# Implementasi Automasi *Machine Learning Operation* Menggunakan n8n untuk Pelatihan dan Penerapan Berkelanjutan Model AI pada Aplikasi SyifAI

**Firlana Umi Azzakiy[1], Oddy Virgantara Putra[2], Aziz Musthofa [3]**
*Teknik Informatika, Universitas Darussalam Gontor*
*e-mail: firlanaumiazzakiy96@student.cs.unida.gontor.ac.id[1], oddy@unida.gontor.ac.id [2], aziz@unida.gontor.ac.id[3]*

***Kata Kunci:***

Machine Learning Operation
Continuous Training
Continuous Deployment
n8n
SyifAI

**ABSTRAK**

Penyakit kulit menempati peringkat ketujuh penyakit terbanyak di Indonesia dengan lebih dari 19.000 kasus pada 2021, sehingga deteksi dini menjadi kebutuhan penting layanan kesehatan digital. SyifAI adalah sistem kecerdasan buatan untuk mengklasifikasikan 23 jenis penyakit kulit dari citra menggunakan model ResNet18, namun pelatihan ulang dan penerapan modelnya masih dilakukan manual tanpa mekanisme terstandardisasi. Penelitian ini merancang dan mengimplementasikan alur kerja *Machine Learning Operations* (MLOps) berbasis n8n untuk mendukung *Continuous Training* dan *Continuous Deployment* pada SyifAI, melalui dua alur kerja n8n yang menangani deteksi pengguna dan pelatihan ulang terjadwal secara independen. Model baru dievaluasi otomatis terhadap model aktif berdasarkan ambang akurasi dan hanya diterapkan jika performanya meningkat. Pengujian selama 80 menit menunjukkan 17 eksekusi pelatihan ulang berjalan tepat setiap 5 menit tanpa pemicuan manual, tujuh di antaranya menyelesaikan siklus penuh, serta sistem terbukti menangani konkurensi permintaan tanpa mengganggu layanan deteksi, sehingga menghilangkan kebutuhan intervensi manual dalam pembaruan model.

***Keyword:***

*Machine Learning Operation*
*Continuous Training*
*Continuous Deployment*
*n8n*
*SyifAI*

**ABSTRACT**

*Skin diseases are the seventh most common disease in Indonesia with over 19,000 cases in 2021, making early detection a crucial need for digital healthcare services. SyifAI is an artificial intelligence system for classifying 23 types of skin diseases from images using the ResNet18 model, but the model retraining and deployment are still done manually without a standardized mechanism. This research designs and implements an n8n-based Machine Learning Operations (MLOps) workflow to support Continuous Training and Continuous Deployment in SyifAI, through two n8n workflows that handle user detection and scheduled retraining independently. New models are automatically evaluated against the active model based on an accuracy threshold and only deployed if their performance improves. An 80-minute test showed 17 retraining executions running precisely every 5 minutes without manual triggering, seven of which completed the full cycle, and the system was proven to handle request concurrency without disrupting the detection service, eliminating the need for manual intervention in model updates.*

Copyright © SENASIF 2026
ISSN: 2598-0076

## I. PENDAHULUAN

Penyakit kulit merupakan salah satu permasalahan kesehatan yang memberikan kontribusi signifikan terhadap beban kesehatan di Indonesia, dipengaruhi oleh iklim tropis serta rendahnya kesadaran kebersihan diri dan lingkungan [1]. Lingkungan yang lembap dan panas membuat kulit lebih rentan terhadap infeksi jamur, bakteri, virus, hingga parasit, sehingga penyakit kulit menjadi salah satu gangguan kesehatan yang umum ditemui [2], Dampaknya tidak hanya bersifat fisik, tetapi juga mencakup aspek psikososial yang dapat menurunkan kualitas hidup masyarakat [3]. Berdasarkan data kesehatan tahun 2021, penyakit kulit tercatat menempati peringkat ketujuh penyakit terbanyak dengan prevalensi 3,94% atau setara 19.513 kasus [4], sehingga deteksi dini menjadi kebutuhan penting yang masih memerlukan perhatian serius.

Sebagai respons terhadap permasalahan tersebut, transformasi digital di sektor kesehatan mulai mengadopsi *Artificial Intelligence* (AI), khususnya *machine learning* dan *deep learning*, yang terbukti mampu meningkatkan akurasi sekaligus mempercepat proses analisis citra medis dibandingkan metode manual [5][6]. Salah satu implementasinya adalah SyifAI, sistem berbasis AI yang dirancang untuk mendeteksi penyakit kulit secara dini melalui analisis citra menggunakan model ResNet18.

