

Penerapan Deep Learning Menggunakan Metode Convolutional Neural Network dan K-Means dalam Klasterisasi Citra Butiran Pasir

Ladyka Febby Olivia[✉], Yuhandri, Syafri Arlis

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK, Padang, 25221, Indonesia

ladyka.febby@gmail.com

Abstract

Fine aggregate (sand) is the most widely used building material in the construction industry, making the daily demand for sand continue to increase. Sand in granular form has different textures for each type. The characteristics of good sand can be determined through several parameters, such as the mud content of the sand, actual water content and SSD inspection, gradation examination, water content, organic substances, bulk/dense unit weight, absorption capacity, and fineness modulus. One of the common problems in the construction field is floor and wall damage, which can be caused by the improper selection of sand. This study aims to classify sand grain images. The method used in this study is Convolutional Neural Network (CNN) with the ResNet50 architecture as feature extraction. The K-Means Clustering method is applied to group sand grain images. The dataset processed in this study was sourced from CV. Sumber Rezeki and consists of 74 sand grain images. The CNN method involves resizing, normalization, and converting images into arrays. Furthermore, the K-Means method is used to cluster the data into certain groups based on feature similarities. The results of the study show that among the input images, there are 14 sub-angular grains, 20 irregular grains, 10 rounded grains, and 15 sharp grains. The benefit of this study is to help identify the type of sand grain suitable for wall and floor plastering.

Keywords: Sand, Convolutional neural network, Arsitektur Resnet-50, Clustering, K-Means.

Abstrak

Agregat halus (pasir) merupakan bahan bangunan yang paling banyak digunakan dalam dunia konstruksi, sehingga kebutuhan pasir setiap harinya semakin meningkat. Pasir berbentuk butiran-butiran memiliki tekstur berbeda untuk setiap jenisnya. Karakteristik pasir yang baik dapat ditentukan melalui beberapa parameter, seperti segi kadar lumpur pasir, pemeriksaan kadar air nyata dan SSD, pemeriksaan gradasi, kadar air, zat organik, berat isi kondisi padat/gembur, daya serap, modulus kehalusan. Masalah yang terjadi dibidang konstruksi salah satunya kerusakan lantai dan dinding, salah satu faktornya tidak sesuai pasir yang digunakan. Penelitian ini bertujuan untuk mengelompokkan citra butiran pasir. Metode yang digunakan pada penelitian ini *Convolutional Neural Network* (CNN) dengan arsitektur ResNet50 digunakan sebagai ekstraksi fitur. Metode K-Means Clustering bekerja untuk melakukan pengelompokan citra butiran pasir dengan mengacu pada kemiripan fitur yang dihasilkan. Dataset yang diolah dalam penelitian ini bersumber di CV. Sumber Rezeki. Dataset terdiri 74 citra butiran pasir. Metode CNN yang digunakan adalah Resizing, Normalisasi dan mengubah gambar menjadi array. Selanjutnya metode K-Means digunakan untuk klasterisasi data kedalam kelompok tertentu berdasarkan kemiripan fitur. Hasil penelitian berdasarkan citra yang telah dipinpoint terdapat dikelompokkan butiran sub angular terdapat 14 citra, butiran tidak beraturan terdapat 20 citra, butiran tumpul 10 citra dan butiran tajam 15 citra. Manfaat dari penelitian ini dapat digunakan untuk mengetahui jenis butiran pasir yang cocok digunakan untuk plasteran dinding dan lantai.

Kata kunci: Pasir, *Convolutional neural network*, *Arsitektur Resnet-50*, klasterisasi, *K-Means*.

KomtekInfo is licensed under a Creative Commons Attribution-Share Alike 4.0 International License.



1. Pendahuluan

Perkembangan zaman yang begitu pesat selalu beriringan dengan perkembangan dan kemajuan teknologi. Khususnya kemajuan teknologi dibidang industri yang begitu cepat hingga sudah sampai pada titik revolusi industri 4.0 [1]. Menghadapi era globalisasi dunia, Indonesia yang diketahui sebagai salah satu Negara Berkembang dituntut untuk lebih kreatif serta memiliki keterampilan dalam bidang konstruksi [2]. dimana dunia telah mengalami perkembangan teknologi yang sangat cepat dan berada pada era digital, banyak teknologi yang berkembang disemua bidang kehidupan untuk membantu mempermudah pekerjaan manusia. Salah satu teknologi yang berkembang adalah pengolahan citra digital.

Pengolahan citra digital merupakan bidang ilmu salah satu cabang informatika yang berkuat pada usaha untuk melakukan transformasi citra menjadi citra lain [3].

Pembangunan diindonesia berubah menjadi pesat dengan perkembangan usaha yang berkaitan dengan konstruksi berkembang sebagai industri komersial [4]. Kebutuhan akan bahan bangunan seperti pasir, koral, batu dan lain-lain sangat meningkat. Menurut badan pusat statistik 2019 terjadi peningkatan Jumlah volume produksi pertambangan bahan galian seperti pasir, batu, kerikil dan tanah meningkat setiap tahunnya.

Agregat halus (pasir) merupakan bahan bangunan yang paling banyak digunakan dalam dunia konstruksi,

sehingga kebutuhan pasir setiap harinya sangat banyak terutama di daerah perkotaan yang pembangunannya sangat pesat [5]. Agregat halus sendiri merupakan butiran-butiran Agregat yang lolos saringan no.4 atau ukuran 4,75 mm [6]. Agregat yang baik untuk campuran beton memiliki ciri-ciri kuat, keras, bersudut, bergradasi, tidak mengandung zat organik, dan tidak mengandung lumpur. Berdasarkan kenyataannya Agregat yang sering dijumpai banyak mengandung pasir dan lumpur [7]. Agregat halus Pasir yang biasanya diambil dari galian kemungkinan pasir besar pasir itu sangat kotor, misalkan bercampur dengan lumpur maupun zat organik lainnya [8].

