

Konvergensi simulasi dan kecerdasan: Tinjauan terhadap integrasi metode Monte Carlo dan *machine learning* dalam manajemen risiko

Ratna Mustika Dewi ^{1*}, Oktarian Wisnu Lusantono ², Indra Wahyu Murtyanto ³

¹ Departemen Teknik Industri, Universitas Atma Jaya Yogyakarta, Yogyakarta, Indonesia; email: ratna.mustika@uajy.ac.id

² Program Studi Teknik Pertambangan, Universitas Pembangunan Nasional (UPN) Veteran Yogyakarta, Yogyakarta, Indonesia

³ PT Studio Mineral Batubara, Yogyakarta, Indonesia

* Corresponding author

Abstrak

Integrasi metode Monte Carlo (MC) dan *machine learning* (ML) merepresentasikan terobosan dalam manajemen risiko modern untuk mengatasi kompleksitas dan ketidakpastian dinamik. Tinjauan sistematis ini mengkaji konvergensi kedua pendekatan tersebut, mengidentifikasi tiga pola integrasi utama: (1) penggunaan ML sebagai surrogate model untuk mempercepat simulasi MC, (2) pemanfaatan MC untuk mengkuantifikasi ketidakpastian dalam model ML, dan (3) penerapan generative ML models untuk pembangkitan skenario stres. Hasil analisis menunjukkan bahwa sinergi ini mampu meningkatkan akurasi prediktif, efisiensi komputasi, dan kapasitas penilaian risiko ekor. Meskipun demikian, tantangan implementasi seperti kompleksitas model dan kebutuhan interpretabilitas masih perlu diatasi. Penelitian ini menyimpulkan bahwa integrasi MC-ML menawarkan paradigma baru yang powerful dan merekomendasikan pengembangan teknik interpretabilitas serta standar validasi sebagai agenda penelitian mendatang.

Kata Kunci: Monte Carlo, manajemen risiko, *machine learning*

Abstract

[Simulation and intelligence convergence: A systematic review of the integration of Monte Carlo method and machine learning in risk management] The integration of Monte Carlo (MC) methods and machine learning (ML) represents a breakthrough in modern risk management for addressing dynamic complexity and uncertainty. This systematic review examines the convergence of these two approaches, identifying three main integration patterns: (1) the use of ML as a surrogate model to accelerate MC simulation, (2) the use of MC to quantify uncertainty in ML models, and (3) the application of generative ML models for stress scenario generation. The analysis results indicate that this synergy can improve predictive accuracy, computational efficiency, and tail risk assessment capacity. Nevertheless, implementation challenges such as model complexity and the need for interpretability still need to be addressed. This study concludes that MC-ML integration offers a powerful new paradigm and recommends the development of interpretability techniques and validation standards as the agenda for future research.

Keywords: Monte Carlo, risk management, *machine learning*

Received: 30-11-2025; Revised: 31-12-2025; Accepted: 31-12-2025

DOI: <https://doi.org/10.24002/jtimr.v3.i2.13337>

Saran format untuk sitasi artikel ini:

Dewi, R. M., Lusantono. O. W., & Murtyanto, I. (2025). Konvergensi simulasi dan kecerdasan: Tinjauan terhadap integrasi metode Monte Carlo dan machine learning dalam manajemen risiko. *Jurnal Teknik Industri dan Manajemen Rekayasa*, 3(2), 125-131.

1. Pendahuluan

Manajemen risiko modern menghadapi paradigma baru yang ditandai dengan volatilitas tinggi, ketidakpastian kompleks, dan interdependensi global (Kaplan dan Mikes, 2012). Peristiwa *systemic risk* seperti krisis finansial 2008 dan pandemi COVID-19 telah mengungkap keterbatasan model tradisional dalam menangkap nonlinearitas dan *fat-tailed distributions* dari distribusi risiko kontemporer (Taleb, 2025). Kondisi ini diperparah dengan disrupsi digital di mana *cyber risk* dan *algorithmic failure* menciptakan ancaman eksistensial baru yang bergerak dalam kecepatan tinggi (World Economic Forum, 2023). Transformasi fundamental ini menuntut evolusi metodologi dari pendekatan statis menuju *framework* dinamis berbasis komputasi canggih.