Permasalahan yang muncul tidak hanya terletak pada pengembangan model, tetapi juga pada aspek implementasinya di lingkungan produksi. Banyak pengembangan *machine learning* yang masih berfokus pada pembuatan model tanpa diikuti pengelolaan alur operasional yang terstandardisasi [7], sehingga proses pelatihan ulang (*retraining*) dan penerapan model (*deployment*) masih dilakukan secara manual dan meningkatkan potensi kesalahan manusia (*human error*) [8]. Ketiadaan alur *Continuous Training* (CT) dan *Continuous Deployment* (CD) yang terstandardisasi menyebabkan proses pembaruan model menjadi tidak konsisten dan sulit direplikasi, yang pada akhirnya berdampak pada rendahnya reliabilitas layanan deteksi bagi pengguna [9][10].

Untuk mengatasi permasalahan tersebut, diperlukan pendekatan yang mampu mengotomatisasi proses *machine learning* secara terstruktur. *Machine Learning Operations* (MLOps), yaitu pendekatan yang menggabungkan pengembangan, penerapan, dan pemeliharaan model secara berkelanjutan, menjadi solusi untuk memastikan sistem berjalan konsisten dan minim kesalahan [7][11]. Sebagai upaya implementasi, penelitian ini mengusulkan penggunaan n8n sebagai orkestrator alur kerja MLOps. n8n merupakan platform *low-code* yang memungkinkan pengguna membangun sistem otomasi dengan minim penulisan kode serta bersifat *self-host*, sehingga memberikan kontrol penuh terhadap data, termasuk data medis yang bersifat sensitif [12][13].

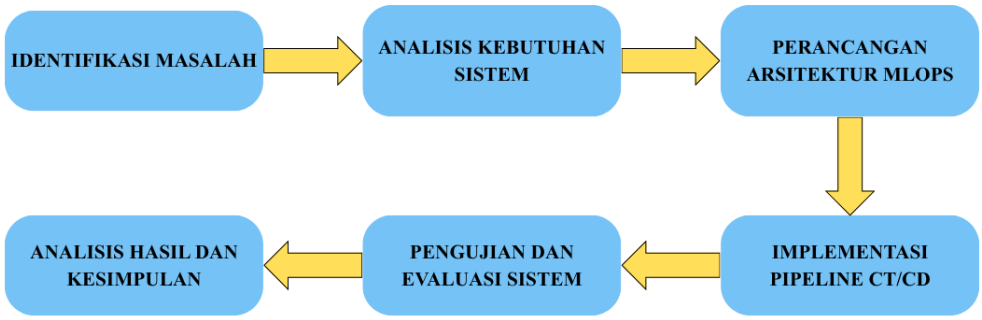
Berdasarkan permasalahan tersebut, penelitian ini bertujuan merancang dan mengimplementasikan alur kerja MLOps berbasis n8n untuk mendukung *Continuous Training* dan *Continuous Deployment* pada aplikasi SyifAI, serta mengevaluasi efektivitasnya dalam mengurangi intervensi manual.

Copyright © SENASIF 2026
ISSN: 2598-0076

## II. METODE

Penelitian ini menerapkan pendekatan eksperimen sistem untuk merancang dan mengimplementasikan alur kerja Machine Learning Operations (MLOps) yang terotomatisasi pada aplikasi SyifAI, yaitu sistem klasifikasi 23 jenis penyakit kulit berbasis model ResNet18. Sistem dibangun menggunakan n8n sebagai orkestrator alur kerja utama. Seluruh komponen layanan dan infrastruktur dioperasikan dalam lingkungan kontainer menggunakan Docker [14] untuk menjamin konsistensi lingkungan pengujian.

Penelitian ini dilaksanakan melalui empat tahapan utama, yaitu identifikasi masalah, analisis kebutuhan sistem, perancangan arsitektur *pipeline*, dan implementasi sistem, sebagaimana disajikan pada Gambar 1.




**Gambar 1.** Tahapan Penelitian

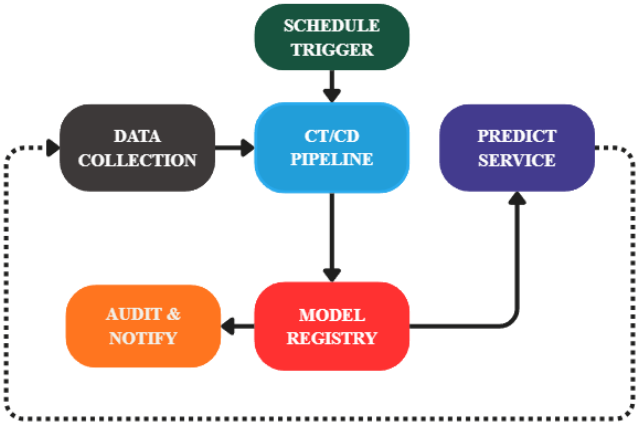
Tahap identifikasi masalah dilakukan dengan mengamati kondisi SyifAI yang hanya dilatih satu kali, dengan proses pembaruan model yang sepenuhnya bergantung pada intervensi manual dan tanpa mekanisme validasi otomatis sebelum model baru diterapkan, sehingga rentan terhadap kesalahan konfigurasi dan menurunkan konsistensi layanan deteksi. Hasil analisis kebutuhan sistem disajikan pada Tabel 1.

