

Optimalisasi Inspeksi Kegagalan: Pengembangan *Unmanned Aerial Vehicles* Terintegrasi *Shallow CNN Architecture* dan IoT Sebagai Pendeteksi Dini Kegagalan Struktur



Bima Bagus Setyobudi^{1*}

¹Mechanical Engineering, Faculty of Industrial Technology and Systems Engineering, Institut Teknologi Sepuluh Nopember, Indonesia

ABSTRACT

Structural failures in buildings and infrastructure are a serious and frequent issue. Failure to detect structural damage early can lead to the collapse of buildings or infrastructure, resulting in loss of life and material damage. In Indonesia, structural failures in construction accidents accounted for 32% of work-related accidents in 2019. Conventional inspection methods still have significant limitations, such as being time-consuming and restricted to easily accessible areas. Additionally, modern AI-integrated inspection methods require optimization for better implementation. To address these challenges, an optimized structural failure inspection system was designed, utilizing Unmanned Aerial Vehicles (UAVs) integrated with Shallow CNN Architecture and IoT. A dataset containing 40,000 images was used, and the OLeNet (Optimized LeNet) model as the Shallow CNN Architecture achieved an accuracy of 99.8%. Moreover, OLeNet showed advantages in computational time, outperforming similar deep learning methods. The UAV implementation addresses the issue of limited accessibility to inspection areas, while the IoT integration allows for real-time data storage, offering a more efficient and scalable solution.

ABSTRAK

Kecelakaan yang disebabkan oleh kegagalan struktural pada bangunan dan infrastruktur merupakan masalah serius yang masih sering terjadi. Kegagalan struktural yang tidak terdeteksi pada tahap awal dapat menyebabkan keruntuhan bangunan atau infrastruktur lainnya, yang berujung pada hilangnya nyawa serta kerugian material. Di Indonesia, kecelakaan akibat kegagalan struktur juga menjadi isu penting. Pada tahun 2019, sektor konstruksi mencatatkan angka kecelakaan sebesar 32% dari total kecelakaan kerja disebabkan oleh kegagalan struktur bangunan. Metode inspeksi konvensional masih memiliki sejumlah kelemahan, seperti memakan waktu yang lama serta terbatas pada area yang mudah dijangkau. Di samping itu, inspeksi modern yang terintegrasi dengan AI masih memerlukan optimalisasi dalam implementasinya. Berdasarkan permasalahan tersebut, dirancang optimalisasi inspeksi kegagalan struktur berbasis Unmanned Aerial Vehicles (UAV) yang terintegrasi dengan *Shallow CNN Architecture* dan IoT. Dalam hal ini, digunakan dataset open source dengan entry 40.000 gambar. Model OLeNet (*Optimized LeNet*) sebagai *Shallow CNN Architecture* menunjukkan akurasi hingga 99,8%. Selain itu, OLeNet menunjukkan keunggulan dalam penggunaan waktu komputasi yang lebih singkat dibandingkan metode *deep learning* sejenis. Implementasi model pada UAV mengatasi permasalahan keterbatasan area yang dapat dijangkau, ditambah integrasi IoT yang mampu menyimpan data secara *real-time*.

PENDAHULUAN

Kecelakaan yang disebabkan oleh kegagalan struktural pada bangunan dan infrastruktur merupakan masalah serius yang masih sering terjadi dan menjadi ancaman bagi keselamatan manusia serta kerugian material yang tidak sedikit. Kegagalan struktural yang tidak terdeteksi sejak awal sering kali berujung pada keruntuhan bangunan atau infrastruktur lainnya, yang tidak hanya mengancam nyawa tetapi juga menimbulkan kerugian yang besar dalam hal

CONTACT

bimabagus.s.b.2525@gmail.com

KEYWORDS

Shallow CNN, Structural Failure, UAV Inspection

biaya perbaikan dan pemulihan. Di Indonesia, masalah kecelakaan yang disebabkan oleh kegagalan struktur juga menjadi isu yang penting. Berdasarkan data pada tahun 2019, sektor konstruksi menyumbang sekitar 32% dari total kecelakaan kerja, dengan kegagalan struktur bangunan sebagai penyebab utama (Laksono dkk., 2024). Angka ini menunjukkan bahwa masih banyak potensi untuk meningkatkan efektivitas inspeksi struktur guna mencegah kejadian serupa di masa depan.