Deep Learning adalah merupakan cabang ilmu machine learning yang berbasis jaringan syaraf tiruan [JST] atau tidak dikatakan sebagai sebagai perkembangan dari JST[9]. dalam penelitian ini penulis menggunakan konsep Deep Learning dengan metode Convolutional Neural Network (CNN) dan K-Means Clustering. metode Convolutional Neural Network (CNN) adalah salah satu metode yang umum digunakan dalam bidang Deep Learning untuk mendeteksi dan mengenali objek dalam citra digital [10]. dalam pengenalan gambar dan klasifikasi gambar jika dibandingkan dengan metode deep learning lainnya [11]. CNN adalah salah satu jenis model deep learning yang mampu memproses data dalam bentuk pola grid. Arsitektur CNN terdiri dari tiga jenis lapisan utama, yaitu lapisan konvolusi (convolutional layer), lapisan pengelompokan (pooling layer), dan lapisan terhubung penuh (Fully Connected Layer). Setiap layer memiliki peran yang berbeda, di mana convolutional layer dan pooling layer bertugas untuk mengekstraksi fitur dari data, sementara Fully Connected Layer berfungsi untuk memetakan fitur hasil ekstraksi ke output klasifikasi [12].

Metode Convolutional Neural Network (CNN) dengan menerapkan arsitektur ResNet- 50 dalam menentukan Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit mengklasifikasi dengan cukup baik dengan tingkat akurasi 0,95% [13]. Penelitian sebelumnya menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet50 dalam klasifikasi jenis mangga berdasarkan bentuk dan tekstur daun mendapatkan hasil akurasi 0,491 dan terus meningkat pada tes ke-24, dan ketepatan nilai rata-rata 0,533 [14]. Penelitian sebelumnya Klasifikasi jamur berdasarkan Genus yang dilakukan menggunakan Metode Convolutional Neural Network jumlah data gambar jamur dengan jumlah 1200. Ada tiga Genus yang digunakan pada penelitian ini yang kemudian dibagi menjadi enam kelas yaitu *Boletus* (konsumsi), *Boletus* (beracun), *Ganoderma* (konsumsi), *Ganoderma* (beracun), *Russula* (konsumsi) dan *Russula* (beracun). Pada tahap pengujian model ini mendapatkan akurasi sebesar 76% [15]. Sistem klasifikasi jenis ikan cupang ini menggunakan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan gambar jenis ikan cupang dengan tingkat akurasi yang sangat tinggi. Hasil pengujian menunjukkan bahwa ikan cupang jenis

big ear memiliki akurasi tertinggi dengan 94,35% secara keseluruhan, ikan cupang Nemo memiliki akurasi 86,24%, ikan cupang Serit memiliki akurasi 84,56 % dan 78,85 %, masing-masing; dan ikan cupang Bluerim memiliki akurasi terkecil dengan 74,44 % [16].

Kinerja Deep Learning dalam beberapa permasalahan dapat dilihat dari performa proses Clustering. Konsep dasar Clustering merupakan proses membagi-bagi obyek dari suatu set data menjadi beberapa klaster yang homogen. Tujuan utama dari metode klaster adalah pengelompokkan sejumlah data/obyek kedalam klaster (grup) sehingga dalam setiap klaster akan berisi data yang semirip mungkin. Clustering berusaha untuk menempatkan obyek yang mirip atau yang jaraknya berdekatan dalam satu klaster dan membuat jarak antar klaster sejauh mungkin. Ini berarti obyek dalam satu klaster sangat mirip satu sama lain dan berbeda dengan obyek dalam klaster-klaster yang lain [17]. K-Means merupakan sebuah algoritma clustering pada data mining untuk dapat menghasilkan kelompok dari data yang jumlahnya banyak dengan metode partisi yang berbasis titik dengan waktu komputasi yang cepat dan efisien.[18].

Berdasarkan penelitian sebelumnya penggunaan K-Means Clustering dan Gray-Level Co-Occurrence Matrix (GLCM) mampu melakukan identifikasi varietas paprika melalui proses segmentasi. Segmentasi objek dilakukan menggunakan algoritma K-Means Clustering untuk membedakan objek dari latar belakangnya. Selanjutnya, proses ekstraksi tekstur dan bentuk dilakukan menggunakan Matriks Co-Occurrence Level Gray (GLCM) untuk membedakan jenis varietas paprika. Hasil penelitian tentang klasterisasi varietas paprika juga menunjukkan bahwa proses itu berhasil. Penggunaan algoritma clustering K-means dan Matriks Co-Occurrence Level Gray (GLCM) menunjukkan hasil yang sangat baik ini membuktikan efektivitasnya dalam melakukan klasterisasi pada varietas paprika [19]. Penggunaan metode K-means dalam klasterisasi pixel citra koleksi foto museum monpera dengan menggunakan aplikasi augmented reality yang menghasilkan Hasil pengujian citra menggunakan metode K-Means menunjukkan data evaluasi yang melibatkan Silhouette Score, Calinski-Harabasz, dan Dunn Index. Hasil pengujian ini menunjukkan bahwa metode K-Means belum mampu meningkatkan kualitas citra hasil klasterisasi pixel, seperti yang ditunjukkan pada hasil pengujian Silhouette Score didapatkan hasil -0.428484, Calinski-Harabasz didapatkan hasil 10143.0, dan Dunn Index didapatkan hasil 0.758773 [20].

Pendekatan K-means clustering untuk segmentasi buah apel menggunakan 20 data gambar. Hasil dari metode k-means secara akurat mampu melakukan identifikasi antara apel fuji dan apel hijau. Penelitian sebelumnya citra clustering dengan data daun tomato leaf panthogen sebanyak 900 citra yang terdiri dari 3

cluster yaitu Bacterial Spot, Yellow Leaf Curl Virus dan Healthy. P [21].