Metode kuantitatif tradisional seperti *Value-at-Risk* (VaR) parametrik terbukti rentan terhadap *black swan events* karena ketergantungannya pada asumsi distribusi normal dan stasioneritas *time series* (Danielsson *et al.*, 2022). Model tersebut gagal mengakomodasi *regime changes* dan *structural breaks* yang menjadi ciri pasar finansial modern (Boucher *et al.*, 2021). Lebih lanjut, pendekatan *siloed risk management* menghambat pemahaman holistik terhadap *risk correlation* dan *spillover effects* antar segmen bisnis (McNeil *et al.*, 2015). Keterbatasan ini mengakibatkan *systematic underestimation* terhadap *tail risk* dan *vulnerability* terhadap kaskade kegagalan sistemik.

Dalam merespons tantangan ini, konvergensi antara metode simulasi stokastik dan *artificial intelligence* menawarkan paradigma baru. Metode Monte Carlo memberikan *robustness* probabilistik melalui *generative modeling* dari *thousands of scenarios*, sementara *machine learning* menawarkan kemampuan *pattern recognition* dalam data *high-dimensional* (Ruf & Wang, 2020). Integrasi ini memungkinkan *development of hybrid models* yang mampu menangkap *complex dependencies* sekaligus menghasilkan *predictive analytics* yang terkalibrasi (Czaronis *et al.*, 2023). Sinergi ini terutama krusial dalam menangani masalah *dimensionalitis curse* yang menghantui kedua pendekatan secara terpisah.

Implementasi integrasi Monte Carlo – *machine learning* (ML) telah menunjukkan *promise* dalam berbagai domain. Dalam *market risk management*, *Bayesian Neural Networks* yang dikombinasikan dengan Monte Carlo *dropout* berhasil menghasilkan *uncertainty-aware prediction intervals* untuk *asset volatility* (Jospin *et al.*, 2022). Di sektor perbankan, *Generative Adversarial Networks* (GANs) dimanfaatkan untuk *synthetic data generation* dalam *stress testing scenarios* yang melampaui *historical data* (Selvaraj *et al.*, 2022). Aplikasi dalam *credit risk demonstrated improvement* signifikan dalam *default probability estimation* melalui *ensemble methods* yang memadukan *survival analysis* dengan Monte Carlo *simulation* (Noriega *et al.*, 2023).

Tinjauan sistematis ini bertujuan mengkonsolidasikan temuan empiris dan konseptual melalui *critical assessment* terhadap konvergensi metodologis tersebut. Penelitian ini memberikan *value* dengan: (1) mengidentifikasi *archetype* integrasi Monte Carlo - ML yang dominan, (2) menganalisis *trade-off* antara *computational complexity* dan *predictive accuracy*, serta (3) mengembangkan *research agenda* untuk *advancing probabilistic machine learning* dalam

manajemen risiko. Kontribusi ini menjadi krusial bagi akademisi dan praktisi dalam *navigating next-generation risk management framework*.

2. Metode

Awalnya, manajemen risiko mengandalkan metode kualitatif yang bersifat subyektif dan berdasarkan pengalaman. Teknik-teknik seperti *checklists*, *brainstorming*, dan analisis *Delphi* banyak digunakan untuk mengidentifikasi dan menilai risiko berdasarkan persepsi para ahli dan manajer (Aven, 2015). Pendekatan ini, meskipun berharga untuk mengumpulkan wujud kontekstual dan mendapatkan penerimaan dari pemangku kepentingan, memiliki keterbatasan signifikan karena tidak dapat memberikan ukuran kuantitatif yang objektif. Kurangnya dasar numerik membuatnya sulit untuk membandingkan tingkat risiko yang berbeda, mengalokasi sumber daya secara optimal, atau mengkomunikasikan eksposur risiko dengan tepat kepada dewan direksi dan regulator (Hopkin, 2018).