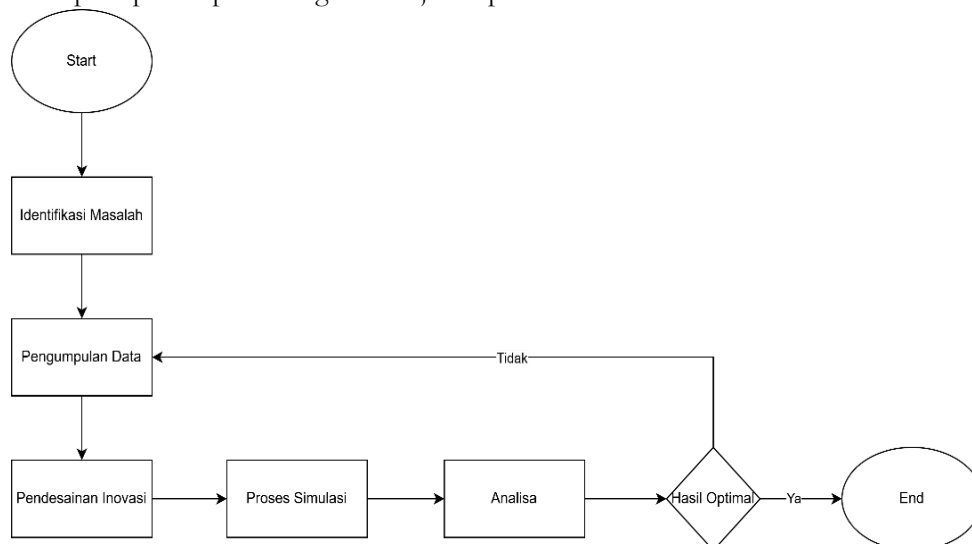
Metode inspeksi konvensional, seperti inspeksi *Non Destructive* (NDE) yang masih banyak digunakan dalam industri konstruksi saat ini memiliki sejumlah kelemahan, seperti proses yang memakan waktu lama serta keterbatasan dalam menjangkau area yang sulit diakses. Banyak penelitian terdahulu yang membahas mengenai topik ini, seperti penelitian dari Yan dkk. (2019) yang meneliti pendeteksian kesehatan struktur berbasis getaran, meskipun lebih andal dari metode konvensional, metode ini masih kurang efektif pada objek yang luas karena memerlukan peralatan yang cukup panjang menyesuaikan dengan luas pemantauan struktur.

Penelitian dari Sivasuriyan dkk. (2024) yang membahas pendeteksian kesehatan struktur dengan multi sensor yang meskipun akurat, memiliki kekurangan pada biaya yang relatif mahal terutama pada struktur yang besar dan luas. Penelitian dari Alfaz dkk. (2019), mengimplementasikan CNN dalam analisa retakan struktur jembatan dan menghasilkan akurasi yang tinggi. Meski lapisan CNN yang lebih dalam mampu menangkap informasi gambar secara lebih detail, masalah *overfitting* pada data pelatihan dan hilangnya gradien menjadi kendala utama. Tantangan ini membuat arsitektur CNN yang sangat dalam kurang efektif dan sulit digunakan. Selain itu, model tangguh seperti *VGG16*, *ResNet*, dan *Inception* memerlukan biaya komputasi yang tinggi untuk pelatihan dan penerapan, terutama dalam analisis waktu nyata (Kim dkk., 2021). Salah satu solusi dari hal tersebut adalah menggunakan *Shallow CNN* dengan Model *OLeNet* (*Optimized LeNet*). Dalam penelitian Kim dkk. (2021) model ini digunakan untuk mendeteksi kesehatan struktur dan menghasilkan akurasi yang tinggi dengan waktu komputasi yang lebih singkat dan ringan, sehingga berpotensi untuk diterapkan.

Akan tetapi, pada penelitian tersebut belum dijelaskan mengenai bentuk implementasi dari model pada kondisi pendeteksian *Real* sehingga pada penelitian ini dikembangkanlah *Unmanned Aerial Vehicles* (UAV) terintegrasi dengan *Shallow Convolutional Neural Network* (CNN) *Architecture* dan *Internet of Things* (IoT). UAV dapat mengakses area yang sulit dijangkau, sementara teknologi AI berbasis CNN mampu menganalisis data citra yang diambil secara otomatis. Dengan integrasi IoT, data hasil inspeksi dapat disimpan dan dikirim secara *real-time*, memungkinkan pengambilan keputusan yang cepat dan responsif. Dalam penelitian ini akan dijelaskan mengenai implementasi model pada UAV, strategi *path planning* pada UAV hingga integrasinya dengan IoT yang dapat menjadi acuan metode mitigasi kerusakan struktur yang efektif.