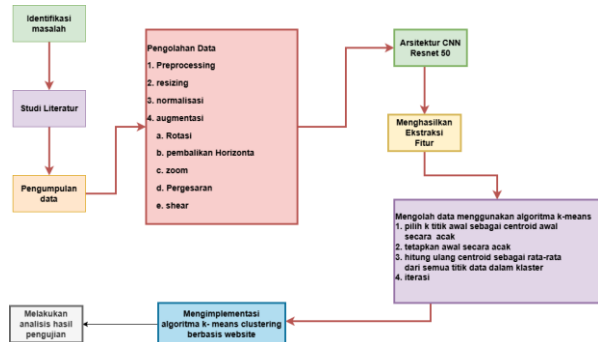
Penelitian sejalan yang dilakukan dengan penggunaan DARKNER19 dan K-Means dalam klasterisasi tomat. Hasil klastering yang terbaik menggunakan K-Means Clustering dengan PCA 20 yang menghasilkan accuracy 97.7%, precision 97.73%, dan recall 97.67% dengan waktu komputasi 1 menit 16 detik. Berdasarkan hasil penelitian dari dengan menggunakan metode K-Means Clustering untuk mendeteksi penyakit jagung dengan menggunakan data latih sebanyak 50 citra, hasil dari clustering mencapai tingkat akurasi 85% [22].

Masalah terjadi pada bidang konstruksi saat ini banyak kerusakan seperti lantai dan plesteran dinding yang disebabkan dari bahan material pasir yang tidak standar. Pasir yang buruk akan membuat lantai dan plesteran dinding menjadi cepat retak, maka dari itu kualitas pasir sangat berpengaruh terhadap ketahanan lantai dan plesteran dinding. Salah satu cara untuk mengatasi masalah tersebut adalah. Penggunaan metode *Convolutional Neural Network* (CNN) dalam ekstraksi fitur, lalu mengidentifikasi butiran pasir dengan melakukan klasterisasi atau pengelompokan menggunakan K-Means. Penggunaan metode *Convolutional Neural Network* (CNN) dan K-Means dalam mengelompokkan kualitas jenis pasir menjadi solusi efektif karena metode ini memiliki keunggulan yang saling melengkapi. CNN berperan dalam ekstraksi fitur secara otomatis dari citra butiran pasir, memungkinkan sistem untuk mengenali pola dan karakteristik pasir tanpa memerlukan intervensi manusia secara langsung. Namun, ekstraksi fitur saja belum cukup untuk melakukan pengelompokan pasir berdasarkan kualitasnya. Oleh karena itu, metode *K-Means* digunakan setelah CNN untuk melakukan klasterisasi berdasarkan fitur yang telah diekstraksi, sehingga butiran pasir dapat dikategorikan ke dalam kelompok. Kombinasi kedua metode ini memastikan bahwa proses identifikasi dan pengelompokan pasir dilakukan dengan cepat, akurat, dan lebih objektif dibandingkan dengan metode konvensional, sehingga mendukung pemilihan material pasir yang lebih sesuai untuk konstruksi lantai dan plesteran dinding yang tahan lama. Sistem yang akan dirancang saat ini diharapkan mampu untuk mendeteksi dan mengelompokkan citra butiran pasir dengan cepat dan responsif dalam menentukan pasir yang sesuai untuk lantai dan plesteran dinding. Hal ini dapat membantu untuk menciptakan ketahanan plesteran dan lantai dikarenakan kesesuaian pasir yang digunakan.

2. Metodologi Penelitian

Penelitian ini menggunakan serangkaian langkah sistematis yang dirancang secara cermat untuk memastikan pelaksanaan berjalan secara efektif dan efisien. Setiap tahapan guna menjaga fokus pada tujuan utama dari penelitian serta meminimalkan resiko yang menyimpang dari pokok pembahasan. langkah-langkah

dan alur pengerjaan yang dilakukan untuk menyelesaikan suatu penelitian agar proses pengerjaan penelitian lebih sistematis dan terstruktur. Langkah-langkah yang digunakan untuk menyelesaikan permasalahan yang dibahas lebih jelasnya mengenai kerangka kerja ini. Adapun kerangka penelitian yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Kerangka Kerja Penelitian

Berdasarkan alur kerja yang ditampilkan pada Gambar 1, setiap tahapan dalam alur tersebut dapat dijelaskan secara rinci menunjukkan urutan proses yang harus diikuti dari tahapan awal sampai akhir. Alur kerja ini secara sistematis untuk memastikan bahwa seluruh proses penelitian berjalan secara terstruktur dan terarah dengan tujuan yang telah ditetapkan. Setiap tahapan memiliki peran penting dalam mendukung kualitas hasil penelitian. penjelasan detail dari tiap langkah akan membantu memahami bagian setiap alur yang dibuat.

1. Identifikasi Masalah

Langkah awal dari penelitian ini adalah tahap identifikasi masalah. Pada tahap ini, peneliti meninjau objek yang akan diteliti, mengidentifikasi permasalahan utama yang terkait dengan objek tersebut, serta menentukan ruang lingkup penelitian. Proses ini membantu memastikan bahwa penelitian fokus pada isu-isu yang relevan dan dapat menghasilkan temuan yang signifikan. Berdasarkan hal tersebut makapenulis dapat menentukan rencana kerja serta menentukan data apa saja yang dibutuhkan dalam penelitian ini.

2. Studi Literatur

Penelitian ini dimulai dengan melakukan Studi Literatur yang mencakup berbagai artikel, e-Book dan buku relevan dengan penggunaan algoritma ResNet- 50 melalui metode Metode *Convolutional Neural Network* (CNN) dan K-Means Clustering.

3. Pengumpulan Data

Pengumpulan data dilakukan dengan metode studi lapangan dan riset yang dilakukan. Data yang dipergunakan dalam penelitian ini merupakan sekumpulan citra pasir. Data dalam bentuk citra atau

gambar yang diambil dengan kamera cannon. Dataset dalam penelitian ini 74 citra atau gambar.


