

Sistem Klasifikasi Suhu dan Kelembapan untuk Deteksi Dini Risiko Penggumpalan pada Material Granular Higroskopis Menggunakan Metode K-Nearest Neighbors

Muhammad Rakha¹, Berlian Al Kindhi^{*2}, Fauzi Imaduddin Adhim³

^{1,2,3} Departemen Teknik Elektro otomasi, Fakultas Vokasi, Institut Teknologi Sepuluh Nopember, Surabaya
Email: ¹2040211085@student.its.ac.id, ²berlian@its.ac.id, ³fauzi.imaduddin@its.ac.id

*Penulis Koresponden

Abstrak

Penggumpalan (caking) adalah masalah umum yang terjadi pada penyimpanan material granular higroskopis, yang dipengaruhi oleh kondisi lingkungan yang tidak terkontrol, khususnya suhu dan kelembapan yang melebihi batas yang ditetapkan. Penggumpalan dapat menyebabkan penurunan kualitas produk dan menghambat proses distribusi serta aplikasi di lapangan. Penelitian ini bertujuan untuk merancang sistem klasifikasi berbasis algoritma *K-Nearest Neighbors* (KNN) guna mengidentifikasi kondisi lingkungan penyimpanan berdasarkan data suhu dan kelembapan yang terukur. Data suhu dan kelembapan dikumpulkan secara berkala menggunakan sensor, disimpan dalam basis data, dan ditampilkan pada antarmuka pemantauan berbasis web. Sistem ini mengklasifikasikan kondisi penyimpanan ke dalam tiga kategori yaitu Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Model dikembangkan dengan parameter $K=5$ dan diuji menggunakan data aktual. Hasil pengujian menunjukkan akurasi klasifikasi sebesar 99,14%, yang menunjukkan kinerja yang sangat baik. Sistem ini dirancang untuk memberikan peringatan dini apabila terjadi penyimpangan dari standar lingkungan yang telah ditetapkan, yang dapat mendukung pengambilan keputusan dalam pengendalian mutu penyimpanan material granular di industri.

Kata kunci: penggumpalan, klasifikasi, suhu, kelembapan, K-Nearest Neighbors

Abstract

Caking is a common problem that occurs in the storage of hygroscopic granular materials due to uncontrolled environmental conditions, particularly temperature and humidity that exceed the established limits. Caking can lead to a decrease in product quality and hinder distribution and application processes in the field. This study aims to design a classification system based on the K-Nearest Neighbors (KNN) algorithm to identify the storage environment conditions based on temperature and humidity data. Data is collected periodically through sensors, stored in a database, and displayed through a web-based monitoring interface. The system classifies storage conditions into three categories: Non-Caking, Potential Caking, and Caking. The model is developed with $K=5$ and tested using actual data. The test results show a classification accuracy of 99.14%, indicating excellent performance. This system is designed to provide early warnings when deviations from the established environmental standards occur, thereby supporting decision-making in controlling the quality of granular material storage in the industry.

Keywords: caking, classification, temperature, humidity, K-Nearest Neighbors

I. PENDAHULUAN

Caking atau penggumpalan merupakan salah satu permasalahan umum yang sering terjadi dalam penyimpanan material berbentuk granular yang bersifat higroskopis[1]. Kondisi ini terjadi ketika partikel-partikel saling menempel akibat suhu dan kelembapan lingkungan yang tidak terkontrol, sehingga membentuk massa padat yang menyulitkan dalam proses penanganan dan distribusi. Salah satu kasus yang paling sering dijumpai adalah pada pupuk urea, di mana kualitas fisiknya sangat dipengaruhi oleh suhu dan kelembapan selama masa penyimpanan[2].

Suhu dan kelembapan menjadi dua parameter penting yang sangat menentukan kestabilan material selama disimpan. Suhu yang terlalu tinggi dapat mempercepat proses degradasi atau reaksi kimia, sedangkan kelembapan yang tinggi memungkinkan partikel menyerap uap air dan memicu terjadinya penggumpalan [3]. Oleh karena itu, diperlukan pemantauan suhu dan kelembapan secara berkala untuk mengidentifikasi kecenderungan perubahan fisik yang tidak diinginkan pada material.

Sejumlah penelitian terdahulu telah menunjukkan urgensi pemantauan suhu dan kelembapan pada berbagai konteks penyimpanan. Aulia dkk, meneliti pengaruh suhu dan kelembapan terhadap kualitas bahan baku di gudang industri pupuk, dengan hasil yang menegaskan bahwa suhu optimal di bawah 32°C penting

untuk menjaga mutu[4]. Akbar dan Sugeng mengembangkan sistem pemantauan berbasis Internet of Things (IoT) di ruang penyimpanan obat menggunakan mikrokontroler dan aplikasi *Blynk* untuk pemantauan jarak jauh[5]. Grahito memadukan teknologi IoT dengan algoritma *K-Nearest Neighbors* (KNN) dalam sistem kontrol otomatis kipas berbasis suhu dan kelembapan gudang[3]. Ramadhona et al. mengusulkan sistem monitoring suhu dan kelembapan di peternakan kelinci menggunakan sensor serial dan komunikasi RS485[6]. Sementara itu, Syarifuddin menerapkan metode KNN untuk klasifikasi kualitas air berbasis parameter lingkungan seperti suhu dan pH[7].