METODE

Proses perancangan inovasi didasarkan pada metode yang tersusun sistematis dengan basis data kuantitatif dan kualitatif dari literatur review beserta evaluasi hasil menggunakan proses simulasi. Adapun alur metodologi yang diimplementasikan pada proses perancangan ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Metodologi

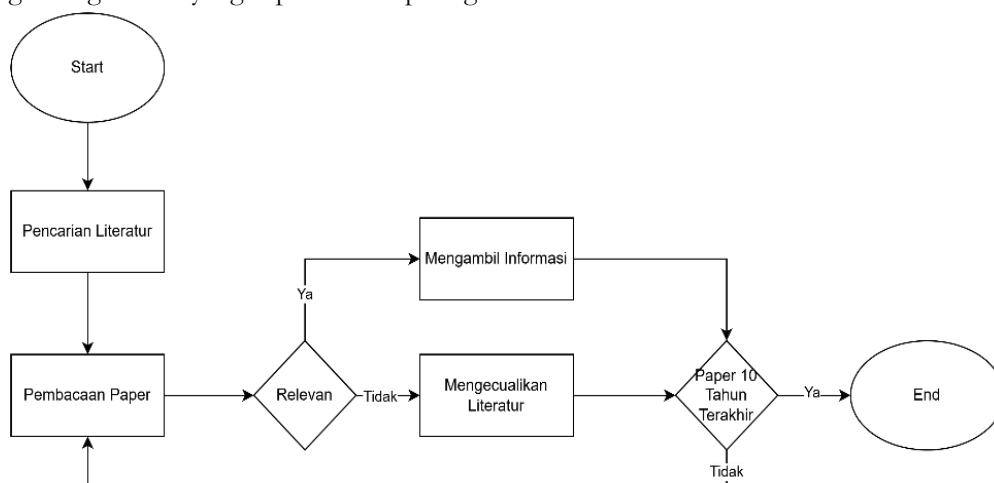
Identifikasi Masalah

Kecelakaan yang disebabkan oleh kegagalan struktural pada bangunan dan infrastruktur merupakan masalah serius yang terus mengancam keselamatan manusia dan menimbulkan kerugian material besar. Dalam memitigasi hal tersebut, dikembangkan UAV yang dilengkapi dengan Shallow CNN dan teknologi IoT untuk deteksi kerusakan struktural secara *real-time*, rumusan masalah dalam penelitian ini difokuskan pada beberapa aspek kunci yang perlu diselesaikan sebagai berikut,

- Bagaimana cara merancang UAV terintegrasi dengan *Shallow* CNN untuk pemantauan kesehatan struktural yang efektif dengan strategi path planningnya?
- Bagaimana cara mengintegrasikan IoT untuk transmisi dan analisis data secara *real-time*?
- Seberapa signifikan peningkatan dalam efisiensi deteksi dan efektivitas biaya dibandingkan dengan metode tradisional ?

Pengumpulan Data

Pengumpulan data dilakukan berdasarkan tinjauan pustaka dari jurnal-jurnal dan artikel yang relevan serta terkini, dengan diagram alir yang dapat diamati pada gambar 2.



Gambar 2. Diagram Alir Pengumpulan Data

UAV

UAV (*Unmanned Aerial Vehicles*), atau yang lebih dikenal dengan nama drone, awalnya dikembangkan untuk keperluan militer, namun kini semakin banyak digunakan dalam berbagai aplikasi sipil, termasuk pemantauan kondisi struktur, hal ini dikarenakan salah satu keunggulan utama drone, yaitu kemampuannya untuk mengakses area yang terpencil atau sulit dijangkau tanpa memerlukan intervensi manusia secara langsung, sehingga mengurangi risiko terhadap keselamatan manusia. Salah satu drone yang potensial dalam tugas tersebut adalah DJI Mavic 2 yang memiliki kelebihan pada harga yang cukup terjangkau dengan berat ringan, ukuran kompak, manuver yang baik, dan mampu terbang cukup lama dibandingkan dengan Drone sejenis (Ko dkk., 2021) ,

Drone ini mampu memungkinkan hasil yang maksimal dalam proses penangkapan gambar yang dapat dikirimkan melalui sistem *Internet of Things* kemudian diproses ke model prediksi kegagalan struktur. Dalam proses pengimplementasian model prediksi seperti CNN dan IoT, drone ini perlu untuk sedikit di *custom*, dengan mengganti kamera bawaan drone dengan kamera eksternal untuk mengintegrasikannya dengan mikrokontroler raspberry pi, dalam hal ini kamera eksternal yang cukup potensial adalah Pi HQ Camera + Lensa 6 mm.

