

Penerapan Simulasi Monte Carlo untuk Memprediksi Kinerja dan Keandalan Sistem Komputer Berbasis *Artificial Intelligence*

Augusta Dwi Putra¹, Bangkit Ririatini², Dzaki Dwi Abdullah³, Rifqi Aziz⁴, Purwadi⁵

Informatika, Ilmu Komputer, Universitas Amikom, Purwokerto, Indonesia^{1,2,3,4}
Jl. Letjend. Pol. Soemarto No. 126, Watumas, Purwanegara, North Purwokerto District, Banyumas Regency,
Central Java

*Email: augustadwiputra20@gmail.com¹, riririir81@gmail.com², dzakidwiabdullah002@gmail.com³,
rfqazz3@gmail.com⁴, purwadi@amikompurwokerto.ac.id⁵

Sejarah Artikel:

Diterima 27-06-2026
Disetujui 02-07-2026
Diterbitkan 04-07-2026

ABSTRACT

The development of Artificial Intelligence (AI)-based computer systems in large-scale data processing environments introduces significant uncertainty regarding operational success rates. AI systems handling thousands to millions of processing requests daily are vulnerable to failures caused by workload variations, limited computational capacity, and model complexity. This study applies a quantitative approach using Monte Carlo Simulation to predict the performance and reliability of AI-based computer systems in data processing by utilizing probability concepts, discrete probability distributions, cumulative probabilities, expected value analysis, and Mean Absolute Percentage Error (MAPE). The research data consist of 250 historical processing observations classified into four categories: optimal success (58%), delayed success (24%), temporary failure with retry (12%), and total failure (6%). The expected processing time was calculated as $E(X) = 3.816$ seconds. A Monte Carlo Simulation with 10,000 iterations produced an average MAPE of 0.58%, indicating excellent predictive accuracy since it is well below the 5% tolerance threshold. Furthermore, under a workload of 50,000 requests per day, approximately 8,950 requests (17.9%) were estimated to potentially affect service reliability. The findings demonstrate that Monte Carlo Simulation is an effective quantitative tool for capacity planning and operational risk mitigation in AI-based computer systems.

Keywords: Monte Carlo Simulation; Artificial Intelligence (AI); AI-Based Computer System Reliability.

ABSTRAK

Perkembangan sistem komputer berbasis kecerdasan buatan (Artificial Intelligence/AI) dalam pemrosesan data berskala besar menimbulkan ketidakpastian terhadap tingkat keberhasilan operasional. Sistem AI yang menangani ribuan hingga jutaan permintaan setiap hari rentan mengalami kegagalan akibat variasi beban kerja, keterbatasan kapasitas komputasi, dan kompleksitas model. Penelitian ini menerapkan pendekatan kuantitatif berbasis Simulasi Monte Carlo untuk memprediksi kinerja dan keandalan sistem AI dalam memproses data dengan memanfaatkan konsep probabilitas, distribusi probabilitas diskret, probabilitas kumulatif, nilai harapan matematis (expected value), serta analisis Mean Absolute Percentage Error (MAPE). Data penelitian berasal dari 250 observasi yang dikelompokkan ke dalam empat kategori, yaitu berhasil optimal (58%), berhasil dengan penundaan (24%), gagal sementara dengan proses ulang/retry (12%), dan gagal total (6%). Nilai harapan matematis waktu pemrosesan diperoleh sebesar $E(X) = 3,816$ detik. Simulasi Monte Carlo sebanyak 10.000 iterasi menghasilkan rata-

rata MAPE sebesar 0,58%, yang menunjukkan tingkat akurasi prediksi sangat baik karena berada di bawah ambang toleransi 5%. Selain itu, pada beban kerja 50.000 permintaan per hari diperkirakan sekitar 8.950 permintaan (17,9%) berpotensi mengganggu keandalan layanan. Hasil penelitian menunjukkan bahwa Simulasi Monte Carlo efektif sebagai alat kuantitatif untuk mendukung perencanaan kapasitas dan mitigasi risiko operasional pada sistem komputer berbasis AI.

Kata kunci: Simulasi Monte Carlo; Kecerdasan Buatan (Artificial Intelligence); Keandalan Sistem Komputer Berbasis AI.

Bagaimana Cara Sitasi Artikel ini:

Putra, A. D. ., Ririadini, B. ., Abdullah, D. D., Aziz, R. ., & Purwadi, P. (2026). Penerapan Simulasi Monte Carlo untuk Memprediksi Kinerja dan Keandalan Sistem Komputer Berbasis Artificial Intelligence. Jejak Digital: Jurnal Ilmiah Multidisiplin, 2(4), 7349-7360. <https://doi.org/10.63822/4dv3rv27>

PENDAHULUAN

Teknologi kecerdasan buatan telah mengalami lompatan kemajuan yang sangat pesat selama satu dekade terakhir. Sistem berbasis AI kini tidak hanya dimanfaatkan sebagai alat bantu pendukung keputusan, melainkan telah menjadi komponen inti dalam arsitektur sistem komputer modern yang menangani pemrosesan data dalam skala masif. Dari sistem rekomendasi konten digital, deteksi penipuan transaksi keuangan, klasifikasi otomatis dokumen, hingga pengelolaan sumber daya infrastruktur komputasi awan secara real-time, AI telah hadir di hampir setiap lapisan ekosistem teknologi informasi. (Listy & Ilham, 2025). Pertumbuhan volume data yang eksponensial—yang lazim disebut big data—semakin memperkuat ketergantungan sistem modern terhadap kapabilitas AI dalam mengolah dan menginterpretasikan informasi secara cepat dan tepat guna. (Maspul & Putri, 2025).