Meskipun berbagai pendekatan telah dikembangkan dalam konteks pemantauan lingkungan, studi mengenai penerapan sistem klasifikasi otomatis berbasis KNN untuk mendeteksi kecenderungan caking secara khusus pada material higroskopis seperti pupuk urea masih sangat terbatas.

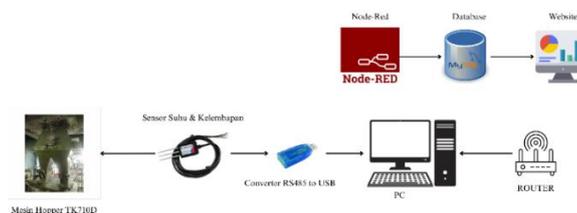
Saat ini, sebagian besar proses klasifikasi kondisi penyimpanan masih dilakukan secara manual dan bersifat reaktif, sehingga tidak mampu memberikan respons cepat terhadap perubahan lingkungan yang berdampak pada mutu produk. Hal ini menunjukkan perlunya sistem klasifikasi otomatis berbasis data yang mampu mengidentifikasi kondisi secara *real-time* dan memberikan peringatan dini terhadap potensi penurunan mutu produk [8].

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi berbasis algoritma *K-Nearest Neighbors* (KNN) yang dapat mendeteksi kecenderungan caking pada pupuk urea berdasarkan data suhu dan kelembapan yang diperoleh secara *real-time* dari sensor. Sistem ini akan mengelompokkan data kondisi lingkungan ke dalam tiga kategori yaitu Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal.

II. METODE PENELITIAN

2.1. Arsitektur Sistem

Sistem yang dikembangkan dalam penelitian ini terdiri dari tiga komponen utama, yaitu unit akuisisi data, unit pemrosesan, dan unit antarmuka. Sensor suhu dan kelembapan dipasang pada area permukaan material dan dihubungkan ke komputer menggunakan konverter RS485 to USB. Data yang dikirim secara berkala diproses oleh perangkat lunak Node-RED dan disimpan ke dalam basis data MySQL. Hasil klasifikasi kemudian ditampilkan melalui antarmuka website monitoring yang dapat diakses melalui jaringan lokal maupun internet. Alur sistem secara umum dapat dilihat pada Gambar 1.



Gambar 1. Arsitektur Sistem Penelitian
Sumber: Dokumen Pribadi

2.2. Akuisisi dan Pra-Pemrosesan Data

Data suhu dan kelembapan dikumpulkan dari sensor *Soil Temperature and Humidity Transmitter* yang dipasang pada permukaan material selama proses penyimpanan. Sensor dihubungkan ke komputer melalui konverter RS485 ke USB, kemudian data dikirim secara berkala ke platform Node-RED untuk diproses dan disimpan dalam database MySQL. Setiap entri data mencakup nilai suhu, kelembapan, dan *timestamp*.

Sebelum digunakan dalam proses klasifikasi, data melewati tahapan pra-pemrosesan. Tahap awal meliputi penghapusan data duplikat dan pengecekan nilai kosong atau tidak valid[9]. Duplikasi diidentifikasi berdasarkan kombinasi nilai suhu, kelembapan, dan timestamp yang identik, dan dihapus secara otomatis. Langkah ini penting dilakukan karena algoritma KNN bersifat *instance-based* dan sensitif terhadap data yang redundan, yang dapat memengaruhi hasil klasifikasi[10].

Setelah pembersihan data, dilakukan normalisasi menggunakan metode *Min-Max Scaling* agar seluruh fitur berada pada skala yang seragam antara 0 hingga 1. Proses normalisasi dilakukan dengan rumus pada Persamaan[1] :

$$X_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad [1]$$

Di mana x adalah nilai asli, x_{min} dan x_{max} masing-masing adalah nilai minimum dan maksimum dari fitur tersebut, dan x_{norm} adalah nilai hasil normalisasi. Normalisasi digunakan untuk memastikan perhitungan jarak oleh KNN tetap seimbang antar fitur.

Setelah dinormalisasi, data diacak (*shuffling*) untuk mencegah bias distribusi, lalu dibagi menjadi data pelatihan dan data pengujian. Label klasifikasi ditentukan berdasarkan kombinasi nilai suhu dan kelembapan, dengan tiga kategori kelas: Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Kriteria klasifikasi didasarkan pada ambang suhu maksimum 50 °C dan kelembapan maksimum 70%. Data diklasifikasikan sebagai "Tidak Menggumpal" jika keduanya di bawah ambang batas, "Potensi Menggumpal" jika salah satu melebihi, dan "Menggumpal" jika keduanya melebihi batas tersebut.