Shallow CNN

Convolutional Neural Network (CNN) merupakan salah satu jenis arsitektur *deep learning* yang sangat populer dalam bidang pengolahan citra. CNN bekerja dengan mengekstraksi fitur spasial dari data input, seperti gambar, menggunakan lapisan-lapisan konvolusi yang terdiri dari kernel/*filter*, diikuti dengan lapisan aktivasi, subsampling (*pooling*), dan akhirnya lapisan *fully connected* untuk klasifikasi (Wang & Zuo, 2024).


Adapun, *Shallow* CNN mengacu pada CNN yang memiliki jumlah lapisan konvolusi yang relatif sedikit, biasanya hanya satu hingga tiga lapisan konvolusi (Das dkk., 2023). Berbeda dengan arsitektur *deep* CNN seperti VGG16, *Inception*, atau *ResNet* yang memiliki puluhan hingga ratusan lapisan. Arsitektur *shallow* CNN memiliki beberapa

keunggulan, terutama dalam hal efisiensi komputasi, sehingga cocok diterapkan pada perangkat dengan daya komputasi terbatas seperti sistem IoT dan UAV (*Unmanned Aerial Vehicle*).

Salah satu contoh terkenal dari *shallow CNN* adalah LeNet-5, yang pertama kali diperkenalkan oleh LeCun pada tahun 1998 untuk klasifikasi angka tulisan tangan dari dataset MNIST. *LeNet-5* memiliki arsitektur yang sederhana terdiri dari dua lapisan konvolusi yang diikuti oleh lapisan pooling dan kemudian dilanjutkan dengan tiga lapisan *fully connected*. Meskipun sederhana, *LeNet-5* sudah terbukti mampu memberikan akurasi tinggi untuk tugas klasifikasi gambar sederhana dengan beban komputasi yang ringan. *Shallow CNN* seperti *OLeNet* sangat cocok untuk tugas klasifikasi gambar dengan kompleksitas rendah atau fitur visual yang tidak terlalu bervariasi, seperti citra retak dan non-retak pada struktur beton. Dengan demikian, pendekatan *shallow CNN* menjadi solusi ideal untuk deteksi kerusakan struktur secara otomatis di lingkungan dengan sumber daya terbatas (Kim dkk., 2021)

Path Planning Strategy

Path planning atau perencanaan lintasan adalah proses penting dalam sistem navigasi otonom *Unmanned Aerial Vehicle* (UAV) yang bertujuan untuk menentukan rute optimal agar UAV dapat menjelajahi area target secara efisien dan aman. Dalam konteks inspeksi bangunan, *path planning* dirancang agar UAV dapat menjangkau seluruh permukaan eksterior bangunan dan mengambil citra dari berbagai sudut yang relevan, dengan mempertimbangkan keterbatasan seperti durasi baterai, akurasi GPS, dan hambatan lingkungan sekitar. Adapun contoh *path planning* ditunjukkan pada Gambar 3.



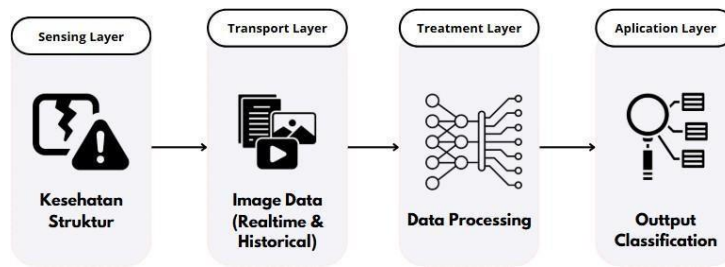
Gambar 3. Jenis *Path Planning* (a) Paralel; (b) Creeping Line; (c) Square; (d) *Sector Search*

Dalam hal ini, salah satu tipe *path* yang cukup efektif dalam penerbangan drone untuk deteksi kegagalan struktur adalah tipe paralel dan *creeping line* yang cocok untuk struktur berbentuk persegi panjang seperti dinding bangunan ataupun jembatan. Metode ini cukup efektif karena sederhana, dapat diimplementasikan secara otonom, dan cukup efektif dalam mencakup seluruh area inspeksi (Ko dkk., 2021).