Di balik manfaat yang besar tersebut, sistem AI menghadapi sebuah tantangan inheren yang tidak dapat diabaikan, yakni ketidakpastian (uncertainty) yang melekat pada setiap siklus pemrosesan data. (Tzivrailis et al., 2025). Ketidakpastian ini dapat bersumber dari berbagai faktor, di antaranya: (1) variasi intensitas beban kerja yang tidak dapat diprediksi secara deterministik; (2) keterbatasan kapasitas komputasi akibat persaingan sumber daya antarproses; (3) kompleksitas arsitektur model AI yang menimbulkan variabilitas pada latensi inferensi; serta (4) gangguan eksternal seperti kegagalan jaringan, kesalahan perangkat keras, atau anomali pada data masukan. (Yigit et al., 2024). Konsekuensi dari ketidakpastian ini adalah timbulnya variasi pada hasil pemrosesan, mulai dari keberhasilan dengan waktu respons optimal, keberhasilan dengan penundaan yang signifikan, kebutuhan pengulangan proses akibat kegagalan sementara, hingga kegagalan total yang mengharuskan permintaan dibatalkan. (Tzivrailis et al., 2025).

Pendekatan analitik deterministik konvensional terbukti tidak memadai untuk merepresentasikan kondisi operasional yang penuh dengan variabilitas semacam ini. Pemodelan berbasis rata-rata atau nilai tunggal kehilangan informasi penting mengenai distribusi kemungkinan hasil, sehingga tidak dapat memberikan gambaran akurat mengenai risiko kegagalan maupun peluang keberhasilan pada berbagai skenario beban kerja. (Pokorádi, 2024). Menegaskan bahwa dalam era pemrosesan big data, kebutuhan terhadap analisis prediktif yang mampu merepresentasikan ketidakpastian secara probabilistik semakin krusial untuk mendukung pengambilan keputusan yang handal dan berbasis data. (Maspul & Putri, 2025).

Simulasi Monte Carlo hadir sebagai metode kuantitatif berbasis pengambilan sampel acak (random sampling) yang terbukti mampu memodelkan ketidakpastian sistem secara realistis melalui pembangkitan ribuan skenario probabilistik. Menyatakan bahwa metode ini menyediakan mekanisme yang andal untuk mengevaluasi kinerja dan keandalan sistem kompleks melalui pemodelan statistik, termasuk untuk sistem yang menjadi tulang punggung infrastruktur digital kritis. (Yigit et al., 2024). Dengan menjalankan sejumlah besar iterasi acak yang merepresentasikan kemungkinan hasil pemrosesan, simulasi Monte Carlo memungkinkan peneliti memperkirakan distribusi hasil secara empiris, menghitung nilai harapan matematis, serta mengidentifikasi risiko kegagalan secara kuantitatif tanpa bergantung pada asumsi distribusi yang kaku. (Pokorádi, 2024).

Penelitian ini bertujuan mengisi kesenjangan yang ada dengan menerapkan simulasi Monte Carlo secara komprehensif—meliputi enam tahapan metodis mulai dari penyusunan distribusi probabilitas hingga analisis MAPE—untuk memprediksi kinerja dan keandalan sistem komputer berbasis AI dalam memproses data. Pendekatan ini diharapkan memberikan kontribusi nyata dalam pengembangan kerangka kerja kuantitatif untuk perencanaan kapasitas sistem AI dan mitigasi risiko kegagalan operasional pada skala produksi. (Guesmi, 2024).

KAJIAN PUSTAKA

Simulasi Monte Carlo telah menjadi instrumen analitik yang mapan dalam kajian keandalan sistem (system reliability analysis). Mendemonstrasikan bahwa simulasi Monte Carlo efektif untuk menginvestigasi sensitivitas dan ketidakpastian parametrik pada sistem dengan interkoneksi yang kompleks, termasuk dalam penentuan elemen kritis dan estimasi kebutuhan suku cadang sistem. (Pokorádi, 2024). Mengembangkan algoritma berbasis Monte Carlo untuk memprediksi Mean Time to Failure (MTTF) struktur kompleks—khususnya jaringan Bridge-type dengan lima elemen berdistribusi kegagalan beragam—menggunakan MATLAB, dan membuktikan bahwa metode ini mampu menangani distribusi Weibull dan eksponensial dengan tingkat galat minimal. (Guesmi, 2024). Secara khusus mengkaji keandalan arsitektur redundan M-out-of-N dengan memperhitungkan ketergantungan antarkomponen melalui simulasi Monte Carlo, dan menemukan bahwa dependensi komponen dapat memberikan efek beragam terhadap keandalan sistem bergantung pada konfigurasinya. (Julitz et al., n.d.).