2.3. Proses Klasifikasi

K-Nearest Neighbors (KNN) digunakan dalam penelitian ini untuk mengklasifikasikan kondisi material berdasarkan suhu dan kelembapan. KNN merupakan metode *supervised learning* yang menentukan kelas suatu data berdasarkan mayoritas kelas dari sejumlah tetangga terdekat dalam ruang fitur[11]. Jarak antar data dihitung menggunakan rumus *Euclidean Distance*:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad [2]$$

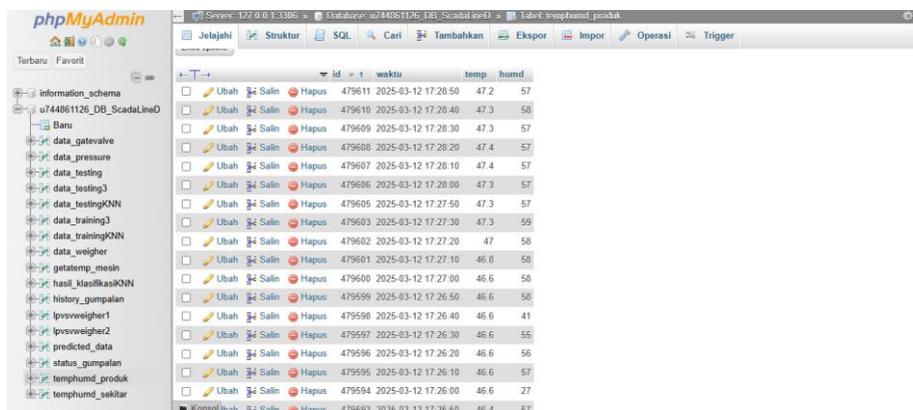
Di mana x_i dan y_i adalah nilai fitur dari data uji dan pelatihan. Setelah seluruh jarak dihitung, data uji akan diklasifikasikan berdasarkan mayoritas kelas dari K tetangga terdekat.

Proses klasifikasi bertujuan untuk menentukan status kestabilan material menjadi tiga kelas: Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Data yang telah dinormalisasi menjadi input untuk algoritma KNN. Nilai K sebagai *hyperparameter* ditentukan melalui proses *hyperparameter tuning*, dengan menguji performa model pada beberapa nilai K ganjil dalam rentang tertentu untuk memperoleh hasil yang optimal.

III. HASIL DAN PEMBAHASAN

3.1. Penarikan dan Penyimpanan Data Sensor

Setelah data dari sensor *Temperature and Humidity Transmitter* diproses dan dikonversi menjadi nilai desimal melalui Node-RED, data tersebut dikirimkan ke database untuk disimpan dan digunakan dalam proses klasifikasi. Pengiriman data dilakukan secara otomatis melalui node database yang terpasang pada alur Node-RED, memungkinkan integrasi langsung antara sistem akuisisi data dan penyimpanan. Data yang dikirim mencakup nilai suhu (*temp*) dan kelembapan (*humd*) yang telah dikonversi serta dilengkapi dengan timestamp sebagai penanda waktu pengukuran.



	id	waktu	temp	humd
<input type="checkbox"/>	479611	2025-03-12 17:28:50	47.2	57
<input type="checkbox"/>	479610	2025-03-12 17:28:40	47.3	56
<input type="checkbox"/>	479609	2025-03-12 17:28:30	47.3	57
<input type="checkbox"/>	479608	2025-03-12 17:28:20	47.4	57
<input type="checkbox"/>	479607	2025-03-12 17:28:10	47.4	57
<input type="checkbox"/>	479606	2025-03-12 17:28:00	47.3	57
<input type="checkbox"/>	479605	2025-03-12 17:27:50	47.3	57
<input type="checkbox"/>	479603	2025-03-12 17:27:30	47.3	56
<input type="checkbox"/>	479602	2025-03-12 17:27:20	47	58
<input type="checkbox"/>	479601	2025-03-12 17:27:10	46.8	58
<input type="checkbox"/>	479600	2025-03-12 17:27:00	46.6	58
<input type="checkbox"/>	479599	2025-03-12 17:26:50	46.6	58
<input type="checkbox"/>	479598	2025-03-12 17:26:40	46.6	41
<input type="checkbox"/>	479597	2025-03-12 17:26:30	46.6	55
<input type="checkbox"/>	479596	2025-03-12 17:26:20	46.6	56
<input type="checkbox"/>	479595	2025-03-12 17:26:10	46.6	57
<input type="checkbox"/>	479594	2025-03-12 17:26:00	46.6	27
<input type="checkbox"/>	479593	2025-03-12 17:25:50	46.4	57

Gambar 2. Data Sensor yang Tersimpan Di Database
Sumber : Dokumen Pribadi

Gambar 2 menunjukkan tampilan database pada phpMyAdmin, di mana data hasil pembacaan sensor telah berhasil disimpan dalam tabel `temphumd_produk`. Terlihat bahwa setiap baris data mencakup nilai suhu (`temp`), kelembapan (`humd`), dan waktu pengukuran (`waktu`). Penyimpanan data dilakukan secara otomatis dan sistematis, sehingga setiap entri dicatat sesuai urutan waktu. Hingga tahap akhir pengujian, sistem berhasil mengumpulkan sebanyak 1.713.973 data sensor yang tersimpan secara berkelanjutan di dalam database. Jumlah data yang besar ini menunjukkan bahwa sistem mampu beroperasi dengan stabil dan konsisten dalam jangka waktu yang lama.