Adapun dalam proses kontrolnya, dapat diimplementasikan kontrol PID untuk menjaga kestabilan drone untuk mengikuti *path* yang telah direncanakan. Kontrol PID bekerja dengan cara menghitung *error*, yaitu selisih antara nilai yang diinginkan (*setpoint*) dengan nilai aktual dari sistem, dan mengoreksinya melalui tiga komponen: *proportional*, *integral*, dan *derivative*. Komponen *proportional* memberikan respons yang sebanding dengan besar *error* saat ini untuk mempercepat reaksi sistem; komponen *integral* menjumlahkan *error* sepanjang waktu guna menghilangkan *error steady-state*; dan komponen *derivative* memprediksi perubahan *error* di masa depan berdasarkan laju perubahannya sehingga mampu meredam osilasi dan meningkatkan kestabilan sistem (Borase dkk., 2021)

Internet of Things

Internet of Things (IoT) adalah suatu konsep teknologi yang memungkinkan objek fisik untuk saling terhubung melalui jaringan, bertukar data secara otomatis, dan merespons informasi secara cerdas tanpa intervensi manusia. IoT terdiri dari empat lapisan utama, yaitu lapisan persepsi (*perception layer*), lapisan jaringan (*network layer*), lapisan pemrosesan (*processing layer*), dan lapisan aplikasi (*application layer*) (Zhang dkk., 2018). Lapisan persepsi bertanggung jawab untuk pengumpulan data melalui sensor seperti kamera. Data kemudian dikirim melalui berbagai jaringan (WiFi, 4G, Internet) ke lapisan pemrosesan yang menganalisis informasi tersebut, lalu diteruskan ke lapisan aplikasi untuk pengambilan keputusan.

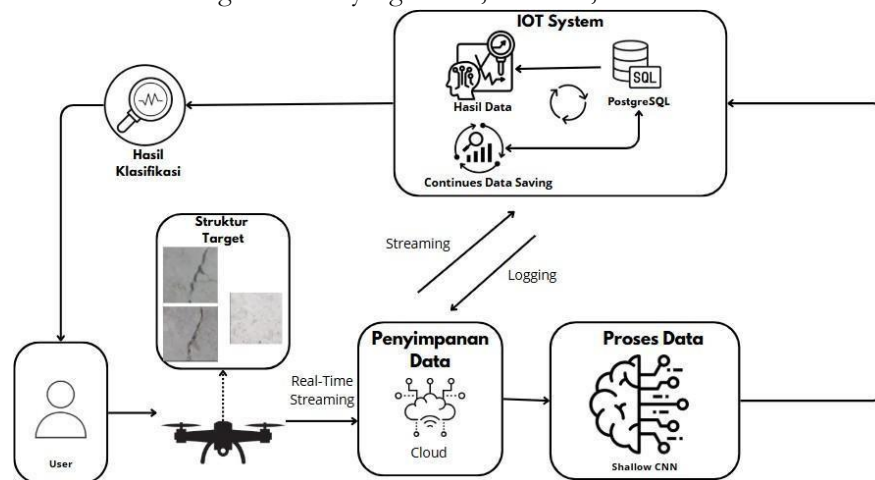


Gambar 4. Lapisan Dalam Jaringan IoT Pendeteksian Kesehatan Struktur

Secara teknis, dalam konteks sistem pendeteksian kesehatan struktur berbasis IoT, prosesnya dapat diawali dengan instalasi sensor atau kamera pada struktur jembatan untuk menangkap gambar retakan. Gambar tersebut kemudian diproses dan dimasukkan ke dalam model CNN yang telah dilatih untuk mengklasifikasikan kesehatan dari struktur. Data hasil klasifikasi dikirim ke sistem pusat menggunakan jaringan IoT untuk diarsipkan dan dipantau oleh operator teknis.

Perancangan Alat

Sistem inovasi deteksi keretakan ini menggabungkan teknologi UAV, *shallow* CNN, dan *Internet of Things* (IoT) untuk menghasilkan solusi monitoring struktural yang efisien, otomatis, dan terdistribusi.



Gambar 5. Mekanisme Kerja Alat

Proses dimulai dari pengambilan citra permukaan struktur oleh drone DJI Mavic 2, yang telah dimodifikasi untuk membawa Raspberry Pi sebagai unit kendali onboard serta kamera Pi HQ Camera lensa 6 mm sebagai sensor penglihatan eksternal. Citra yang diambil selama misi inspeksi dikirim secara *real-time streaming* ke modul penyimpanan data (*cloud* atau lokal), lalu diteruskan ke modul pemrosesan berbasis *shallow* CNN (*OLeNet*) yang berjalan langsung di Raspberry Pi. CNN ini melakukan klasifikasi cepat untuk menentukan apakah citra menunjukkan adanya retakan atau tidak.