4. Pengolahan Data

Tahapan Setelah data terkumpul, langkah selanjutnya adalah Proses preprocessing bertujuan ini terdiri dari beberapa tahapan penting yaitu melibatkan tahapan resizing, normalisasi dan augmentasi citra, yang mana masing-masing memiliki peran dalam meningkatkan kualitas data. Setiap proses yang dilakukan berguna untuk meningkatkan kemampuan dalam mengenali objek pada berbagai kondisi. Tahapan ini sangat membantu mengurangi risiko *overfitting* dan meningkatkan kemampuan generalisasi baik.

- a. Proses Resizing akan merubah semua data, yaitu semua citra butiran pasir yang berhasil dikumpulkan, menjadi dimensi yang konsisten. Ukuran yang dipilih untuk disesuaikan dengan ukuran input standar arsitektur ResNet-50, akan dipakai dimensi 224 x 224 piksel.
- b. Normalisasi penelitian ini menormalisasikan nilai piksel citra (gambar) dengan membagi nilai piksel dengan 255 sehingga nilai piksel berada dalam rentang 0 hingga 1.
- c. Augmentasi Pengumpulan data adalah teknik yang digunakan untuk memperbesar dataset dengan membuat variasi dari gambar yang ada. Teknik augmentasi yang digunakan dalam penelitian ini. Rotasi dilakukan untuk Memutar citra butiran pasir pada sudut tertentu untuk menghasilkan variasi orientasi gambar. Pembalikan Horizontal dilakukan Membalikkan citra butiran pasir secara horizontal untuk meningkatkan variasi data. Zoom dilakukan Memperbesar atau memperkecil citra butiran pasir untuk mensimulasikan gambar yang diambil dari jarak yang berbeda. Pergeseran dilakukan Menggeser gambar ke kiri, kanan, atas, atau bawah untuk menambah variasi posisi objek dalam gambar. Shear dilakukan Menggeser satu bagian gambar lebih dari bagian lain untuk menciptakan efek perspektif.

5. Arsitektur CNN ResNet 50

Model CNN yang digunakan dalam penelitian ini menggunakan model pra latih yang telah dilatih pada dataset yang besar dan serbaguna seperti ImageNet, yang berisi jutaan gambar dari ribuan kategori. Penggunaan model pelatihan ini sangat bermanfaat karena memungkinkan jaringan memanfaatkan fitur visual yang telah telah dipelajari sebelumnya dari datset yang sangat besar dan beragam. Dalam konteks *Convolutional Neural Networks*(CNN), model pra-latih seperti ResNet-50 telah belajar mengenali berbagai pola, bentuk, dan fitur dari gambar-gambar ini. pra-latih seperti ResNet-50 memiliki kemampuan mendalam dalam mengekstraksi fitur tingkat rendah hingga tingkat tinggi.

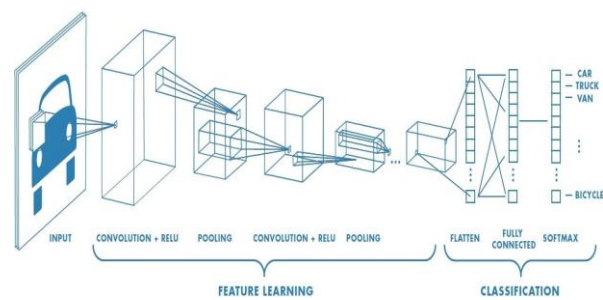


Gambar 2. Arsitektur CNN ResNet 50

Gambar 2 menunjukkan arsitektur model Residual Network (ResNet) yang terdiri dari 50 lapisan, termasuk lapisan konvolusi, *batch normalization*, aktivasi ReLU, dan *fully connected layer*. Keunggulan utama dari model ini terletak pada penggunaan *residual block*, yaitu teknik koneksi jalur pintas (*shortcut connection*) yang memungkinkan informasi melewati beberapa lapisan tanpa perubahan. Arsitektur ini terdiri dari 50 lapisan yang dirancang untuk mengekstraksi fitur visual dari data citra secara bertahap dengan mempertahankan informasi penting melalui koneksi residual (*residual block*). Proses ekstraksi fitur dimulai dengan tahap awal yang melibatkan *zero padding* untuk menjaga dimensi citra, diikuti dengan lapisan konvolusi yang bertugas mendeteksi fitur dasar seperti tepi dan tekstur gambar. Setelah itu, dilakukan proses normalisasi menggunakan *batch normalization* yang berfungsi menstabilkan distribusi data dan mempercepat proses pelatihan jaringan.

6. Ekstraksi Fitur

Analisa sistem difokuskan kepada penerapan deep learning dengan menggunakan metode CNN arsitektur ResNet-50. Penggunaan CNN arsitektur ResNet-50 di penelitian ini dipakai untuk ekstraksi fitur. ResNet-50 adalah salah satu dari banyak varian dari arsitektur ResNet, yang dibedakan berdasarkan jumlah lapisan dalam jaringan. ResNet-50 terdiri dari 50 lapisan, yang mencakup kombinasi dari lapisan Konvolusi, lapisan *pooling*, dan lapisan fully connected.



Gambar 3. Arsitektur CNN

Gambar 3 diatas terlihat bagian lapisan fully connected tidak akan digunakan pada penelitian, dikarenakan hanya bagian-bagian lapisan untuk kebutuhan ekstraksi fitur. Model yang digunakan untuk kebutuhan ekstraksi fitur adalah ResNet 50 yang terdiri dengan layer dengan stage proses konvolusi. Citra masukan menggunakan citra dengan resolusi 224 x 224 serta 3 channel yang digunakan dalam proses ekstraksi fitur.