Pada ranah sistem berbasis AI, Tzivrailis, Rosso, dan Kawasaki (2025) mengidentifikasi persoalan ketidakpastian epistemik yang muncul ketika model AI diposisikan sebagai fungsi pendekatan (surrogate) dalam rantai simulasi Monte Carlo, dan mengajukan metode berbasis ensemble berpenalti untuk mereduksi dampak ketidakpastian tersebut. (Tzivrailis et al., 2025). Menegaskan pentingnya simulasi Monte Carlo dalam konteks perlindungan infrastruktur digital berbasis AI dengan menyatakan bahwa teknik ini mampu memodelkan skenario kegagalan sistem secara statistik dengan menggunakan distribusi probabilitas untuk menggambarkan ketidakpastian pada kinerja komponen. (Yigit et al., 2024). Goyal (2025) memperlihatkan bahwa pendekatan berbasis AI yang dipadukan dengan analisis prediktif dapat digunakan untuk memperkirakan penggunaan sumber daya pada jalur pemrosesan big data dengan tingkat akurasi yang kompetitif, membuka peluang integrasi antara prediksi berbasis AI dan metodologi simulasi Monte Carlo. (Goyal, 2025)

Sejumlah penelitian di Indonesia juga telah mengadopsi simulasi Monte Carlo untuk keperluan prediksi di berbagai domain. Khairul Abdi dan Lubis (2024) menggunakannya untuk memprediksi jumlah mahasiswa baru, (Abdi & Lubis, 2024) sedangkan (Bayu Viargo et al., 2023) menerapkannya pada prediksi jumlah penumpang kereta api. (Asril, 2022) membuktikan penerapan Monte Carlo pada prediksi pendapatan penjualan dengan tahapan distribusi probabilitas, distribusi kumulatif, interval angka acak, dan simulasi percobaan. Rahmayana, (Rahmayana et al., 2025) memadukan Monte Carlo dengan metode nilai hasil (earned value) untuk pengendalian proyek, sementara (Mustafian et al., 2024) memanfaatkannya untuk pengukuran risiko portofolio melalui Value-at-Risk. (Kayadibi, 2025) menerapkan simulasi Monte Carlo berbobot untuk mengukur keberhasilan persepsi pengguna terhadap teknologi AI generatif berdasarkan tinjauan sistematis.

Pada perspektif yang lebih makro, (Listy & Ilham, 2025) menegaskan bahwa integrasi AI dan big data dalam sistem informasi manajemen mendorong efisiensi pengambilan keputusan namun sekaligus menghadirkan risiko operasional baru yang perlu dikelola secara terukur. (Maspul & Putri, 2025) menggarisbawahi pentingnya analitika prediktif berbasis big data bagi transformasi digital, sementara (Nawawi et al., 2024) memperlihatkan potensi model pembelajaran mesin berbasis data historis dalam mendukung prediksi klasifikasi untuk keperluan sistem operasional. Berdasarkan kajian komprehensif tersebut, ditemukan bahwa penerapan simulasi Monte Carlo yang secara terintegrasi menggabungkan distribusi probabilitas, probabilitas kumulatif, nilai harapan matematis, dan analisis MAPE dalam konteks spesifik pemrosesan data pada sistem komputer berbasis AI masih belum banyak dilakukan, sehingga penelitian ini mengisi celah tersebut secara langsung.

METODE PENELITIAN

Desain dan Pendekatan Penelitian

Penelitian ini menggunakan desain penelitian kuantitatif berbasis simulasi (quantitative simulation-based research design). Pendekatan kuantitatif dipilih karena tujuan penelitian bersifat prediktif dan evaluatif terhadap variabel-variabel numerik yang terukur, meliputi probabilitas kategori hasil pemrosesan, nilai harapan waktu pemrosesan, dan tingkat galat prediksi.(Pokorádi, 2024). (Julitz et al., n.d.) Metode simulasi Monte Carlo diterapkan sebagai inti analisis karena kemampuannya memodelkan ketidakpastian probabilistik melalui pembangkitan sampel acak berskala besar.(Pokorádi, 2024), (Guesmi, 2024), (Julitz et al., n.d.). Kerangka kerja metodologis yang diadopsi dalam penelitian ini terdiri dari enam tahapan berurutan sebagaimana divisualisasikan pada Gambar 1, yang mencakup pengumpulan data historis, penyusunan distribusi probabilitas, perhitungan probabilitas kumulatif, pembentukan interval angka acak, pelaksanaan simulasi Monte Carlo 10.000 iterasi, serta analisis akurasi dan galat prediksi.(Asril, 2022), (Abdi & Lubis, 2024), (Bayu Viargo et al., 2023).