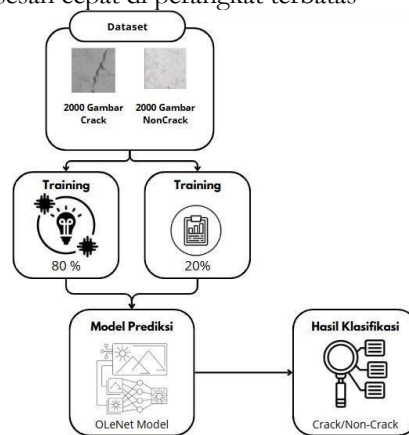
Hasil klasifikasi selanjutnya dikirimkan ke sistem IoT, yang dalam arsitektur ini berfungsi sebagai pusat manajemen data dan komunikasi. Sistem IoT tersebut memerlukan beberapa komponen tambahan agar dapat berfungsi secara optimal: (1) modul *Wi-Fi* atau LTE dongle agar Raspberry Pi dapat terhubung ke internet atau jaringan lokal untuk mentransmisikan data; (2) broker komunikasi seperti MQTT, yang digunakan sebagai protokol ringan untuk mengirim hasil klasifikasi, metadata sensor, serta status perangkat; (3) basis data PostgreSQL, yang bertugas menyimpan hasil klasifikasi, timestamp, koordinat GPS, dan ID misi untuk keperluan logging dan histori data; serta (4) *dashboard* IoT berbasis *web*, misalnya menggunakan *Node-RED*, *ThingsBoard*, atau integrasi *custom* dengan webserver *Flask/ReactJS* untuk menampilkan data hasil klasifikasi secara visual kepada pengguna.

Selain itu, sistem IoT juga mencakup mekanisme data redundancy dan backup, seperti menyimpan salinan gambar atau hasil klasifikasi di direktori lokal sebelum dikirim ke cloud, serta sistem monitoring status perangkat (termasuk suhu Pi, kapasitas penyimpanan, dan kekuatan sinyal). Semua proses dalam sistem IoT berlangsung secara berkelanjutan dan otomatis, melalui skrip daemon atau *task scheduler* (seperti *cron* atau *systemd*) di Raspberry Pi yang menjamin data terus dikirim dan disimpan tanpa intervensi manual. Dengan arsitektur ini, hasil deteksi dari

drone dapat langsung diteruskan ke pusat data dan ditampilkan kepada pengguna dalam waktu nyata, menciptakan sistem inspeksi struktural yang terjangkau, portabel, dan sangat responsif terhadap kondisi lapangan.

Perancangan Sistem Prediksi

Perancangan sistem prediksi deteksi keretakan permukaan pada struktur beton menggunakan *shallow Convolutional Neural Network* (CNN) dilakukan dengan mengadaptasi dan mengoptimalkan arsitektur dasar *LeNet-5* menjadi versi baru yang disebut *OLeNet*. Sistem ini dirancang untuk berjalan pada perangkat komputasi daya rendah, seperti Raspberry Pi, dan digunakan bersama drone DJI Mavic 2 sebagai akuisisi data visual di lapangan. Arsitektur *OLeNet* terdiri dari dua lapisan convolutional layer dengan ReLU *activation function*, yang diikuti oleh *max pooling*, *dropout layer* untuk mengurangi *overfitting*, dan *fully connected layer* untuk klasifikasi. Model ini dilatih menggunakan dataset METU yang terdiri dari 40.000 citra (ukuran 227×227 piksel) dan dikonversi menjadi ukuran yang lebih kecil (50×50 piksel) agar sesuai untuk pemrosesan cepat di perangkat terbatas



Gambar 6. Sistem Prediksi

Setelah tahap pelatihan selesai, model *OLeNet* dapat digunakan untuk memproses citra baru yang ditangkap oleh kamera Raspberry Pi HQ selama misi UAV berlangsung. Gambar yang diambil akan melalui proses *pre-processing* (*resize*, normalisasi), lalu dimasukkan ke dalam arsitektur *OLeNet* yang telah dilatih. Model akan memberikan *output* biner berupa "crack" atau "non-crack".

Simulasi Inovasi

Proses simulasi dikhususkan untuk model yang telah ditentukan, prosesnya dilakukan dengan beberapa langkah sebagai berikut, langkah ini disesuaikan dengan penelitian dari Kim dkk. (2021).

Pengumpulan dan Persiapan Dataset

Tahapan pertama dalam perancangan sistem prediksi adalah pengumpulan dan persiapan data. Dataset yang digunakan adalah METU *Concrete Crack Dataset* (Özgenel dkk., 2019), yang berisi total 40.000 gambar permukaan beton, terdiri atas dua kelas yaitu 20.000 gambar yang mengandung retakan (*crack*) dan 20.000 gambar tanpa retakan (*non-crack*). Gambar-gambar ini awalnya memiliki resolusi 227×227 piksel, namun untuk mendukung efisiensi komputasi di perangkat *embedded* seperti Raspberry Pi, ukuran citra kemudian diubah menjadi 50×50 piksel. Perubahan ukuran ini tetap mempertahankan detail penting dari citra namun memungkinkan pemrosesan yang lebih cepat dan ringan.