3.2. Hasil Pra-Pemrosesan Data

Data suhu dan kelembapan yang terkumpul kemudian diproses melalui tahap normalisasi untuk mempersiapkan data tersebut bagi proses klasifikasi. Normalisasi penting dilakukan karena setiap fitur (suhu dan kelembapan) memiliki satuan dan rentang nilai yang berbeda. Untuk menyamakan skala, digunakan metode *Min-Max Scaling*, yang mengubah nilai asli ke dalam rentang $[0, 1]$. Nilai minimum dan maksimum untuk normalisasi ini diambil dari data training, agar hasil normalisasi tidak bias terhadap data testing.

Selama tahap pra-pemrosesan, juga ditemukan adanya data redundan atau duplikat, yaitu entri dengan nilai suhu dan kelembapan yang sama secara berulang dalam interval waktu yang berdekatan. Redundansi ini dapat menyebabkan bias dan mengurangi akurasi model. Oleh karena itu, dilakukan proses data cleaning untuk menghapus duplikat tersebut. Setelah normalisasi dan pembersihan data, jumlah data yang digunakan untuk proses klasifikasi tersisa sebanyak 4.948 data unik. Data yang telah diproses ini dianggap mewakili kondisi yang sebenarnya dan siap digunakan untuk pelatihan dan pengujian model.

Tabel 1. Contoh Hasil Data yang Telah Di Normalisasi

Suhu (°C)	Kelembapan (%)	Suhu_Norm	Kelembapan_Norm
46.1	57	0.455	0.529
46.2	57	0.458	0.529
46.1	56	0.455	0.514
45.9	56	0.45	0.514
45.7	56	0.444	0.514

Tabel 1 memperlihatkan sebagian hasil dari proses normalisasi, yang mencakup beberapa data awal dan akhir. Semua nilai berada dalam rentang 0 hingga 1, yang menunjukkan bahwa proses normalisasi berjalan secara konsisten dan valid. Data yang telah dinormalisasi ini selanjutnya digunakan sebagai input utama dalam proses klasifikasi menggunakan algoritma *K-Nearest Neighbors* (K-NN). Proses klasifikasi ini akan memetakan kondisi suhu dan kelembapan ke dalam kelas yang telah ditentukan.

Tabel 2. Contoh Hasil Data yang Telah Di Klasifikasi

Suhu (°C)	Kelembapan (%)	Klasifikasi
36.5	67	Tidak Menggumpal
44.7	55	Tidak Menggumpal
52.6	49	Potensi Menggumpal
48.5	73	Potensi Menggumpal
52.4	78	Menggumpal
51.3	75	Menggumpal

Setiap data yang telah diproses kemudian diklasifikasikan ke dalam salah satu dari tiga kategori, yaitu Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Proses klasifikasi dilakukan berdasarkan kombinasi nilai suhu dan kelembapan yang telah dinormalisasi. Hasil klasifikasi yang ditampilkan dalam Tabel 2 menunjukkan bahwa sistem berhasil mengelompokkan data sesuai dengan kondisi aktual dengan sangat baik. Penghapusan data redundan yang dilakukan sebelumnya juga berkontribusi terhadap

peningkatan kestabilan dan keakuratan hasil klasifikasi, memastikan bahwa model dapat berfungsi secara optimal dalam mengidentifikasi kondisi material.

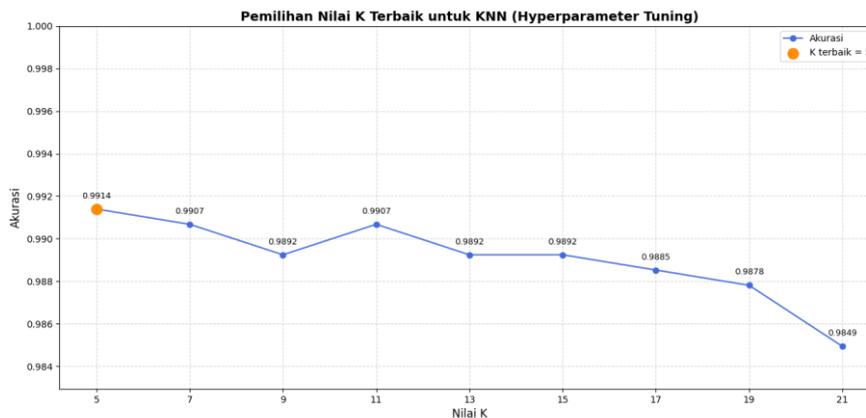
3.3. Hasil Hyperparameter Tuning Nilai K

Proses *hyperparameter tuning* dilakukan untuk menentukan nilai K terbaik dalam algoritma *K-Nearest Neighbors* (K-NN). Nilai K diuji secara bertahap untuk menemukan konfigurasi yang memberikan akurasi tertinggi dan performa klasifikasi yang paling stabil. Rentang nilai K yang diuji mencakup K = 5, 7, 9, 11, 13, 15, 17, 19, dan 21. Pengujian dilakukan dengan melatih model menggunakan data training dan mengujinya terhadap data testing. Evaluasi dilakukan menggunakan akurasi sebagai metrik utama untuk menilai performa klasifikasi terhadap tiga kelas: Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Rincian hasil akurasi untuk setiap nilai K disajikan pada Tabel 3.