[Tahap 1: Pengumpulan Data Historis] → [Tahap 2: Distribusi Probabilitas] → [Tahap 3: Probabilitas Kumulatif] → [Tahap 4: Interval Angka Acak] → [Tahap 5: Simulasi 10.000 Iterasi] → [Tahap 6: Analisis Akurasi & MAPE]

Gambar 1. Kerangka Kerja Metodologis Penelitian

Pengumpulan Data Historis Pemrosesan AI

Data yang digunakan dalam penelitian ini adalah catatan log (log record) historis pemrosesan data pada sistem AI yang mencakup informasi mengenai kategori hasil pemrosesan setiap permintaan (request) dan waktu pemrosesan yang dibutuhkan. Setiap catatan log dihasilkan secara otomatis oleh sistem dan merepresentasikan satu siklus pemrosesan, mulai dari penerimaan permintaan hingga pengembalian respons atau pencatatan galat. Total data historis yang digunakan berjumlah 250 observasi yang dikumpulkan dalam satu periode pengamatan (Yigit et al., 2024), (Listy & Ilham, 2025). dan diklasifikasikan ke dalam empat kategori hasil berdasarkan kombinasi antara status penyelesaian dan performa waktu respons, yaitu: (1) berhasil optimal—permintaan terselesaikan dengan latensi rendah dan akurasi model di atas ambang batas; (2) berhasil dengan penundaan—permintaan terselesaikan namun dengan latensi lebih tinggi dari standar yang ditetapkan; (3) gagal sementara—permintaan mengalami galat dan membutuhkan proses ulang (retry) sebelum akhirnya berhasil atau ditinggalkan; serta (4) gagal total—permintaan dibatalkan sepenuhnya karena galat sistem yang tidak dapat dipulihkan dalam batas waktu yang ditentukan.

Penyusunan Distribusi Probabilitas

Distribusi probabilitas diskret disusun dengan menghitung proporsi frekuensi relatif masing-masing kategori hasil pemrosesan terhadap total keseluruhan data historis. Formula yang digunakan adalah:

$$P(i) = f(i) / N$$

di mana $P(i)$ adalah probabilitas kategori ke- i , $f(i)$ adalah frekuensi kemunculan kategori ke- i dalam data historis, dan N adalah jumlah total observasi ($N = 250$). (Asril, 2022), (Abdi & Lubis, 2024), (Bayu Viargo et al., 2023). Syarat yang harus dipenuhi adalah $\sum P(i) = 1$ untuk seluruh i , sehingga distribusi probabilitas yang dihasilkan merupakan distribusi probabilitas yang valid.(Mustafian et al., 2024), (Rahmayana et al., 2025). Distribusi ini mencerminkan kecenderungan hasil pemrosesan data sistem AI secara empiris berdasarkan pengalaman operasional historis.

Perhitungan Probabilitas Kumulatif

Probabilitas kumulatif dihitung secara bertahap (kumulatif additive) dari kategori pertama ke kategori terakhir menggunakan rumus:

$$F(i) = \sum P(k), \text{ untuk } k = 1 \text{ s.d. } i$$

di mana $F(i)$ adalah fungsi distribusi kumulatif pada kategori ke- i . Nilai $F(i)$ (Asril, 2022), (Abdi & Lubis, 2024) bersifat monoton tidak menurun dan memenuhi $F(n) = 1,00$ pada kategori terakhir. Probabilitas kumulatif ini selanjutnya digunakan sebagai dasar matematis dalam penentuan batas atas interval angka acak pada setiap kategori. (Pokorádi, 2024), (Guesmi, 2024).

Pembentukan Interval Angka Acak

Interval angka acak ditetapkan secara proporsional terhadap nilai probabilitas setiap kategori dengan menggunakan skala bilangan bulat 0000 hingga 9999, sehingga ruang sampel berjumlah 10.000 angka yang mencerminkan 10.000 kemungkinan iterasi. Batas bawah interval kategori ke- i ditetapkan sebagai:

$$\text{Batas bawah}(i) = F(i-1) \times 10.000 \text{ [dibulatkan ke bawah]}$$

dan batas atas interval kategori ke- i adalah:

$$\text{Batas atas}(i) = F(i) \times 10.000 - 1 \text{ [dibulatkan ke bawah]}$$

Pendekatan ini menjamin bahwa peluang suatu bilangan acak yang dibangkitkan secara seragam (uniform) pada rentang 0000–9999 jatuh dalam interval kategori ke- i tepat setara dengan $P(i)$, sehingga proses pemetaan bilangan acak ke kategori bersifat valid secara statistik. (Asril, 2022), (Bayu Viargo et al., 2023), (Abdi & Lubis, 2024).

Simulasi Monte Carlo (10.000 Iterasi)

Simulasi Monte Carlo dilaksanakan dengan membangkitkan bilangan acak semu (pseudo-random number) sebanyak 10.000 kali menggunakan generator bilangan acak yang berdistribusi seragam (uniform distribution) pada rentang bilangan bulat 0000–9999. (Pokorádi, 2024), (Julitz et al., n.d.). Pada setiap iterasi ke- t , sebuah bilangan acak $r(t)$ dibangkitkan dan dipetakan ke dalam kategori hasil pemrosesan sesuai interval yang telah ditentukan, kemudian nilai waktu pemrosesan $x(t)$ ditetapkan berdasarkan nilai rata-rata waktu pada kategori yang terpilih. Nilai harapan matematis waktu pemrosesan secara simulatif dihitung sebagai rata-rata sederhana dari seluruh nilai $x(t)$:

$$E_{sim}(X) = (1/N_{sim}) \sum x(t), \text{ untuk } t = 1 \text{ s.d. } N_{sim} = 10.000$$

sementara nilai harapan matematis teoretis diperoleh dari formula:

$$E(X) = \sum [P(i) \times \mu(i)], \text{ untuk } i = 1 \text{ s.d. } k$$

di mana $\mu(i)$ adalah rata-rata waktu pemrosesan pada kategori ke- i berdasarkan data historis, dan k adalah jumlah kategori ($k = 4$). (Guesmi, 2024), (Mustafian et al., 2024). Pemilihan minimal 10.000 iterasi didasarkan pada prinsip hukum bilangan besar (law of large numbers) yang menjamin konvergensi proporsi simulasi menuju probabilitas teoretis seiring bertambahnya jumlah iterasi. (Pokorádi, 2024), (Julitz et al., n.d.).