Pre-processing Data

Setelah data dikumpulkan, dilakukan tahap *pre-processing*. Setiap gambar hasil *resize* kemudian dinormalisasi ke dalam rentang $[0, 1]$ dengan membagi setiap pixel dengan nilai 255. Selanjutnya, label dari masing-masing gambar dikonversi menjadi *one-hot encoded vector* untuk mempermudah proses klasifikasi biner. Dataset juga dibagi menjadi dua bagian utama, yaitu 80% untuk pelatihan (*training*) dan 20% untuk validasi (*validation*), serta menggunakan teknik *K-fold cross-validation* untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting* akibat pemisahan data tetap.

Desain Arsitektur *Shallow* CNN (OLeNet)

Model *OLeNet* yang digunakan dalam penelitian ini merupakan modifikasi dari arsitektur CNN klasik *LeNet-5*, dengan penyesuaian untuk pemrosesan citra biner pada perangkat terbatas. *OLeNet* terdiri dari dua lapisan konvolusi yang masing-masing diikuti oleh lapisan *max pooling*, serta menggunakan fungsi aktivasi ReLU yang menggantikan fungsi aktivasi Tanh dari versi *LeNet* asli. Setelah ekstraksi fitur, terdapat lapisan *dropout* untuk mengurangi *overfitting*, diikuti oleh lapisan *fully connected* dan *softmax output* untuk klasifikasi akhir. Arsitektur ini dipilih karena ringan, mudah dilatih, dan terbukti efektif untuk tugas klasifikasi dua kelas.

Pelatihan Model

Pelatihan model dilakukan menggunakan *framework* Keras dengan *backend TensorFlow*, dan dikonfigurasi dengan *hyperparameter* optimal yang ditentukan melalui eksperimen, yaitu jumlah epoch sebanyak 19, *learning rate* sebesar 0.1, dan *batch size* sebanyak 64. Proses pelatihan menggunakan *optimizer Stochastic Gradient Descent* (SGD) dan fungsi *loss categorical crossentropy* yang umum digunakan dalam klasifikasi multi-kelas. Kombinasi *hyperparameter* ini terbukti memberikan keseimbangan antara kecepatan pelatihan dan akurasi tinggi, sehingga ideal untuk implementasi di perangkat dengan keterbatasan daya komputasi.

Evaluasi Performa Model

Setelah pelatihan selesai, model dievaluasi menggunakan data validasi untuk mengukur performa klasifikasinya. Dalam hal ini digunakan *Accuracy, Precision, Recall, F-Measure*.

HASIL DAN PEMBAHASAN

Hasil Evaluasi yang telah didapatkan adalah sebagai berikut,

Tabel 1. Hasil Evaluasi

Model	Accuracy	Precision	Recall	F-Measure
XGBoost	99.80%	97.95%	99.78%	99.80%

Berdasarkan hasil tersebut, model *OLeNet* mampu mencapai akurasi sebesar 99,80%, yang menunjukkan bahwa hampir seluruh data uji berhasil diklasifikasikan dengan benar antara kategori retak (*crack*) dan tidak retak (*non-crack*). Selain itu, *precision* sebesar 99,82% menunjukkan bahwa sebagian besar prediksi model yang menyatakan bahwa gambar mengandung retakan adalah benar, sehingga kesalahan prediksi positif sangat minim. Sementara itu, *recall* sebesar 99,78% menunjukkan bahwa model berhasil mengenali sebagian besar dari total gambar retak yang sebenarnya, yang berarti tingkat kelolosan citra retak sangat kecil. *F1-score* yang tercatat sebesar 99,80% menggambarkan keseimbangan yang sangat baik antara *precision* dan *recall*, serta menjadi indikator kuat bahwa model ini tidak hanya akurat secara keseluruhan, tetapi juga konsisten dalam mendeteksi kelas minor (retakan). Dengan kombinasi metrik yang hampir sempurna ini, dapat disimpulkan bahwa arsitektur *OLeNet* sangat cocok untuk diterapkan pada sistem pendeteksian retakan berbasis *edge computing* seperti Raspberry Pi, karena selain ringan, model ini juga sangat andal.