7. Klasterisasi Fitur

Klasterisasi adalah teknik dalam analisis data yang bertujuan untuk mengelompokkan data ke dalam beberapa kelompok (klaster) sehingga data dalam satu klaster memiliki kemiripan tinggi sementara data antar klaster berbeda secara signifikan. Dalam penelitian ini, kita menggunakan fitur yang diekstraksi oleh CNN ResNet-50 dari citra butiran pasir dan kemudian mengelompokkan fitur-fitur tersebut menggunakan algoritma K-Means. Langkah-langkah yang dilakukan dalam klasterisasi fitur sebagai berikut ini [20]:

- a. Inisialisasi : pilih K titik awal sebagai centroid awal secara acak.
- b. Assigment step: Tetapkan setiap titik data ke centroid terdekat.
- c. Update Step : Hitung ulang centroid sebagai rata-rata dari semua titik data dalam klaster tersebut.
- d. Iterasi : Ulangi langkah 2 dan 3 sampai centroid tidak lagi berubah secara signifikan atau setelah mencapai jumlah iterasi maksimum.

3. Hasil dan Pembahasan

Tahap awal dalam melakukan pengolahan citra menggunakan metode CNN dan K-Means adalah mengumpulkan data pasir. Data sample ini akan diolah menggunakan metode CNN terlebih dahulu untuk menghasilkan ekstraksi fitur. Dimana CNN memiliki keunggulan dalam mendeteksi fitur dengan baik, setelah proses CNN sudah dilakukan masuk ketahapan selanjutnya menggunakan K-Means Clustering untuk mengelompokkan data butiran pasir.

3.1 Convolutional Neural Network

Convolutional Neural Network(CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah video, gambar. CNN terdiri dari beberapa lapisan, termasuk lapisan konvolusi, yang bertugas mengekstraksi fitur dari input dengan menerapkan filter atau kernel yang digeser sepanjang gambar, menghasilkan peta fitur. Pada penelitian ini CNN hanya digunakan untuk ekstraksi saja, setelah hasil ekstraksi didapatkan maka dilanjutkan pada proses K-Means Clustering.

1. Operasi Konvolusi

Konvolusi didefinisikan sebagai proses untuk memperoleh suatu piksel didasarkan pada nilai piksel itu sendiri dan tetangganya dengan melibatkan suatu matriks yang disebut kernel yang merepresentasikan pembobotan. Proses Konvolusi memanfaatkan apa yang disebut sebagai filter. Seperti layaknya gambar, filter memiliki ukuran tinggi, lebar, dan tebal tertentu. Lapisan Konvolusi menggunakan filter (kernel) untuk memindai gambar input dan menghasilkan peta fitur (feature map). Setiap filter dapat mendeteksi fitur spesifik dalam gambar. Pada Percobaan ini digunakan kernel 3x3 dengan nilai seperti Gambar 4.

1	0	-1
1	0	-1
1	0	-1

Gambar 4. Kernel

Langkah selanjutnya adalah dilakukan perhitungan pada setiap channel diatas dengan kalikan dengan kernel ukuran 3X3 pada gambar diatas. Tahapan dilakukan berulang dengan pergeseran kernel sebanyak 1 kali sebanyak 1 strides disetiap channelnya sehingga mendapatkan perhitungan dari setiap channel berikutnya.

0	0	0	0	0	0
0	191	192	194	194	0
0	193	193	194	192	0
0	190	191	193	193	0
0	189	189	192	193	0
0	0	0	0	0	0

0	0	0	0	0	0
0	191	192	194	194	0
0	193	193	194	192	0
0	190	191	193	193	0
0	189	189	192	193	0
0	0	0	0	0	0

+	0	0	0	0	0
0	191	192	194	194	0
0	193	193	194	192	0
0	190	191	193	193	0
0	189	189	192	193	0
0	0	0	0	0	0

0	0	0	0	0	0
0	191	192	194	194	0
0	193	193	194	192	0
0	190	191	193	193	0
0	189	189	192	193	0
0	0	0	0	0	0

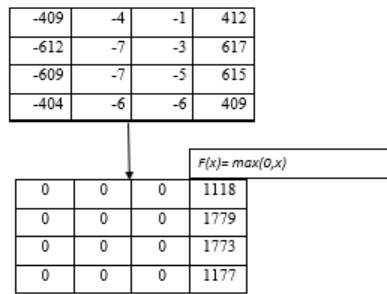
Gambar 5. Operasi Konvolusi

Gambar 5. Diatas adalah Lapisan pooling yang merupakan salah satu tahapan penting dalam jaringan konvolusi (CNN) untuk pengolahan citra. Lapisan pooling berfungsi mengurangi dimensi peta fitur sambil mempertahankan informasi penting. Teknik umum yang digunakan adalah max pooling dan average pooling. Sementara itu, average pooling menghitung rata-rata nilai piksel dalam jendela filter, sehingga menghasilkan keluaran yang lebih halus dengan mempertahankan informasi umum dari area tersebut.

2. Lapisan Aktivasi (Activation Layers)

Linear Unit adalah fungsi aktivasi yang umum digunakan pada CNN. Hasil perhitungan dari operasi konlusional layer selanjutnya adalah tahapan ReLU yang mana pada aktivitas ReLU mengonversikan

Activation Relu maka setiap nilai yang negative akan diubah menjadi angka 0 sehingga didapatkanlah hasil convolution seperti Gambar 6.




Gambar 6. Lapisan Aktivasi (Activation Layers)

Pada Gambar 6. adalah Proses diatas ini akan berulang sampai keseluruhan citra dengan menggunakan jenis filter yang berbeda sehingga keluaran dari tahapan konvolusi layer ini menghasilkan banyak feature map. merupakan salah satu contoh dari *feature map*. Pada CNN hasil dari ReLU nantinya akan menjadi inputan baru untuk layer selanjutnya.