Analisis Akurasi dan Galat Prediksi (MAPE)

Evaluasi akurasi dilakukan dengan membandingkan proporsi hasil simulasi untuk setiap kategori terhadap nilai probabilitas teoretis. Ukuran galat yang digunakan adalah Mean Absolute Percentage Error (MAPE), yang dihitung sebagai:

$$MAPE = (1/k) \sum | (P(i) - P_{sim}(i)) / P(i) | \times 100\%$$

di mana $P(i)$ adalah probabilitas teoretis kategori ke- i dan $P_{sim}(i)$ adalah proporsi simulasi kategori ke- i . (Asril, 2022), (Rahmayana et al., 2025). Interpretasi kualitas model prediksi mengacu pada kriteria Lewis

(dalam Asril, 2023): nilai $MAPE < 10\%$ menunjukkan kemampuan prediksi yang sangat baik (highly accurate), $MAPE 10\%–20\%$ tergolong baik, $MAPE 20\%–50\%$ tergolong cukup, dan $MAPE > 50\%$ tergolong tidak akurat. (Asril, 2022), (Abdi & Lubis, 2024), (Bayu Viargo et al., 2023). Hasil analisis MAPE kemudian digunakan sebagai dasar evaluasi kelayakan model simulasi dan sebagai pijakan rekomendasi peningkatan sistem.

HASIL DAN PEMBAHASAN

Data Historis dan Distribusi Frekuensi

Pengolahan terhadap 250 catatan log historis pemrosesan data pada sistem AI menghasilkan distribusi frekuensi sebagaimana disajikan pada Tabel 1. Setiap kategori hasil pemrosesan ditentukan berdasarkan status penyelesaian permintaan dan nilai latensi yang dibandingkan dengan ambang batas kinerja yang telah ditetapkan oleh sistem.

No.	Kategori Hasil Pemrosesan	Frekuensi (f)	P(i)	Persentase (%)
1	Berhasil Optimal	145	0,580	58,0
2	Berhasil dengan Penundaan	60	0,240	24,0
3	Gagal Sementara (Retry)	30	0,120	12,0
4	Gagal Total	15	0,060	6,0
	Jumlah	250	1,000	100,0

Tabel 1. Distribusi Frekuensi dan Probabilitas Hasil Pemrosesan Data Sistem AI

Tabel 1 menunjukkan bahwa mayoritas permintaan pemrosesan (82,0%) berhasil diselesaikan oleh sistem, baik secara optimal (58,0%) maupun dengan keterlambatan waktu respons (24,0%). Proporsi ini mencerminkan kondisi sistem yang cukup handal secara keseluruhan, meskipun kategori berhasil dengan penundaan yang mencapai 24,0% mengindikasikan adanya tekanan beban kerja yang mulai mempengaruhi kualitas layanan. Di sisi lain, akumulasi kegagalan—baik sementara maupun total—mencapai 18,0%, yang merupakan angka yang tidak dapat diabaikan pada sistem dengan volume permintaan harian yang tinggi. (Yigit et al., 2024), (Listy & Ilham, 2025). Distribusi ini selanjutnya digunakan sebagai dasar penyusunan model probabilistik untuk simulasi.

Distribusi Probabilitas, Probabilitas Kumulatif, dan Interval Angka Acak

Berdasarkan distribusi frekuensi pada Tabel 1, probabilitas kumulatif $F(i)$ dihitung secara bertahap dan interval angka acak ditetapkan secara proporsional pada skala 0000–9999. (Asril, 2022), (Bayu Viargo et al., 2023). Hasil selengkapnya disajikan pada Tabel 2.

No.	Kategori Hasil Pemrosesan	P(i)	F(i) Kumulatif	Interval Angka Acak
1	Berhasil Optimal	0,580	0,580	0000 – 5799
2	Berhasil dengan Penundaan	0,240	0,820	5800 – 8199
3	Gagal Sementara (Retry)	0,120	0,940	8200 – 9399
4	Gagal Total	0,060	1,000	9400 – 9999

Tabel 2. Probabilitas Kumulatif dan Interval Angka Acak per Kategori

Tabel 2 menunjukkan interval angka acak yang proporsional terhadap nilai probabilitas setiap kategori. Kategori berhasil optimal mendapat interval terluas (0000–5799, mencakup 5.800 angka dari total 10.000 angka), yang tepat setara dengan probabilitas 0,580 atau 58%. Verifikasi proporsionalitas: $5.800 / 10.000 = 0,580 \checkmark$; $2.400 / 10.000 = 0,240 \checkmark$; $1.200 / 10.000 = 0,120 \checkmark$; $600 / 10.000 = 0,060 \checkmark$. Jumlah total angka yang tercover = $5.800 + 2.400 + 1.200 + 600 = 10.000 \checkmark$. Sebagai contoh ilustratif, apabila dalam satu iterasi dibangkitkan bilangan acak $r = 7.234$, angka tersebut jatuh dalam interval 5800–8199 sehingga iterasi tersebut diklasifikasikan ke dalam kategori "Berhasil dengan Penundaan".