Tabel 3. Hasil Akurasi Nilai K

Nilai K	5	7	9	11	15	17	19	21
Akurasi (%)	99.14	98.07	98.92	99.07	98.92	98.92	98.85	98.49

Berdasarkan Gambar 3, dapat dilihat bahwa K = 5 memberikan akurasi tertinggi sebesar 99,14%. Meskipun perbedaan akurasi antar nilai K cukup kecil, tren penurunan akurasi terlihat seiring dengan peningkatan nilai K, yang menunjukkan bahwa model menjadi lebih umum dan kurang sensitif terhadap pola lokal. Sebaliknya, nilai K yang terlalu kecil (misalnya K = 1) cenderung menyebabkan *overfitting*, di mana model terlalu terfokus pada data individu. Dengan mempertimbangkan keseimbangan antara akurasi tinggi, kestabilan klasifikasi, dan potensi *overfitting*, K = 5 dipilih sebagai nilai optimal untuk parameter K. Nilai ini kemudian digunakan sebagai parameter utama dalam sistem klasifikasi untuk seluruh proses pengujian lanjutan.

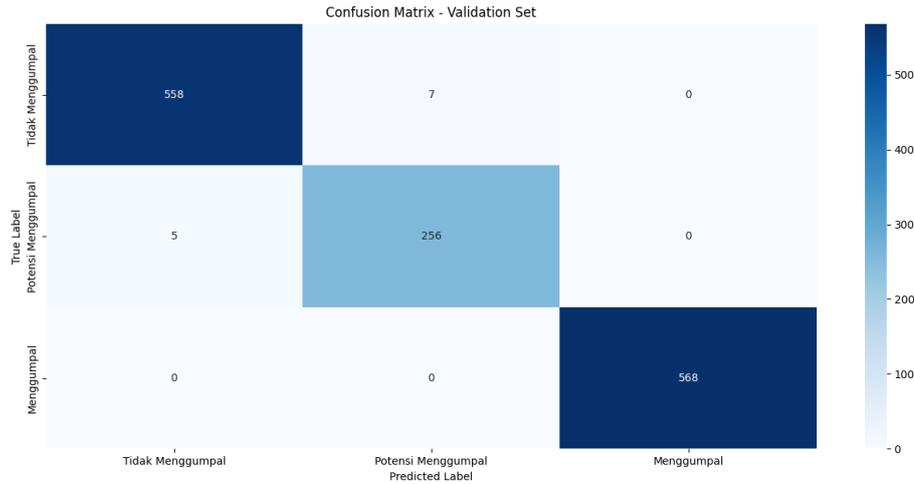


Gambar 3. Grafik Akurasi Nilai K

Sumber : Dokumen Pribadi

3.4. Evaluasi Kinerja Model

Evaluasi kinerja dilakukan untuk menilai seberapa baik sistem klasifikasi dapat memprediksi kelas kondisi penyimpanan pupuk berdasarkan suhu dan kelembapan yang terbaca oleh sensor. Model yang digunakan dalam penelitian ini adalah algoritma *K-Nearest Neighbors* (KNN) dengan nilai K = 5, hasil dari proses *hyperparameter tuning*. Evaluasi dilakukan dengan membandingkan hasil klasifikasi terhadap data testing dan label aktual. Hasil klasifikasi ini kemudian dianalisis menggunakan beberapa metrik evaluasi utama, yaitu akurasi, *precision*, *recall*, dan *F1-score*.



Gambar 4. Hasil *Confusion Matrix*
Sumber : Dokumen Pribadi

Berdasarkan confusion matrix pada Gambar 4, dilakukan perhitungan manual untuk mengukur akurasi dan masing-masing nilai precision, recall, dan F1-score. Total data validasi adalah 1394 sampel, dan jumlah klasifikasi yang benar sebanyak 1382. Perhitungan manual tiap kelas klasifikasi pada persamaan dibawah ini :

$$Precision_{TM} = \frac{TP_{TM}}{TP_{TM}+FP_{TM}} = \frac{558}{558+5} = 0,9911 \quad [3]$$

$$Recall_{TM} = \frac{TP_{TM}}{TP_{TM}+FN_{TM}} = \frac{558}{558+7} = 0,9876 \quad [4]$$