**Tabel 1.** Analisis Kebutuhan Sistem

| Masalah | Dampak | Kebutuhan |
|---|---|---|
| Pembaruan model bergantung penuh pada intervensi manual | Proses tidak konsisten dan sulit direplikasi | Alur kerja CT otomatis melalui *schedule trigger* |
| Model baru dipakai tanpa diketahui performanya | Model berpotensi diterapkan meski tidak lebih baik | Validasi ambang akurasi sebelum diterapkan |
| Pelatihan ulang dan deteksi berjalan bersamaan tanpa pengaturan | Hasil deteksi ke pengguna bisa tidak konsisten | Mekanisme pengaturan agar kedua proses tidak saling mengganggu |
| Model dan data tidak memiliki riwayat versi | Model lama tidak dapat ditelusuri/dikembalikan | *Model registry* untuk model aktif dan riwayat versi |
| Belum ada notifikasi atas hasil siklus pelatihan ulang | Tim pengembang tidak mengetahui status pembaruan secara langsung | Notifikasi otomatis melalui Telegram untuk tiga kondisi: diterima, ditolak, dan data belum cukup |

Copyright © SENASIF 2026
ISSN: 2598-0076

Pada tahap perancangan, arsitektur *pipeline* MLOps disusun mengacu pada lima tahap umum, yaitu *Ingestion*, *Preparation*, *Build Model*, *Deployment*, dan *Monitor* [9], yang membentuk siklus tertutup (*closed-loop*) sebagaimana ditunjukkan pada Gambar 2.




**Gambar 2.** Siklus Closed-Loop Continuous Training dan Continuous Deployment SyifAI

Siklus dimulai dari *Data Collection*, yaitu citra kulit yang diunggah pengguna, yang menjadi masukan bagi *pipeline* CT/CD yang dijalankan secara berkala melalui *schedule trigger*. Model hasil pelatihan yang lolos validasi ambang akurasi disimpan pada *Model Registry* sebagai model aktif, yang selanjutnya digunakan oleh *Predict Service* untuk melayani permintaan deteksi pengguna, sementara setiap siklus pelatihan dicatat pada tahap *Audit & Notify* sebagai jejak audit. Data hasil interaksi pengguna terus bertambah dan menjadi masukan bagi siklus retraining berikutnya, sehingga membentuk alur tertutup yang berkelanjutan.

Untuk mewujudkan siklus tersebut, sistem SyifAI dibangun menggunakan dua alur kerja n8n yang saling terhubung ke *backend* FastAPI yang sama. Alur kerja pertama, yaitu Workflow Deteksi Penyakit Kulit, ditunjukkan pada Gambar 3.