Nilai Harapan Matematis (Expected Value) Waktu Pemrosesan

(Guesmi, 2024), (Mustafian et al., 2024). Berdasarkan data historis, nilai rata-rata waktu pemrosesan per kategori yang digunakan dalam perhitungan adalah: $\mu_1 = 1,20$ detik (berhasil optimal), $\mu_2 = 5,50$ detik (berhasil dengan penundaan), $\mu_3 = 9,00$ detik (gagal sementara, termasuk durasi retry), dan $\mu_4 = 12,00$ detik (gagal total, termasuk waktu penanganan galat). Nilai harapan matematis waktu pemrosesan secara teoretis dihitung sebagai berikut:

No.	Kategori	P(i)	$\mu(i)$ (detik)	$P(i) \times \mu(i)$	Kumulatif
1	Berhasil Optimal	0,580	1,20	0,696	0,696
2	Berhasil dengan Penundaan	0,240	5,50	1,320	2,016
3	Gagal Sementara (Retry)	0,120	9,00	1,080	3,096
4	Gagal Total	0,060	12,00	0,720	3,816

Tabel 3. Perhitungan Nilai Harapan Matematis Waktu Pemrosesan

Dari Tabel 3 diperoleh:

$$E(X) = (0,580 \times 1,20) + (0,240 \times 5,50) + (0,120 \times 9,00) + (0,060 \times 12,00)$$

$$E(X) = 0,696 + 1,320 + 1,080 + 0,720 = 3,816 \text{ detik}$$

Nilai harapan matematis sebesar 3,816 detik per permintaan ini dapat dimaknai sebagai estimasi rata-rata waktu yang dibutuhkan sistem AI untuk memproses satu permintaan, dengan memperhitungkan kemungkinan terjadinya penundaan, retry, dan kegagalan total sesuai distribusi probabilitasnya. Nilai ini menjadi acuan baseline yang penting dalam perencanaan kapasitas sistem: apabila sistem diharapkan

menyelesaikan N permintaan per jam, maka kapasitas komputasi minimum yang dibutuhkan dapat diestimasi berdasarkan nilai $E(X)$ ini.

Pelaksanaan Simulasi Monte Carlo (10.000 Iterasi)

Simulasi Monte Carlo dilaksanakan dengan membangkitkan 10.000 bilangan acak berdistribusi seragam pada rentang 0000–9999. Setiap bilangan acak dipetakan ke dalam kategori yang sesuai berdasarkan interval pada Tabel 2, kemudian frekuensi kumulatif per kategori dihitung dan dibandingkan dengan nilai teoretis. Rekapitulasi hasil simulasi disajikan pada Tabel 4. (Pokorádi, 2024), (Julitz et al., n.d.).

Kategori	Frek. Teoretis	P Teoretis	Frek. Simulasi	P Simulasi	Selisih (poin %)
Berhasil Optimal	5.800	0,5800	5.793	0,5793	−0,07
Berhasil Tertunda	2.400	0,2400	2.417	0,2417	+0,17
Gagal Sementara	1.200	0,1200	1.198	0,1198	−0,02
Gagal Total	600	0,0600	592	0,0592	−0,08
Total	10.000	1,0000	10.000	1,0000	—

Tabel 4. Perbandingan Frekuensi dan Proporsi: Nilai Teoretis vs. Hasil Simulasi Monte Carlo (10.000 Iterasi)

Tabel 4 menggambarkan tingkat kesesuaian yang sangat tinggi antara proporsi hasil simulasi dengan nilai probabilitas teoretis. Selisih terbesar terjadi pada kategori "Berhasil dengan Penundaan" dengan deviasi sebesar +0,17 poin persentase, sementara kategori lainnya memiliki deviasi di bawah 0,10 poin. Kondisi ini memvalidasi prinsip hukum bilangan besar yang menyatakan bahwa distribusi empiris simulasi akan semakin mendekati distribusi teoretis seiring meningkatnya jumlah iterasi. (Pokorádi, 2024), (Julitz et al., n.d.). Temuan ini juga sejalan dengan (Guesmi, 2024) yang membuktikan bahwa algoritma berbasis Monte Carlo mampu menghasilkan estimasi MTTF dengan galat yang sangat kecil pada berbagai jenis distribusi kegagalan.