$$F1 - Score_{TM} = 2 \times \frac{Precision_{TM} \times Recall_{TM}}{Precision_{TM} + Recall_{TM}} = \frac{0,9911 \times 0,9876}{0,9911 + 0,9876} = 0,9893 \quad [5]$$

$$Precision_{PM} = \frac{TP_{PM}}{TP_{PM}+FP_{PM}} = \frac{256}{256+7} = 0,9734 \quad [6]$$

$$Recall_{PM} = \frac{TP_{PM}}{TP_{PM}+FN_{PM}} = \frac{256}{256+5} = 0,9808 \quad [7]$$

$$F1 - Score_{PM} = 2 \times \frac{Precision_{PM} \times Recall_{PM}}{Precision_{PM} + Recall_{PM}} = \frac{0,9734 \times 0,9808}{0,9734 + 0,9808} = 0,9771 \quad [8]$$

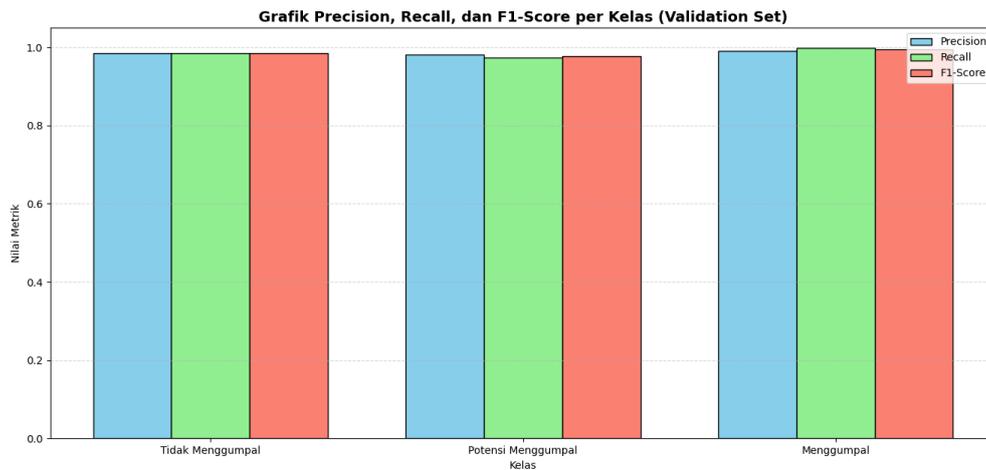
$$Precision_M = \frac{TP_M}{TP_M+FP_M} = \frac{568}{568+0} = 1,0 \quad [9]$$

$$Recall_{PM} = \frac{TP_M}{TP_M+FN_M} = \frac{568}{568+0} = 1,0 \quad [10]$$

$$F1 - Score_M = 2 \times \frac{Precision_M \times Recall_M}{Precision_M + Recall_M} = \frac{1,0 \times 1,0}{1,0 + 1,0} = 1,0 \quad [11]$$

$$Accuracy = \frac{TP_{TM} + TP_{PM} + TP_M}{Total Sample} = \frac{558 + 256 + 568}{1394} = 0,9914 \quad [12]$$

TM merupakan singkatan dari Tidak Menggumpal, PM untuk Potensi Menggumpal, dan M untuk Menggumpal, sedangkan TP (True Positive), FP (False Positive), dan FN (False Negative).



Gambar 5. Grafik Evaluasi Nilai Precision, Recall dan F1-Score
Sumber : Dokumen Pribadi

Berdasarkan hasil evaluasi model pada data validasi, diperoleh nilai Precision, Recall, dan F1-Score yang tinggi dan stabil untuk seluruh kelas: Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal. Nilai-nilai ini dihitung untuk setiap kelas secara individual guna mengetahui performa model dalam mengklasifikasikan kondisi yang berbeda. Visualisasi grafik yang ditampilkan pada Gambar 5 menunjukkan performa model terhadap masing-masing metrik evaluasi.

Untuk kelas Tidak Menggumpal, nilai *precision*, *recall*, dan *F1-score* semuanya berada di atas 0,98, yang menunjukkan bahwa model mampu mengklasifikasikan kelas ini dengan tingkat kesalahan yang sangat rendah. Pada kelas Potensi Menggumpal, meskipun recall sedikit lebih rendah dibanding precision, perbedaan ini tidak signifikan, dan performa model tetap stabil. Penurunan recall ini kemungkinan disebabkan oleh kemiripan pola fitur antara kelas ini dengan dua kelas lainnya, namun model tetap mampu mengenali karakteristik kelas ini dengan baik.

Sementara itu, untuk kelas Menggumpal, model menunjukkan performa terbaik di antara kedua kelas lainnya. Hal ini terlihat dari nilai recall tertinggi yang mencapai 0.9985, yang menandakan bahwa hampir seluruh data dengan label Menggumpal berhasil diklasifikasikan dengan benar. *Precision* pada kelas ini juga sangat tinggi, yakni 0.9911, menghasilkan nilai *F1-score* tertinggi sebesar 0.9948.