3. Pooling Layer

Pooling layer adalah lapisan yang menggunakan fungsi dengan feature map sebagai masukan dan mengolah dengan berbagai macam operasi statistic berdasarkan piksel terdekat. Dari hasil tahapan ReLU output tahapan Konvolusi akan dijadikan input untuk *pooling* layer. Pada tahapan ini menggunakan *maxpooling* dengan kernel size 3x3 dengan strides 1 dari tahapan 3x3x32. Ilustrasi kerja dari *maxpooling* seperti Gambar 7.

Gambar 7. diatas adalah tahapan *maxpolling* dimana pada tahapan ini menggunakan kernel 3x3, dari nilai kernel ini akan diambil nilai tertinggi maka didapatkan untuk stage pertama 0, selanjutnya dilakukan pergeseran kernel sebanyak 1 kali karena penulisan menggunakan strides 1. Nilai kernel 3x3 matrik nilai hasil dari *maxpolling*, dan begitu seterusnya hingga selesai sehingga didapatkan output *maxpolling* dengan nilai 0.1179, 0.1773.



Gambar 7. Pooling Layer

4. Dropout Layer

Fungsi *Dropout* mengurangi kompleksitas model yang telah dibangun dengan membuang neural network yang tidak terpakai. Untuk ukuran model akan tetap yaitu 2x2x32 dan tidak ada perubahan pada tahap ini. Dengan cara ini, *Dropout* Layer membantu meningkatkan generalisasi model dengan mengurangi ketergantungan berlebihan pada neuron tertentu, memungkinkan jaringan untuk belajar representasi yang lebih robust dan mengurangi risiko overfitting pada data pelatihan.

5. Flattening layer

Pada tahapan *flatten* layer fungsinya adalah untuk mengubah matrik kedalam bentuk vector atau metrik 1 dimensi. Output *Dropout* layer sebesar 2x2x32 akan mendapatkan bentuk vector baru. Gambar ilustrasi dapat dilihat pada seperti Gambar 8.



Gambar 8. Flattening layer

Gambar 8 adalah proses *flatten* dimana matrix 2x2 diubah menjadi 4x1 atau vector. Setelah melewati lapisan konvolusi dan *pooling*, data umumnya matriks atau sensor dengan beberapa dimensi, seperti ukuran tinggi, lebar dan jumlah saluran. Output pada tahapan ini adalah vector 1 dimensi yang nanti akan digunakan sebagai input di *Fully Connected Layer* (dense).

6. Fully Connected Layer


Fully Connected Layer dalam CNN adalah lapisan dimana setiap neuron terhubung sepenuhnya dengan setiap neuron dilapisan sebelumnya. FC berguna untuk mengintegrasikan informasi dari fitur yang telah diekstraksi oleh *lapisan* konvolusi dan *pooling*, dan menghasilkan output akhir seperti klasifikasi atau prediksi. Melalui proses pembelajaran, *Fully Connected Layer* membantu model dalam memetakan input ke output dengan menyesuaikan bobot setiap koneksi untuk meminimalkan kesalahan prediksi. Output dari tahapan *flatten* layer adalah vector 1 dimensi yang nanti akan menjadi inputan pada berikut ilustrasi tentang *Fully Connected Layer* seperti Gambar 9.

$$J1 = (0 \times 0,1) + (1779 \times 0,1) + (0 \times 0,1) + (1779 \times 0,1) = 335,8$$

$$J2 = (0 \times 0,4) + (1779 \times 0,4) + (0 \times 0,4) + (1779 \times 0,4) = 1423,2$$

$$J3 = (0 \times 0,5) + (1779 \times 0,5) + (0 \times 0,5) + (1779 \times 0,5) = 1779 \text{ J}$$

$$4 = (0 \times 0,3) + (1779 \times 0,3) + (0 \times 0,3) + (1779 \times 0,3) = 1067,4$$



Gambar 9. Fully Connected Layer

Hidden layer pertama di ilustrasikan dengan j_1, j_2, j_3, j_4 dimana setiap neuron dari I_1, I_2, I_3, I_4 dikalikan dengan nilai weight yang berbeda – beda sehingga menghasilkan nilai $j_1=335,8$ $j_2=1423,2$, $j_3=1779$, $j_4=1067,4$. Setiap nilai dai j_1, j_2, j_3 dan j_4 akan dikalikan lagi dengan weight yang berbeda – beda untuk menghasilkan nilai dai h_1, h_2, h_3 dan h_4 sebagai hidden layer selanjutnya.

$$H_1 = (0,3 \times 335,8) + (0,3 \times 1423,2) + (0,3 \times 1779) + (0,3 \times 1067,4) = 1387,62$$

$$H_2 = (0,4 \times 335,8) + (0,4 \times 1423,2) + (0,4 \times 1779) + (0,4 \times 1067,4) = 1850,16$$

$$H_3 = (0,5 \times 335,8) + (0,5 \times 1423,2) + (0,5 \times 1779) + (0,5 \times 1067,4) = 2312,7$$

$$H_4 = (0,2 \times 335,8) + (0,2 \times 1423,2) + (0,2 \times 1779) + (0,2 \times 1067,4) = 925,08$$

Fungsi ini mengonversikan skor mentah dari setiap kelas menjadi nilai 0 hingga 1, dimana jumlah totalnya sama dengan 1, sehingga dapat diartikan sebagai probabilitas. Setiap neuron dari h_1, h_2, h_3 dan h_4 ini akan dikalikan lagi dengan weight yang berbeda-beda untuk mendapatkan nilai dari o_1 dan o_2 sebagai hidden layer selanjutnya. Langkah selanjutnya adalah perhitungan softmax dengan rumus eksponensial o_1 dibagi dengan total eksponensial o_1 dan eksponensial o_2 . Tahap ini dilakukan dua kali baik pada o_1 ataupun o_2 mendapatkan hasil 1.

