & De Marco, A. (2017). Exposure to PM 10, NO 2, and O 3 and impacts on human health. Environmental science and pollution research, 24, 2781-2789.
11. Arregocés, H. A., Bonivento, G. J., Ladino, L. A., Beristain-Montiel, E., Restrepo, G., Miranda, J., ... & Rojano, R. (2023). Human health risk assessment of PM10-bound heavy metals and PAHs around the Latin America's Largest opencast coal mine. Environmental Science and Pollution Research, 30(60), 125915-125930.
12. Leão, M. L. P., Zhang, L., & da Silva Júnior, F. M. R. (2023). Effect of particulate matter (PM2. 5 and PM10) on health indicators: climate change scenarios in a Brazilian metropolis. Environmental Geochemistry and Health, 45(5), 2229-2240.
13. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2018). Recent Advances In Convolutional Neural Networks. Pattern Recognition, 77, 354-377.
14. BMKG. (2024, June). Monitoring Suspended Particulated Matter (SPM) (April 2024). <https://www.bmkg.go.id/kualitas-udara/informasi-spm.bmkg>
15. Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. IEEE transactions on neural networks and learning systems, 33(12), 6999-7019.
16. Zhang, X., Zhang, X., & Wang, W. (2023). Convolutional Neural Network. In Intelligent Information Processing with Matlab (pp. 39-71). Singapore: Springer Nature Singapore.
17. Taye, M. M. (2023). Theoretical understanding of convolutional neural network: Concepts, architectures, applications, future directions. Computation, 11(3), 52 <https://doi.org/10.3390/computation11030052>
18. Hardini, M., Riza Chakim, M. H. ., Magdalena, L. ., Kenta, H. ., Rafika, A. S. ., & Julianingsih, D. (2023). Image-based Air Quality Prediction using Convolutional Neural Networks and Machine Learning. Aptisi Transactions on Technopreneurship (ATT), 5(1Sp), 109–123. <https://doi.org/10.34306/att.v5i1Sp.337>
19. Putra, S. R. (2015). IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORK FOR THE CLASSIFICATION OF OBJECT IN IMAGES. ITS.
20. Wahyudianta, S. A., & Supriyati. (2024). Analisis Kualitas Udara Jakarta dan Prediksi Tingkat Polusi dengan Metode Mesin Pembelajaran SVM. 3.
21. Wang, J., Li, X., Jin, L., Li, J., Sun, Q., & Wang, H. (2022). An air quality index prediction model based on CNN-ILSTM. *Scientific Reports*, 12(1), 8373.