KESIMPULAN

Sistem inovatif untuk deteksi keretakan struktural berbasis integrasi *Unmanned Aerial Vehicle* (UAV), *shallow* CNN (*OLeNet*), dan *Internet of Things* (IoT) didesain untuk memberikan solusi pemantauan kesehatan struktur bangunan dan infrastruktur secara otomatis, efisien, dan *real-time*. UAV (DJI Mavic 2) dimodifikasi dengan Raspberry Pi dan kamera eksternal Pi HQ untuk mengambil gambar area struktur yang sulit dijangkau. Gambar tersebut kemudian diproses menggunakan model prediksi *OleNet* versi ringan dari CNN yang diimplementasikan secara langsung pada Raspberry Pi, menjadikannya sangat sesuai untuk sistem berbasis *edge computing*.

Dari proses simulasi menggunakan dataset METU Crack, model *OLeNet* yang dirancang dengan konfigurasi optimal (epoch 19, *learning rate* 0.1, *batch size* 64) mampu menghasilkan performa klasifikasi yang sangat tinggi, yaitu akurasi 99,80%, *precision* 99,82%, *recall* 99,78%, dan *F1-score* 99,80%. Nilai-nilai ini menunjukkan bahwa sistem tidak hanya akurat tetapi juga stabil dalam mendeteksi citra retak dan non-retak. Selain itu, sistem IoT yang dirancang mampu mengirim dan menyimpan hasil klasifikasi secara otomatis melalui jaringan nirkabel menggunakan protokol MQTT dan database PostgreSQL, serta menampilkannya dalam dashboard yang dapat diakses oleh operator teknis secara *real-time*. Integrasi ketiga teknologi ini membuktikan bahwa solusi berbasis UAV, CNN, IoT memiliki potensi besar untuk menggantikan metode inspeksi konvensional yang cenderung mahal, lambat, dan sulit menjangkau area tertentu.

DAFTAR PUSTAKA

- Alfaz, N., Hasnat, A., Khan, A. M. R. N., Sayom, N. S., & Bhowmik, A. (2022, March). Bridge crack detection using dense convolutional network (densenet). *In Proceedings of the 2nd International Conference on Computing Advancements* (pp. 509-515).
- Borase, R. P., Maghade, D. K., Sondkar, S. Y., & Pawar, S. N. (2021). A review of PID control, tuning methods and applications. *International Journal of Dynamics and Control*, 9, 818-827 Das, H. S.,
- Das, A., Neog, A., Mallik, S., Bora, K., & Zhao, Z. (2023). Breast cancer detection: Shallow convolutional neural network against deep convolutional neural networks based approach. *Frontiers in Genetics*, 13, 1097207.
- Kim, B., Yuvaraj, N., Sri Preethaa, K. R., & Arun Pandian, R. (2021). Surface crack detection using deep learning with shallow CNN architecture for enhanced computation. *Neural Computing and Applications*, 33(15), 9289-9305.
- Ko, P., Prieto, S. A., & de Soto, B. G. (2021). ABECIS: An automated building exterior crack inspection system using UAVs, open-source deep learning and photogrammetry. In ISARC. *Proceedings of the International Symposium on Automation and Robotics in Construction* (Vol. 38, pp. 637-644). IAARC Publications.
- Laksono, N., Hasiholan, Y. T., Latief, Y., & Saputro, D. E. (2024). Pengembangan Standar Work Breakdown Structure (WBS) Pekerjaan Pemeliharaan dan Perawatan Struktur Atas Jembatan Beton Berbasis Risiko untuk Meningkatkan Kinerja Keselamatan Konstruksi. *Jurnal Teknik Sipil dan Lingkungan*, 9(1), 137-146.
- Özgenel, Çağlar Fırat (2019), "Concrete Crack Images for Classification", *Mendeley Data*, V2, doi: 10.17632/5y9wdsg2zt.2
- Sivasuriyan, A., Vijayan, D. S., Devarajan, P., Stefańska, A., Dixit, S., Podlasek, A., ... in & Koda, E. (2024). Emerging trends in the integration of smart sensor technologies structural perspective. *Sensors*, 24(24), 8161. health monitoring: a contemporary
- Wang, Z., & Zuo, R. (2024). An evaluation of convolutional neural networks for lithological mapping based on hyperspectral images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- Vakalopoulou, M., Christodoulidis, S., Burgos, N., Colliot, O., & Lepetit, V. (2023). Deep learning: basics and convolutional neural networks (CNNs). *Machine learning for brain disorders*, 77-115.
- Yan J, Downey A, Cancelli A, Laflamme S, Chen A, Li J, Ubertaini F (2019) Concrete crack detection and monitoring using a capacitive dense sensor array. *Sensors*. <https://doi.org/10.3390/s19081843>
- Zhang, L., Zhou, G., Han, Y., Lin, H., & Wu, Y. (2018). Application of internet of things technology and convolutional neural network model in bridge crack detection. *Ieee Access*, 6, 39442-39451.