3.2 Klusterisasi Menggunakan K-Means

Klusterisasi adalah teknik dalam analisis data yang bertujuan untuk mengelompokkan data ke dalam beberapa kelompok (kluster) sehingga data dalam satu kluster memiliki kemiripan tinggi sementara data antar kluster berbeda secara signifikan. Dalam penelitian ini, kita menggunakan fitur yang diekstraksi oleh CNN ResNet-50 dari citra butiran pasir dan kemudian mengelompokkan fitur-fitur tersebut menggunakan algoritma K-Means. Implementasikan K-Mean dapat dilakukan dengan menggunakan langkah-langkah berikut ini:

1. Inisialisasi Objek KMeans Tentukan jumlah kluster $n_clusters$, dalam penelitian ini akan digunakan nilai $n_clusters = 5$

2. Gunakan parameter `random_state` untuk mendapatkan hasil yang dapat direproduksi. 2. Fit dan Predict : Gunakan metode `fit_predict` untuk melakukan klusterisasi dan mendapatkan label kluster untuk setiap data.
3. Visualisasi Hasil Setelah klusterisasi, kita dapat memvisualisasikan hasilnya dengan menggunakan teknik visualisasi seperti PCA (Principal Component Analysis) untuk mengurangi dimensi data.

3.3 Hasil Pengujian

Hasil pengujian dari penelitian ini menunjukkan bahwa proses klusterisasi jenis butiran pasir berhasil dilakukn berdasarkan bentuk dan tekstur. Setiap pengujian dari citra akan diklusterisasikan dalam bentuk katerogi butiran tumpul, butiran angular, butiran bulat dan butiran tajam. Tahap pengujian ini membuktikan bahwa metode yang digunakan mampu membedakan jenis pasir sesuai dengan karakteristiknya, sehingga dapat membantu fungsi penggunaan pasir lebih efektif. berikut hasil pengujian Tabel 1.

Tabel 1. Hasil Pengujian

No	Jenis Butiran Pasir	Gambar	Pengelompokkan	Hasil
1.	Air Haji Basah		Butiran tumpul	Plesteran Dinding
2.	Sako		Butiran Sub Angular	Lantai
3.	Campuran Korral dan pasir sungai penuh dalam kondisi basah		Butiran Tidak beraturan	Lantai
4.	Tapan		Butiran Bulat	Plesteran Dinding
5.	Campuran korral dan pasir tanah kampung dalam kondisi kering		Butiran Tajam	Lantai

Tabel 2 menunjukkan hasil pengujian jenis butiran pasir berdasarkan bentuk dan teksturnya menggunakan metode *Convolutional Neural Network (CNN)* dan *K-Means Clustering*. Pengelompokkan ini dilakukan untuk menentukan jenis butiran pasir yang sesuai digunakan dalam pekerjaan konstruksi, khususnya pada

aplikasi plesteran dinding dan lantai. Berdasarkan tabel, setiap jenis pasir yang diuji memiliki karakteristik butiran yang berbeda. Hasil pengelompokan ini membuktikan bahwa tekstur dan bentuk butiran pasir sangat mempengaruhi fungsionalitas bahan bangunan pada proses konstruksi. Dengan metode ini, pemilihan bahan bangunan dapat lebih terarah sesuai dengan kebutuhan konstruksi.

Butiran Tumpul Seperti pada pasir Air Haji Basah dan Tapan, yang cocok digunakan untuk plesteran dinding karena memiliki permukaan halus yang menghasilkan daya rekat lebih baik. Butiran Sub Angular, Pasir jenis ini ditemukan pada Sako, Abu Batu, dan Birun Halus Kering. Butiran ini memiliki sudut yang tidak terlalu tajam, sehingga cocok digunakan untuk lantai yang membutuhkan kekuatan lebih baik. Butiran Tidak Beraturan. Ditemukan pada Campuran Korala dan Pasir Sungai Penuh dan Sarolagun. Pasir ini memiliki bentuk tidak seragam dan digunakan untuk lantai, karena mampu memberikan daya ikat lebih kuat. Butiran Tajam Ditemukan pada Campuran Korala dan Pasir Tanah Kampung, yang cocok digunakan untuk lantai karena mampu meningkatkan kekuatan.

8. Kesimpulan

Penelitian ini menunjukkan bahwa penerapan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50 sebagai ekstraksi fitur dan algoritma K-Means Clustering efektif dalam mengelompokkan butiran pasir yang sesuai untuk plesteran dinding atau lantai. dengan 74 citra butiran pasir. Terdapat butiran sub angular sebanyak 14 citra cocok digunakan untuk lantai, butiran tidak beraturan sebanyak 20 citra cocok digunakan untuk lantai, butiran tumpul sebanyak 10 citra cocok digunakan untuk plesteran dinding, butiran bulat sebanyak 12 citra untuk plesteran dinding, dan butiran tajam sebanyak 15 citra cocok digunakan untuk lantai.