Nilai Harapan Waktu Pemrosesan Hasil Simulasi

Rata-rata waktu pemrosesan secara simulatif dihitung berdasarkan frekuensi hasil simulasi pada Tabel 4 dengan mempertahankan nilai $\mu(i)$ yang sama:

$$E_{sim}(X) = (5793 \times 1,20 + 2417 \times 5,50 + 1198 \times 9,00 + 592 \times 12,00) / 10.000$$

$$E_{sim}(X) = (6.951,6 + 13.293,5 + 10.782,0 + 7.104,0) / 10.000$$

$$E_{sim}(X) = 38.131,1 / 10.000 = 3,813 \text{ detik}$$

Selisih antara nilai harapan teoretis (3,816 detik) dan nilai harapan simulasi (3,813 detik) adalah 0,003 detik, yang setara dengan galat relatif sebesar 0,08%. (Pokorádi, 2024), (Guesmi, 2024). Nilai galat yang sangat kecil ini mempertegas bahwa simulasi Monte Carlo dengan 10.000 iterasi mampu mengestimasi nilai harapan waktu pemrosesan sistem AI dengan presisi yang sangat tinggi.

Analisis Akurasi dan MAPE

Perhitungan MAPE dilakukan terhadap seluruh kategori hasil pemrosesan. Hasil selengkapnya disajikan pada Tabel 5.

Kategori	P Teoretis	P Simulasi	Selisih	Selisih / P Teoretis	MAPE per Kategori (%)
Berhasil Optimal	0,5800	0,5793	0,0007	0,0012	0,12
Berhasil Tertunda	0,2400	0,2417	0,0017	0,0071	0,71
Gagal Sementara	0,1200	0,1198	0,0002	0,0017	0,17
Gagal Total	0,0600	0,0592	0,0008	0,0133	1,33
Rata-rata MAPE					0,58

Tabel 5. Analisis Mean Absolute Percentage Error (MAPE) per Kategori

Tabel 5 memperlihatkan bahwa rata-rata MAPE keseluruhan sebesar 0,58% berada jauh di bawah ambang 10%, sehingga menurut kriteria Lewis sebagaimana dikutip Asril (2023), tingkat akurasi prediksi simulasi tergolong sangat baik (highly accurate). (Asril, 2022). Kategori gagal total memiliki MAPE relatif lebih tinggi (1,33%) dibandingkan kategori lainnya; hal ini merupakan konsekuensi alami dari probabilitas kategori yang sangat kecil (0,060), sehingga fluktuasi absolut yang kecil pun akan menghasilkan galat persentase yang relatif lebih besar. Temuan ini konsisten dengan penjelasan mengenai karakteristik ketidakpastian pada kejadian berprobabilitas rendah dalam simulasi berbasis AI, yang memerlukan perhatian khusus dalam pengelolaan risiko sistem. (Tzivraailis et al., 2025).

Identifikasi Risiko Kegagalan pada Skala Operasional

Salah satu nilai tambah utama dari simulasi Monte Carlo adalah kemampuannya mengkuantifikasi risiko operasional pada skenario beban kerja yang lebih representatif. Untuk tujuan ini, dilakukan proyeksi risiko pada skala beban kerja operasional harian sebagaimana disajikan pada Tabel 6.

Kategori	P Simulasi	Volume Harian (req)	Estimasi Jumlah (req)	Dampak Operasional
Berhasil Optimal	0,5793	50.000	28.965	Tidak ada gangguan
Berhasil Tertunda	0,2417	50.000	12.085	Penurunan kepuasan pengguna
Gagal Sementara	0,1198	50.000	5.990	Beban antrean & retry tinggi
Gagal Total	0,0592	50.000	2.960	Kehilangan data & insiden SLA

Kategori	P Simulasi	Volume Harian (req)	Estimasi Jumlah (req)	Dampak Operasional
Total Terganggu	0,1790	50.000	8.950	17,9% dari total harian

Tabel 6. Proyeksi Risiko Operasional pada Beban Kerja 50.000 Permintaan/Hari

Tabel 6 mengungkapkan gambaran yang krusial: pada beban kerja sebesar 50.000 permintaan per hari, sistem AI diperkirakan akan mengalami sekitar 8.950 permintaan yang terganggu per hari (17,9%), dengan rincian 5.990 permintaan gagal sementara (memerlukan retry dan meningkatkan beban komputasi) dan 2.960 permintaan gagal total (berpotensi menyebabkan pelanggaran Service Level Agreement/SLA dan kehilangan data). Temuan ini sejalan dengan kekhawatiran yang diungkapkan (Yigit et al., 2024) bahwa kegagalan pada sistem AI yang menopang infrastruktur digital dapat memicu efek berantai (cascading effect) yang berdampak pada layanan dependen. (Listy & Ilham, 2025) juga menegaskan bahwa manajemen risiko operasional pada sistem berbasis AI dan big data menjadi salah satu tantangan paling kritis yang dihadapi organisasi digital saat ini.

KESIMPULAN

Penelitian ini menunjukkan bahwa Simulasi Monte Carlo efektif digunakan untuk memprediksi kinerja dan keandalan sistem komputer berbasis AI dalam memproses data. Hasil simulasi mampu merepresentasikan distribusi probabilitas pemrosesan data dengan tingkat akurasi yang sangat baik, ditunjukkan oleh nilai MAPE sebesar 0,58% dan galat relatif nilai harapan hanya 0,08%. Simulasi juga berhasil mengidentifikasi risiko operasional, di mana sekitar 17,9% permintaan berpotensi mengalami gangguan pada beban kerja 50.000 permintaan per hari. Temuan ini menegaskan bahwa Simulasi Monte Carlo dapat menjadi alat yang efektif untuk mendukung perencanaan kapasitas, pengelolaan risiko, dan pengambilan keputusan berbasis data pada sistem AI.