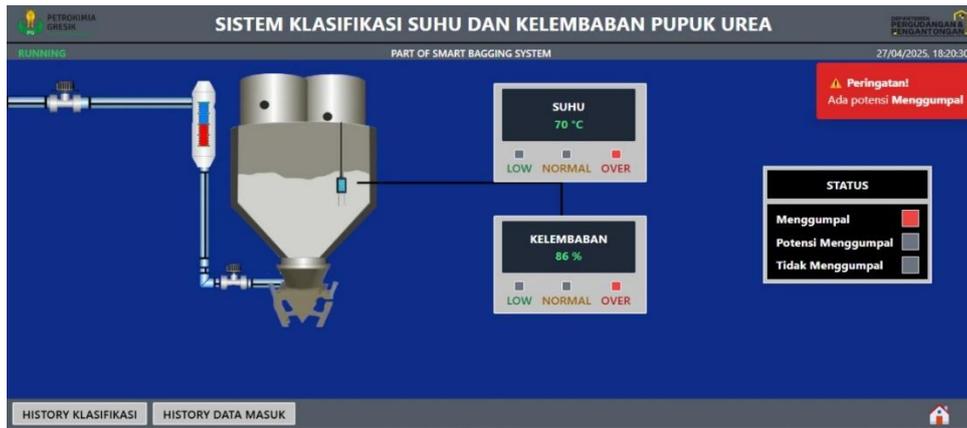
Tabel 4. Evaluasi Nilai *Precision*, *Recall* dan *F1-Score*

Kelas	Precision	Recall	F1-Score
Tidak Menggumpal	0.9911	0.9876	0.9911
Potensi Menggumpal	0.9734	0.9808	0.9771
Menggumpal	1,0	1,0	1,0

Rangkuman dari nilai evaluasi metrik untuk masing-masing kelas ditampilkan pada Tabel 4 Hasil ini menunjukkan bahwa model *K-Nearest Neighbors* (KNN) tidak hanya memiliki akurasi tinggi secara keseluruhan, tetapi juga mampu memberikan prediksi yang konsisten dan seimbang untuk setiap kategori kondisi penyimpanan pupuk.

3.5. Evaluasi Fitur Website dalam Sistem Klasifikasi

Pengujian fitur website dilakukan untuk memastikan seluruh halaman dan fungsionalitas sistem berfungsi dengan baik. Hasil pengujian menunjukkan bahwa semua halaman, mulai dari halaman utama klasifikasi data, grafik sensor, hingga riwayat klasifikasi, dapat diakses dengan lancar dan menampilkan informasi yang dibutuhkan secara akurat. Data suhu dan kelembapan ditampilkan dengan tepat pada grafik sensor, dan hasil klasifikasi tercatat dengan benar pada riwayat klasifikasi. Dengan demikian, sistem website berhasil mengolah dan menampilkan data sesuai dengan yang diharapkan.



Gambar 6. Tampilan Halaman Utama Website

Halaman utama klasifikasi dirancang untuk memudahkan pengguna memulai proses klasifikasi suhu dan kelembapan yang terhubung dengan sensor *Temperature and Humidity Transmitter*. Sebelum tombol Mulai Klasifikasi diklik, halaman ini menampilkan informasi suhu dan kelembapan beserta statusnya, yaitu LOW, NORMAL, atau OVER. Setelah tombol tersebut diklik, halaman akan menampilkan status klasifikasi yang menunjukkan apakah kondisi pupuk menggumpal, potensi menggumpal, atau tidak menggumpal. Jika statusnya menggumpal, notifikasi peringatan muncul di pojok kanan atas layar, memberi tahu pengguna tentang potensi menggumpal yang perlu diperhatikan. Gambar 6 menunjukkan tampilan halaman utama klasifikasi sebelum tombol diklik, dengan suhu dan kelembapan beserta statusnya yang sesuai.



Gambar 7. Tampilah Halaman Hasil Riwayat Klasifikasi

Pada halaman riwayat hasil klasifikasi menampilkan data yang telah diklasifikasikan menggunakan algoritma *K-Nearest Neighbors* (KNN). Di halaman ini, pengguna dapat melihat nilai suhu, kelembapan, status klasifikasi, dan waktu klasifikasi. Status yang ditampilkan adalah Menggumpal, Potensi Menggumpal, atau Tidak Menggumpal. Halaman ini memungkinkan pengguna untuk memantau riwayat klasifikasi, memudahkan mereka melacak perubahan kondisi material dari waktu ke waktu dan memastikan pemantauan yang akurat. Gambar 7 memperlihatkan tampilan halaman riwayat hasil klasifikasi, yang menampilkan data yang telah diklasifikasikan lengkap dengan waktu dan statusnya.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi berbasis algoritma *K-Nearest Neighbors* (KNN) untuk mendeteksi kondisi material granular higroskopis berdasarkan parameter suhu dan kelembapan. Sistem ini dirancang untuk mengklasifikasikan kondisi material ke dalam tiga kategori, yaitu Tidak Menggumpal, Potensi Menggumpal, dan Menggumpal, menggunakan data yang diperoleh secara real-time dari sensor suhu dan kelembapan yang terpasang pada permukaan material selama proses penyimpanan.