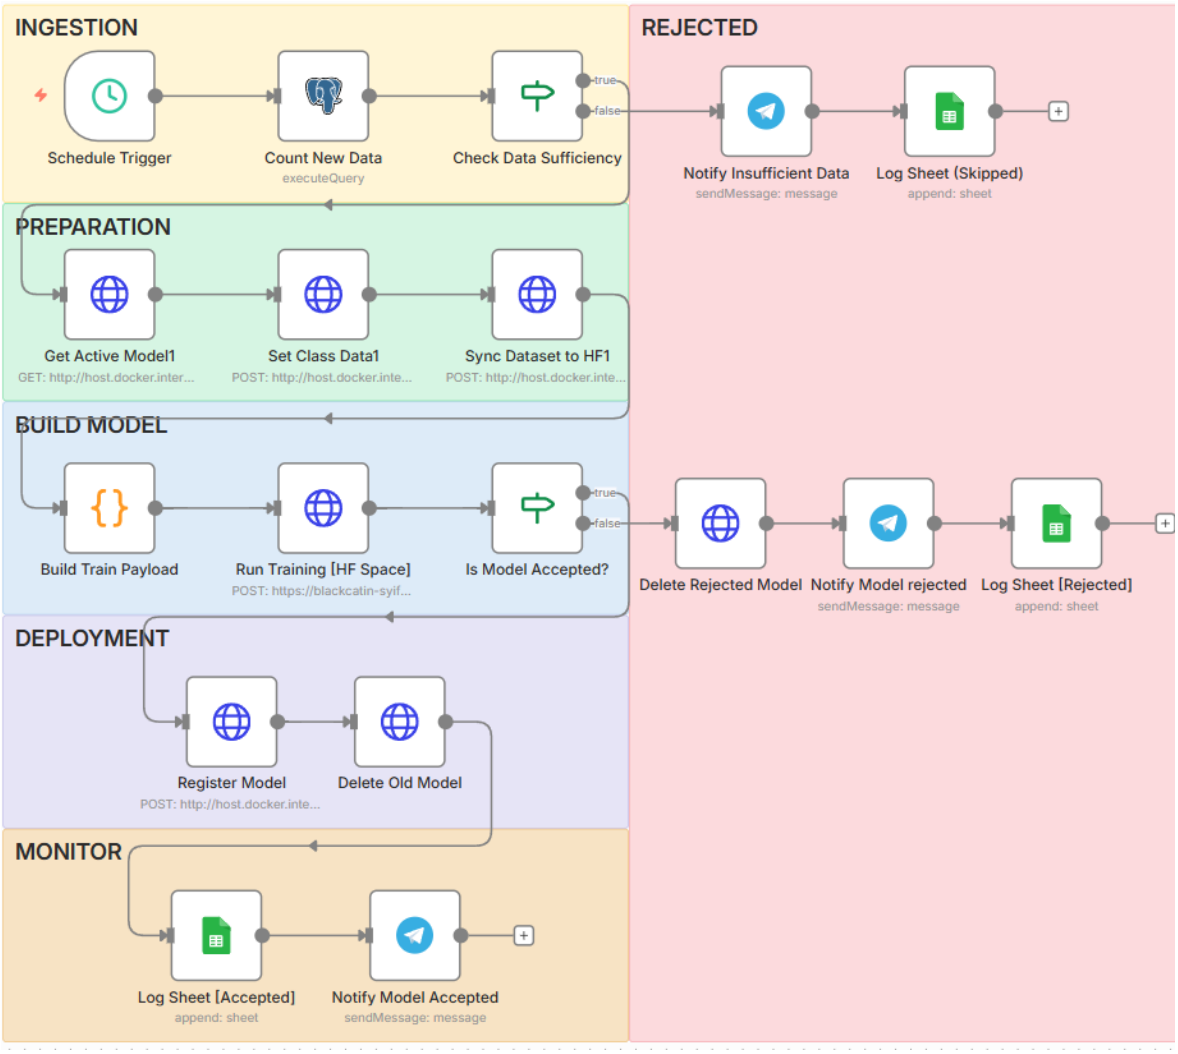



**Gambar 3.** Workflow Deteksi Penyakit Kulit

Alur kerja ini menjadi titik awal siklus karena bertugas melayani permintaan deteksi dari pengguna, dan bersifat independen dari siklus pelatihan ulang. Sistem menerima citra kulit yang diunggah pengguna melalui *webhook*, kemudian meneruskannya ke layanan deteksi pada *backend* FastAPI untuk diklasifikasi. Guna mengantisipasi lonjakan trafik dan mencegah kegagalan sistem akibat banyaknya permintaan yang masuk secara bersamaan, backend FastAPI dilengkapi dengan mekanisme antrean *request* (*request queue*) yang mengatur urutan pemrosesan data secara sinkron sebelum hasil klasifikasi dikirimkan kembali kepada pengguna. Setiap citra yang masuk melalui alur kerja ini berpotensi disimpan sebagai data baru yang kelak digunakan pada siklus pelatihan ulang berikutnya.

Copyright © SENASIF 2026
ISSN: 2598-0076

Alur kerja kedua, yaitu Workflow Retraining dan Deployment, dijalankan secara terjadwal dan terdiri dari lima tahap berurutan sebagaimana ditunjukkan pada Gambar 4.




**Gambar 4**. Workflow Retraining dan Deployment

Alur kerja sistem otomasi *Continuous Training* dan *Continuous Deployment* (CT/CD) ini dirancang melalui lima tahapan sistematis. Tahap pertama yaitu *Ingestion*, di mana sistem memantau dan menghitung jumlah data baru secara berkala melalui pemicu waktu, lalu memeriksa kecukupannya terhadap ambang batas minimum; jika data belum mencukupi, sistem mengirimkan notifikasi dan menghentikan siklus sementara. Tahap kedua yaitu *Preparation*, di mana sistem mengambil versi model aktif sebagai acuan, menyusun data baru ke dalam struktur per kelas, dan menyinkronkannya ke *Hugging Face Dataset*. Tahap ketiga yaitu *Build Model*, yang mengunduh model aktif dan data terbaru untuk pelatihan ulang dengan menyertakan 230 citra sampel data lama yang diambil secara merata sebanyak 10 citra untuk masing-masing dari 23 kelas penyakit kulit menggunakan teknik *stratified sampling* (pengambilan sampel berstrata) guna mencegah *catastrophic forgetting* (kondisi di mana model mengalami lupa pada pola pengetahuan lama saat mempelajari data baru), sementara metrik pelatihan dicatat otomatis oleh *MLflow*. Tahap keempat yaitu *Deployment*, di mana model dievaluasi terhadap ambang batas akurasi untuk kemudian