Penelitian selanjutnya disarankan menggunakan data log aktual dari sistem AI produksi dengan periode pengamatan yang lebih panjang agar hasil simulasi lebih representatif. Selain itu, peningkatan jumlah iterasi simulasi, integrasi machine learning untuk pembaruan probabilitas secara adaptif, serta penerapan teknik pengurangan varians dapat dilakukan guna meningkatkan akurasi prediksi. Bagi praktisi, hasil simulasi sebaiknya diintegrasikan ke dalam sistem monitoring untuk mendukung deteksi dini risiko operasional dan meningkatkan keandalan layanan secara berkelanjutan.

DAFTAR PUSTAKA

- Abdi, K., & Lubis, M. R. A. (2024). Prediksi Jumlah Mahasiswa Baru FMIPA UNIMED Dengan Menggunakan Teknik Simulasi Monte Carlo. *Mars : Jurnal Teknik Mesin, Industri, Elektro Dan Ilmu Komputer*, 2(3), 72–83.
- Asril, A. P. (2022). Simulasi dalam Menganalisis Tingkat Pendapatan Penjualan Produk Bengkel Las menggunakan Metode Monte Carlo. *Jurnal Sistim Informasi Dan Teknologi*, 5, 7–9. <https://doi.org/10.37034/jsisfotek.v5i1.155>
- Bayu Viargo, A. K., Saifudin, T., & Chamidah, N. (2023). Prediksi Jumlah Penumpang Kereta Api Stasiun

- Surabaya Gubeng dengan Metode Monte Carlo. *Limits: Journal of Mathematics and Its Applications*, 20(3), 275. <https://doi.org/10.12962/limits.v20i3.16123>
- Goyal, H. (2025). *Artificial Intelligence for Cost-Aware Resource Prediction in Big Data Pipelines*. <http://arxiv.org/abs/2510.05127>
- Guesmi, H. A. (2024). Prediction of the Mean Time to Failures of a Complex System Using the Monte Carlo Simulation Method. *Journal of Reliability and Statistical Studies*, 17(2), 267–288. <https://doi.org/10.13052/jrss0974-8024.1721>
- Julitz, T. M., Tordeux, A., Schlüter, N., & Löwer, M. (n.d.). *Reliability of Redundant M-Out-Of-N Architectures With Dependent Components: A Comprehensible Approach With Monte Carlo Simulation*.
- Kayadibi, S. Y. (2025). *Quantifying Student Success with Generative AI: A Monte Carlo Simulation Informed by Systematic Review*. <http://arxiv.org/abs/2507.01062>
- Listy, V., & Ilham, I. (2025). Revolusi Sistem Informasi Manajemen di Era AI dan Big Data Mengubah Cara Bisnis Bekerja. *Simpatik: Jurnal Sistem Informasi Dan Informatika*, 5(1), 27–36. <https://doi.org/10.31294/simpatik.v5i1.7621>
- Maspul, K. A., & Putri, N. K. (2025). Big Data and Predictive Analytics for Indonesia's Economic Transformation and Digital Resilience. *Journal of Technology and System Information*, 2(2), 22. <https://doi.org/10.47134/jtsi.v2i2.3774>
- Mustafian, M., Mauliddin, M., & Abdal, A. M. (2024). Penerapan Value-at-Risk dan Conditional-Value-at-Risk Dalam Pengukuran Risiko Portofolio Optimal Menggunakan Pendekatan Simulasi Monte Carlo. *Jurnal Riset Dan Aplikasi Matematika (JRAM)*, 8(1), 39–50. <https://doi.org/10.26740/jram.v8n1.p39-50>
- Nawawi, H. M., Hikmah, A. B., Mustopa, A., & Wijaya, G. (2024). *Model Klasifikasi Machine Learning untuk Prediksi Ketepatan Penempatan Karir Era modern telah dipenuhi oleh kompleksitas pasar kerja yang terus berubah , maka dari itu penting bagi maupun organisasi untuk untuk mengatasi kompleksitas dan dalam pengambilan*. 14(1), 13–25.
- Pokorádi, L. (2024). Monte-Carlo Simulation of Reliability of System with Complex Interconnections. *Vehicles*, 6(4), 1801–1811. <https://doi.org/10.3390/vehicles6040087>
- Rahmayana, R., Bachmid, S., & Maricar, H. (2025). Kajian pengendalian waktu dan biaya dengan metode nilai hasil dan simulasi monte carlo. *Jurnal Teknik Industri Terintegrasi*, 8(1), 1230–1238. <https://doi.org/10.31004/jutin.v8i1.41834>
- Tzivraillis, D., Rosso, A., & Kawasaki, E. (2025). *Uncertainty in AI-driven Monte Carlo simulations*. 1–15. <http://arxiv.org/abs/2506.14594>
- Yigit, Y., Ferrag, M. A., Sarker, I. H., Maglaras, L. A., Chrysoulas, C., Moradpoor, N., & Janicke, H. (2024). *Critical Infrastructure Protection: Generative AI, Challenges, and Opportunities*. 4. <http://arxiv.org/abs/2405.04874>