Melalui evaluasi performa model, sistem ini menunjukkan tingkat akurasi dan konsistensi klasifikasi yang sangat tinggi, dengan nilai *F1-score* lebih dari 98% untuk seluruh kelas. Hasil ini menunjukkan bahwa sistem mampu secara andal mengenali pola perubahan suhu dan kelembapan untuk menentukan status kestabilan material, serta dapat membedakan kondisi dengan akurasi yang baik.

Selain itu, sistem juga berhasil diimplementasikan dalam bentuk prototipe berbasis web, yang memungkinkan tampilan hasil klasifikasi dan notifikasi secara visual dan real-time. Fitur ini meningkatkan kemampuan untuk melakukan pemantauan langsung terhadap kondisi material, menjadikannya alat yang sangat berguna dalam industri penyimpanan material, terutama dalam memantau kualitas penyimpanan pupuk urea.

Berdasarkan hasil yang dicapai, sistem ini dinilai layak untuk diterapkan dalam konteks industri penyimpanan material sebagai solusi deteksi dini terhadap risiko penggumpalan. Untuk pengembangan selanjutnya, sistem ini dapat ditingkatkan dengan menambahkan variabel lingkungan lain, seperti tekanan dan sirkulasi udara, yang dapat memperkaya analisis kondisi material. Selain itu, eksplorasi algoritma klasifikasi alternatif, seperti *Random Forest* dan *Support Vector Machine (SVM)*, juga dapat dilakukan untuk meningkatkan skalabilitas, akurasi, dan ketahanan sistem terhadap data dengan kompleksitas yang lebih tinggi.

REFERENSI

- [1] A. Nugroho, “Analisis Pengaruh Suhu dan Kelembapan Terhadap Kualitas Pupuk Urea di Gudang Penyimpanan,” *J. Rekayasa Dan Teknol. Ind.*, vol. 5, 2021.
- [2] M. R. F. A. Salim, “Development of fertilizer quality monitoring system using DHT22 sensor and fuzzy logic,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 18, 2020.
- [3] Y. Grahito, ‘Pemanfaatan IoT dan KNN untuk kontrol suhu dan kelembapan gudang’, *J. Teknol. Inf. Dan Sist.*, vol. 9, pp. 56–65, 2021.
- [4] R. Aulia, W. Zamrudy, and S. Hendrawan, ‘PENGARUH SUHU TERHADAP KUALITAS PRODUK PADA RUANG PENYIMPANAN DI PT PCTDI SIDOARJO’, *DISTILAT J. Teknol. Separasi*, vol. 8, pp. 72–76, May 2023, doi: 10.33795/distilat.v8i1.302.
- [5] F. Akbar and S. Sugeng, ‘Implementasi Sistem Monitoring Suhu dan Kelembapan Ruangan Penyimpanan Obat Berbasis Internet Of Things (IoT) di Puskesmas Kecamatan Taman Sari Jakarta Barat’, *J. Sos. Teknol.*, vol. 1, pp. 1021–1028, Sep. 2021, doi: 10.36418/journalsostech.v1i9.198.
- [6] S. Romadhona, Z. Pradana, S. Larasati, and S. Perangin-angin, ‘PRTOTIPE MONITORING SUHU DAN KELEMBAPAN PADA BUDIDAYA KELINCI DENGAN KOMUNIKASI MODBUS PADA SENSOR XY-MD02’, *J. SINTA Sist. Inf. Dan Teknol. Komputasi*, vol. 1, Jul. 2024, doi: 10.61124/sinta.v1i3.21.
- [7] M. Syarifuddin, ‘Klasifikasi Kualitas Air Pada Program Penyediaan Air Minum Dan Sanitasi Berbasis Masyarakat Desa Semeninggir Dengan Metode Algoritma K-Nearest Neighbor’, *Multidiscip. Appl. Quantum Inf. Sci. Al-Mantiq*, vol. 1, pp. 55–61, Aug. 2023, doi: 10.32665/almantiq.v1i2.1991.
- [8] A. Nugroho, ‘Pengembangan sistem pemantauan suhu dan kelembapan berbasis data sensor untuk peningkatan mutu pupuk’, *J. Pupuk Dan Kim. Ind.*, vol. 15, pp. 199–205, 2021.
- [9] J. L. J. Zhang, “Temperature and humidity monitoring system for warehouse based on wireless sensor network,” *Int. J. Distrib. Sens. Netw.*, vol. 11, pp. 1–9, 2015.
- [10] M. A. A. Al-Fuqaha, “Internet of Things: A survey on enabling technologies, protocols, and applications,” *IEEE Commun. Surv. Tutor.*, vol. 17, pp. 2347–2376, 2015.
- [11] H. Cover, ‘Nearest Neighbor Pattern Classification’, *IEEE Trans. Inf. Theory*, vol. 13, pp. 21–27, 1967.