Copyright © SENASIF 2026
ISSN: 2598-0076

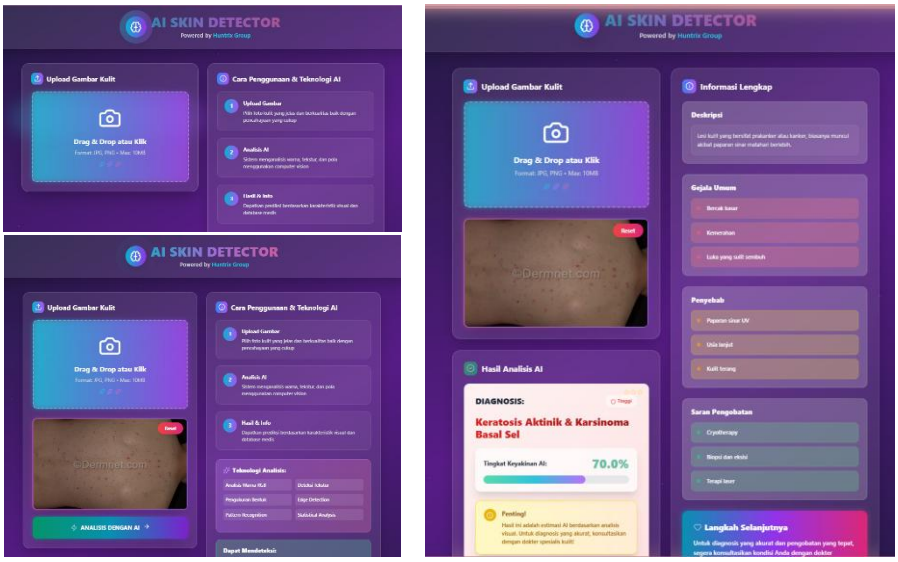
didaftarkan sebagai model aktif baru jika lolos, atau mempertahankan model lama jika gagal. Tahap kelima yaitu *Monitor*, di mana hasil akhir siklus dicatat sebagai *audit log* ke dalam Google Sheets dan notifikasi dikirimkan kepada tim pengembang melalui Telegram.

FastAPI dirancang dengan mekanisme antrean permintaan dan penguncian sementara pada model aktif, agar permintaan deteksi dan pelatihan ulang tidak saling mengganggu saat berjalan bersamaan. Implementasi diuji pada lingkungan lokal (*localhost*) menggunakan orkestrator n8n, kontainer Docker, serta layanan backend FastAPI.

## III. HASIL DAN PEMBAHASAN

### Implementasi Layanan Deteksi Penyakit Kulit

Alur kerja Workflow Deteksi Penyakit Kulit yang telah dirancang pada Gambar 5 diimplementasikan menjadi layanan yang dapat diakses langsung oleh pengguna melalui antarmuka web, sebagaimana ditunjukkan pada Gambar 5.




**Gambar 5.** Tampilan Antarmuka Website Deteksi Penyakit Kulit SyifAI

Pengguna mengunggah citra kulit melalui antarmuka tersebut, lalu sistem mengirimkan hasil berupa diagnosis, tingkat keyakinan, serta informasi pendukung seperti gejala dan saran penanganan. Citra yang masuk lewat layanan ini nantinya bisa dipakai sebagai data baru untuk siklus retraining berikutnya, sesuai dengan siklus *closed-loop* pada Gambar 2.

### Pengujian Siklus Retraining Otomatis

Pengujian dilakukan dengan mengaktifkan *schedule trigger* (pemicu jadwal) pada interval 5 menit, tanpa satu pun pemicuan manual dari peneliti. Sebelum pengujian dimulai, model aktif yang digunakan (model_v1) memiliki akurasi 60,74. Selama 80 menit pengamatan, tercatat 17 kali eksekusi *workflow Retraining* dan *Deployment*, sebagaimana dirangkum pada Tabel 2.

Copyright © SENASIF 2026
ISSN: 2598-0076

**Tabel 2.** Hasil Pengujian Siklus Retraining Otomatis via Schedule Trigger

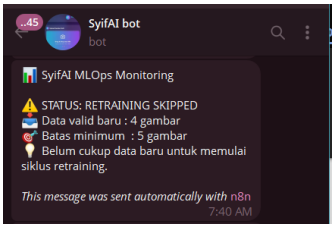
| No | Waktu | Versi Model | Data Baru | Akurasi | Baseline | Keputusan Sistem |
|---|---|---|---|---|---|---|
| 1 | 06:55:27 | model_v2 | 5 | 85,11% | 60,74% | Diterima |
| 2 | 07:10:27 | model_v3 | 5 | 89,13% | 85,11% | Diterima |
| 3 | 07:20:27 | model_v4 | 5 | 78,26% | 89,13% | Ditolak |
| 4 | 07:30:27 | model_v4a | 5 | 95,74% | 89,13% | Diterima |
| 5 | 07:45:27 | model_v5 | 5 | 80,43% | 95,74% | Ditolak |
| 6 | 07:55:27 | model_v5a | 5 | 93,62% | 95,74% | Ditolak |
| 7 | 08:05:27 | model_v5b | 5 | 86,96% | 95,74% | Ditolak |