Daftar Rujukan

- [1] A. Randi, K. Kunci, Dan : Sipil, "Penggunaan Material Komposit Dalam Konstruksi Bangunan Bertingkat Tinggi: Kelebihan Dan Tantangan," 2024.
- [2] A. Lutfi, A. S. M. Agus, S. Al Fathoni, Dan B. Afriandini, "The Analysis Influence Of Sludge Level In Sands Towards The Compressive Strength Of Concrete (Semaya Sand And Sikasur Sand)," 2022. [Daring]. Tersedia Pada: <http://jurnalnasional.ump.ac.id/index.php/civeng>
- [3] L. Hakim Dkk., "Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network," 2023. [Daring]. Tersedia Pada: <https://ejournal.teknokrat.ac.id/index.php/teknoinfo/index>
- [4] B. Adhitya, A. Prabawa, Dan H. Kencana, "Analisis Pengaruh Pendidikan, Kesehatan, Sanitasi Dan Rata-Rata Jumlah Anggota Keluarga Per Rumah Tangga Terhadap Kemiskinan Di Indonesia," *Ekonomis: Journal Of Economics And Business*, Vol. 6, No. 1, Hlm. 288, Mar 2022, Doi: 10.33087/Ekonomis.V6i1.501.
- [5] P. Yane Putri, "Analisis Kekuatan Beton Normal Menggunakan Pasir Petok Sebagai Agregat Halus," 2022, [Daring]. Tersedia Pada: <http://ejournal.unp.ac.id/index.php/cived/index>
- [6] M. Hudori, M. Tandedi, A. T. Sentanu, M. A. Ferdinand, Dan J. Rab, "Studi Pengujian Kadar Lumpur Agregat Halus Pada Pasir Di Kota Batam," 2022. [Daring]. Tersedia Pada: <http://jurnal.univrab.ac.id/index.php/racic>
- [7] R. D. Fatika Dkk., "Meningkatkan Kapasitas Kuat Tekan Beton Dengan Kendala Kadar Lumpur Agregat Halus," *Cived*, Vol. 10, No. 1, Hlm. 190, Mar 2023, Doi: 10.24036/Cived.V10i1.121338.
- [8] J. Khatib Sulaiman, U. Klasifikasi Jenis Beras Berdasarkan Citra Digital Robi Ardiansyah, E. Itje Sela, Dan U. Teknologi Yogyakarta, "Implementasi Convolutional Neural Network," *Indonesian Journal Of Computer Science Attribution*, Vol. 12, No. 6, Hlm. 2023-4172, 2023.
- [9] J. Khatib Sulaiman, Z. Azhari, L. Efrizoni, W. Agustin, R. Yanti, Dan S. Amik Riau Pekanbaru, "Opinion Mining Menggunakan Algoritma Deep Learning Untuk Menganalisis Penggunaan Aplikasi Jamsostek Mobile," *Indonesian Journal Of Computer Science Attribution*, Vol. 12, No. 2, Hlm. 2023-666, 2023.
- [10] S. Adiningsi Dan R. A. Saputra, "Jip (Jurnal Informatika Polinema) Identifikasi Jenis Daun Tanaman Obat Menggunakan Metode Convolutional Neural Network (Cnn) Dengan Model Vgg16," 2023.
- [11] D. Iswantoro Dan D. Handayani Un, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (Cnn)," *Jurnal Ilmiah Universitas Batanghari Jambi*, Vol. 22, No. 2, Hlm. 900, Jul 2022, Doi: 10.33087/Jiubj.V22i2.2065.
- [12] H. Gunawan Dan V. Purwayoga, "Data Mining Menggunakan Algoritma K-Means Clustering Untuk Mengetahui Potensi Penyebaran Virus Corona Di Kota Cirebon," *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, Vol. 11, No. 1, Hlm. 1-8, Jan 2022, Doi: 10.32736/Sisfokom.V11i1.1316.
- [13] I. Dinda Anjani Dan A. Bahtiar, "Penerapan Algoritma K-Means Clustering Untuk Mengelompokkan Penerima Bantuan Sosial Tunai (Bst) Di Jawa Barat," 2024.
- [14] E. Oktafanda, "Klasifikasi Citra Kualitas Bibit Dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (Cnn)," *Jurnal Informatika Ekonomi Bisnis*, Hlm. 72-77, Agu 2022, Doi: 10.37034/InfEb.V4i3.143.
- [15] D. Hidayat, "Klasifikasi Jenis Mangga Berdasarkan Bentuk Dan Tekstur Daun Menggunakan Metode Convolutional Neural Network (Cnn) Classification Of Types Of Mango Based On Leave Shape And Texture Using Convolutional Neural Network (Cnn) Method," *Journal Of Information Technology And Computer Science (IntecomS)*, Vol. 5, No. 1, 2022.
- [16] U. Sri Rahmadhani Dan N. Lysbetti Marpaung, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode Cnn," Vol. 8, No. 2, 2023.
- [17] M. T. A. Syech Ahmad Dan B. Sugiarto, "Implementasi Convolutional Neural Network (Cnn) Untuk Klasifikasi Ikan Cupang Berbasis Mobile," *Digital Transformation Technology*, Vol. 3, No. 2, Hlm. 712-723, Des 2023, Doi: 10.47709/Digitech.V3i2.3245.
- [18] F. Ilmawan Dan A. Ramadhanu, "Implementasi Metode K-Means Untuk Klasterisasi Varietas Parpika Dengan Menggunakan Teknik Pengolahan Citra Digital," *Jurnal Informatika Teknologi Dan Sains*, Vol. 7, No. 1, Hlm. 249-254, 2025.
- [19] D. Haversyalapa, S. Puspari, Dan R. Gustriansyah, "Klasterisasi Pixel Citra Koleksi Foto Museum Monpera Dengan Metode K-Means Pada Aplikasi Augmented Reality," 2024. [Daring]. Tersedia Pada: <http://jom.fti.budiluhur.ac.id/index.php/idealis/index>
- [20] I. Rosa, A. Ramadhanu, M. Teknik Informatika, Dan U. Yptk Padang, "Identifikasi Cerdas Apel Fuji Dan Apel Hijau: Pendekatan K-Means Clustering Untuk Segmentasi Buah," 2024.
- [21] A. Rachmad, M. H. Rohman, Dan W. Setiawan, "Pengaruh Reduksi Dimensi Pada Clustering Citra Daun Tomat Menggunakan Darknet19 Dan K-Means Effect Of Dimensionality Reduction On Tomato Leaf Image Clustering Using Darknet19 And K-Means," 2023.

- [22] I. R. Nr, E. Prasetyowati, Dan D. B. Said, “Penerapan Citra Berbasis K-Means Clustering Untuk Mendeteksi Penyakit Bulai Pada Komoditas Jagung Madura,” 2023. [Daring]. Tersedia Pada: <https://jurnal.umj.ac.id/index.php/Just-It/Index>