Berdasarkan hasil pengujian sistem *Continuous Training* dan *Continuous Deployment* (CT/CD) yang dirangkum pada Tabel 2, pengujian dilakukan selama 80 menit dengan total 17 kali eksekusi otomatis. Dari total tersebut, terdapat 10 siklus yang dilewati secara otomatis karena jumlah data baru belum mencapai batas minimum 5 sampel (dengan kekurangan bervariasi antara 1 hingga 5 sampel). Sementara itu, 7 siklus lainnya berhasil memproses pelatihan ulang. Berdasarkan tabel tersebut, pengujian menunjukkan bahwa mekanisme gerbang validasi (*validation gate*) pada *pipeline* MLOps berfungsi dengan sangat baik. Sebagai contoh, model_v4 (akurasi 78,26% terhadap *baseline* 89,13%), model_v5 (akurasi 80,43% terhadap *baseline* 95,74%), serta model_v5a dan model_v5b secara otomatis ditolak karena tidak melampaui performa model sebelumnya. Penolakan ini membuktikan bahwa sistem mampu mencegah penurunan performa model masuk ke lingkungan produksi, sehingga stabilitas dan kualitas model tetap terjaga secara konsisten.

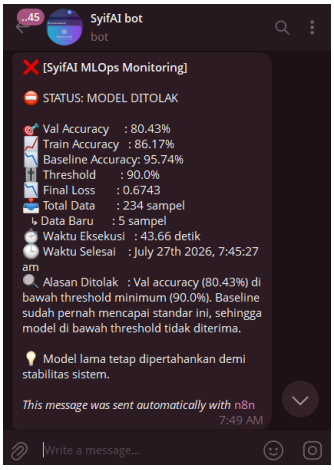
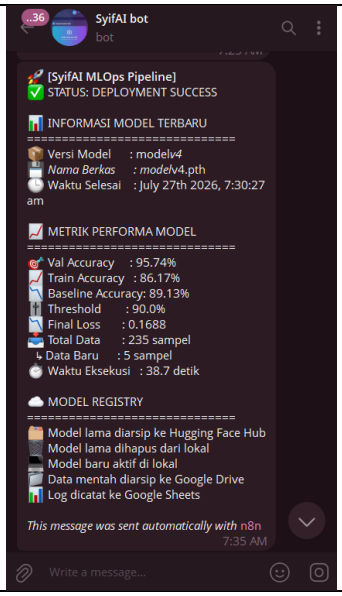
**Notifikasi pada Tiga Skenario Keputusan**

Setiap keputusan yang diambil sistem disertai notifikasi otomatis melalui Telegram, mencakup tiga skenario: data belum cukup, model ditolak, dan model diterima, sebagaimana ditampilkan pada Tabel 3.

**Tabel 3.** Notifikasi Otomatis pada Tiga Skenario Keputusan

| Skenario | Notifikasi Telegram | Isi Notifikasi | Keterangan |
|---|---|---|---|
| Data Belum Cukup |  | ⚠️ RETRAINING SKIPPED.<br>📥 Data valid baru: 4 gambar.<br>🎯 Batas minimum: 5 gambar<br>💡 Belum cukup data baru untuk memulai siklus retraining. | Sistem menghentikan siklus karena jumlah data baru belum mencapai batas minimum. |

Copyright © SENASIF 2026
ISSN: 2598-0076

| Skenario | Notifikasi Telegram | Isi Notifikasi | Keterangan |
|---|---|---|---|
| Model Ditolak |  | ⛔ MODEL DITOLAK<br>🎯 Val Accuracy : 80.43%<br>📉 Baseline Accuracy: 95.74%<br>🎚️ Threshold : 90.0%<br>🔍 Alasan Ditolak : Val accuracy (80.43%) di bawah threshold minimum (90.0%). Baseline sudah pernah mencapai standar ini, sehingga model di bawah threshold tidak diterima. | Sistem membandingkan akurasi validasi model baru terhadap model aktif (*baseline*) dan ambang batas, lalu mempertahankan model lama karena tidak ada peningkatan. |
| Model Diterima |  | ☑DEPLOYMENT SUCCESS.<br>📦 Versi Model : modelv4<br>🎯 Val Accuracy : 95.74%<br>📉 Baseline Accuracy: 89.13%<br>🎚️ Threshold : 90.0% | Sistem mengarsipkan model lama ke HuggingFace Hub, mengaktifkan model baru, mengarsipkan data mentah ke Google Drive, dan mencatat log ke Google Sheets. |

Ketiga notifikasi ini membuktikan bahwa proses yang biasanya dilakukan manual memeriksa kecukupan data, membandingkan skor akurasi, memutuskan status *deployment* sepenuhnya diambil alih oleh alur kerja otomatis, dengan hasil keputusan yang langsung diketahui developer tanpa perlu membuka server.

**Penanganan Konkurensi Antar Workflow**

Selain memastikan sistem berjalan secara konsisten, peralihan dari proses manual ke alur kerja otomatis juga menghilangkan hambatan operasional dalam pembaruan model. Pengujian pada bagian ini berfokus pada konkurensi, yaitu kemampuan sistem menjalankan beberapa workflow secara bersamaan tanpa saling mengganggu. Untuk mengujinya, dilakukan pengamatan terhadap riwayat eksekusi workflow Deteksi Penyakit Kulit dan workflow Retraining dan Deployment pada n8n, sebagaimana ditunjukkan pada Gambar 6.

Copyright © SENASIF 2026
ISSN: 2598-0076

| Workflow | Status | Started | Run Time | Exec. ID |
|---|---|---|---|---|
| SyifAI - Predict Webhook | Success | Jul 27, 07:15:47 | 2.787s | 401 |
| SyifAI - Batch MLOps Retraining | Success | Jul 27, 07:15:27 | 5.369s | 400 |
| SyifAI - Predict Webhook | Success | Jul 27, 07:11:52 | 1.95s | 399 |
| SyifAI - Batch MLOps Retraining | Success | Jul 27, 07:10:27 | 3m 29.284s | 398 |
| SyifAI - Predict Webhook | Success | Jul 27, 07:09:37 | 2.023s | 397 |

**Gambar 6.** Riwayat Eksekusi Kedua Workflow pada n8n

Pada Gambar 6, *workflow Retraining* dan *Deployment* yang mulai berjalan pukul 07:10:27 baru selesai pada 07:13:56 (durasi 3 menit 29 detik). Di tengah rentang waktu tersebut, tepatnya pukul 07:11:52, permintaan dari *workflow* Deteksi Penyakit Kulit tetap berhasil diproses (*status: Success*). Ini menunjukkan bahwa kedua *workflow* dapat berjalan bersamaan secara nyata, bukan hanya berdekatan waktu mulainya, sehingga membuktikan penanganan konkurensi (*concurrency*) bekerja dengan baik.

**Pencatatan Riwayat Model Melalui Mlflow**

Setiap siklus pelatihan juga dicatat di MLflow, seperti pada Gambar 7. Riwayat setiap versi model beserta parameter pelatihannya dapat ditelusuri kembali kapan pun dibutuhkan. Kemampuan ini menunjukkan aspek traceability, yaitu kemampuan sistem menyimpan dan melacak riwayat eksperimen sehingga dapat diverifikasi kembali sewaktu-waktu.




**Gambar 7.** Dashboard Pelacakan Eksperimen pada MLflow

Copyright © SENASIF 2026
ISSN: 2598-0076

Dashboard tersebut menampilkan metrik akurasi dan *loss* dari setiap percobaan pelatihan secara berdampingan, baik pada data latih maupun data validasi. Dengan tampilan ini, performa satu percobaan dapat langsung dibandingkan dengan percobaan lainnya tanpa perlu membuka catatan satu per satu secara manual, sehingga setiap keputusan sistem dapat ditelusuri kembali datanya kapan pun dibutuhkan untuk keperluan evaluasi atau audit. Melalui visualisasi tersebut, riwayat dari setiap versi model mulai dari model_v2 hingga model_v5b terlihat dengan jelas beserta naik-turun performanya pada setiap siklus pelatihan otomatis.

## IV. SIMPULAN

Penelitian ini berhasil membangun alur kerja MLOps berbasis n8n yang mampu menjalankan proses pelatihan ulang dan penerapan model SyifAI secara otomatis sesuai jadwal, tanpa campur tangan manual. Sistem terbukti mandiri dalam memeriksa data baru, melatih ulang model, membandingkan performa, hingga memutuskan kelayakan model baru. Setiap keputusan selalu disertai notifikasi langsung kepada pengembang, dan sistem tetap andal melayani permintaan deteksi pengguna di latar belakang sementara pelatihan berjalan. Seluruh riwayat percobaan juga tercatat rapi untuk keperluan audit. Kendati demikian, penelitian ini masih berskala prototipe dengan data terbatas, sehingga belum menggambarkan performa pada skala industri yang lebih besar. Pengujian lanjutan dengan volume data yang lebih besar dan periode lebih panjang sangat diperlukan ke depan untuk memastikan konsistensi dan keandalan sistem dalam kondisi penggunaan nyata.

## DAFTAR RUJUKAN


[1] L. Triyono, A. N. aziz Thohari, I. Hestiningsih, and A. Yobioktabera, “KLASIFIKASI PENYAKIT KULIT MENGGUNAKAN METODECONVOLUTIONAL NEURAL NETWORK,” in *Penelitian dan Pengabdian Masyarakat*, POLINES, 2022, pp. 37–44. [Online]. Available: https://jurnal.polines.ac.id/index.php/Sentrikom/article/view/3338

[2] R. Alfadli and S. Khairunisa, “Prevalensi Penyakit Kulit Infeksi dan Non-infeksi di Poliklinik Kulit dan Kelamin RSUD Jagakarsa Periode Februari 2023 - Januari 2024 Prevalence of Infectious and Non-infectious Skin Diseases in the Dermatology and Venereology Outpatient Department at Jagakarsa Regional Hospital between February 2023 - January 2024,” vol. 30, no. 3, pp. 151–156, 2024.

[3] S. Wulan, V. Oktia, C. Puri, and D. Syavani, “GANGGUAN PENYAKIT KULIT DAN KUALITAS HIDUP MASYARAKAT TELUK SEPANG KOTA BENGKULU : ANALISIS DERMATOLOGY LIFE,” vol. 2, no. 2, pp. 51–60, 2025, doi: https://doi.org/10.70248/jp.v2i2.3487.

[4] M. Nanda, N. I. Nasution, R. Pohan, M. A. Fattahillah, and N. Lestari, “HUBUNGAN


Copyright © SENASIF 2026
ISSN: 2598-0076

PERSONAL HYGIENE DAN KUALITAS AIR DENGAN KEJADIAN PENYAKIT KULIT DI DESA DURIN JANGAK MEDAN TUNTUNGAN," vol. 11, no. 7, pp. 1378–1385, 2024, doi: https://doi.org/10.33024/jikk.v11i7.16064.

[5] I. Zaenuddin and A. B. Riyan, "Perkembangan Kecerdasan Buatan (AI) Dan Dampaknya Pada Dunia Teknologi," vol. 2, no. 2, pp. 128–153, 2024, doi: https://doi.org/10.55903/jitu.v2i2.240.

[6] F. Prasetya and Edward, "Diagnosis Penyakit Menggunakan Artificial Intelligence (AI): Konsep, Bukti Ilmiah, dan Implikasi Klinis," *J. Sains dan Kesehat.*, vol. 6, no. 1, pp. 98–107, 2025, doi: https://doi.org/10.30872/jsk.v6i1.976.

[7] D. Kreuzberger, N. Kuhl, and S. Hirschl, "Machine Learning Operations (MLOps): Overview, Definition, and Architecture," *IEEE Access*, vol. 11, pp. 31866–31879, 2023, doi: 10.1109/ACCESS.2023.3262138.

[8] A. Balasubramanian, "End-to-end model lifecycle management : An MLOPS framework for drift detection , root cause analysis , and continuous retraining," *Int. J. Multidiscip. Res. Growth Eval.*, vol. 1, no. 1, pp. 92–102, 2020, doi: https://doi.org/10.54660/.IJMRGE.2020.1.1-92-102.

[9] R. Subramanya, S. Sierla, and V. Vyatkin, "From DevOps to MLOps: Overview and Application to Electricity Market Forecasting," *Appl. Sci.*, 2022, doi: https://doi.org/10.3390/app12199851.

[10] S. Joshi, "A Review of Generative AI and DevOps Pipelines : CI / CD , Agentic Automation , MLOps Integration , and Large Language Models," *Int. J. Innov. Res. Comput. Sci. Technol.*, vol. 13, no. 4, pp. 1–14, 2025, doi: https://doi.org/10.55524/ijircst.2025.13.4.1.

[11] D. O. Hanchuk and S. O. Semerikov, "Implementing MLOps practices for effective machine learning model deployment: A meta synthesis," *CEUR Workshop Proc.*, vol. 3918, pp. 329–337, 2025, doi: https://doi.org/10.55056/ceur-ws.org/Vol-3918/paper404.pdf.

[12] I. Nakavisute and T. Sincharoonsak, "OPTIMIZING THE AUTOMATION PROCESS WITH N8N," *TPM – Testing, Psychom. Methodol. Appl. Psychol.*, vol. 32, no. Doyce 12, pp. 1786–1793, 2025, [Online]. Available: https://tpmap.org/submission/index.php/tpm/article/view/3011

[13] N. Herk, "The Ultimate n8n Starter Kit (2025).pdf," 2025, *AI Automation Society*. [Online]. Available: https://hubinterior.com/trail.pdf

[14] B. L. Ortiz *et al.*, "Data Preprocessing Techniques for AI and Machine Learning Readiness : Scoping Review of Wearable Sensor Data in Cancer Corresponding Author :," *JMIR MHEALTH UNHEALTH*, vol. 12, pp. 1–18, 2024, doi: 10.2196/59587.

[15] C. Arnold, "The role of hyperparameters in machine learning models and how to tune them," *Polit. Sci. Res. Methods*, vol. 12, pp. 841–848, 2024, doi: 10.1017/psrm.2023.61.

Copyright © SENASIF 2026

ISSN: 2598-0076