Revolusi dalam manajemen risiko dimulai dengan diperkenalkannya metode kuantitatif. Dalam risiko finansial, *Value-at-Risk* (VaR) menjadi standar industri untuk mengestimasi kerugian potensial maksimum dalam portofolio pada selang kepercayaan dan periode waktu tertentu (Jorion, 2007). VaR parametrik, yang mengasumsikan distribusi normal, mendominasi praktik karena kesederhanaan perhitungannya. Selain VaR, teknik statistik seperti analisis sensitivitas, analisis skenario, dan simulasi stres digunakan untuk menguji ketahanan portofolio terhadap perubahan kondisi pasar. Namun, metode ini terbukti rapuh selama krisis, karena ketergantungannya pada data historis dan asumsi distribusi yang sering kali tidak berlaku pada peristiwa ekstrem (*tail events*) (Taleb, 2007).

Untuk mengatasi keterbatasan model parametrik, metode Monte Carlo diadopsi secara luas sebagai teknik yang lebih kuat untuk menangkap kompleksitas dan non-linearitas. Metode ini memungkinkan praktisi untuk menghasilkan ribuan atau bahkan jutaan skenario masa depan yang mungkin dengan mensimulasikan jalur acak dari faktor risiko yang mendasarinya (Glasserman, 2003). Keunggulan utamanya terletak pada kemampuannya untuk memodelkan instrumen keuangan yang kompleks (seperti opsi eksotis) dan memberikan seluruh distribusi probabilitas dari outcome, bukan hanya satu angka seperti VaR. Hal ini memungkinkan perhitungan metrik yang lebih informatif seperti *Conditional VaR* (CVaR), yang mengukur rata-rata kerugian melebihi VaR, sehingga memberikan gambaran yang lebih baik tentang risiko ekor (McNeil *et al.*, 2015).

Dengan meledaknya ketersediaan data (*big data*), *machine learning* (ML) telah membawa perubahan paradigma dengan fokus pada kemampuan prediktif. Algoritma seperti *Random Forest*, *Gradient Boosting Machines* (GBM), dan *Support Vector Machines* (SVM) telah diterapkan untuk memprediksi *default* kredit (*credit scoring*), mendeteksi penipuan (*fraud detection*), dan mengklasifikasi risiko operasional dengan akurasi yang lebih tinggi daripada model regresi tradisional (Hastie *et al.*, 2009). ML unggul dalam menemukan pola non-linier dan interaksi kompleks dalam dataset yang besar dan berdimensi tinggi, yang sering kali terlewat oleh metode statistik konvensional.


Tren paling mutakhir adalah konvergensi antara kekuatan simulasi stokastik dan kecerdasan prediktif ML. Pendekatan hibrida ini muncul untuk menutupi kelemahan masing-masing metode. Sebagai contoh, simulasi Monte Carlo digunakan untuk mengkuantifikasi ketidakpastian pada output model ML, seperti dalam *Bayesian Neural Networks* (Gal & Ghahramani, 2016). Integrasi ini memungkinkan terciptanya sistem manajemen risiko yang

tidak hanya dapat memprediksi kejadian merugikan tetapi juga secara probabilistik mengkuantifikasi potensi dampaknya dalam berbagai skenario, yang pada akhirnya mengarah pada pengambilan keputusan yang lebih tangguh dan adaptif.

Penelitian ini menggunakan metode tinjauan pustaka sistematis untuk mengkaji konvergensi metode Monte Carlo dan *machine learning* dalam manajemen risiko modern. Prosedur pelaksanaan mengacu pada kerangka PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), yang meliputi empat tahap utama: (1) *Identification*: pencarian literatur awal secara ekstensif di *database* akademik (Scopus, Google Scholar, Science Direct dan lain sebagainya) menggunakan kombinasi kata kunci terkait; (2) *Screening*: penyaringan berdasar kriteria inklusi-eksklusi untuk relevansi dan kualitas; (3) *Eligibility*: penilaian kelayakan studi secara mendalam; dan (4) *Inclusion*: ekstraksi dan sintesis data dari studi terpilih. Melalui pendekatan sistematis ini, penelitian bertujuan memetakan pola integrasi, menganalisis keunggulan dan tantangan, serta mengidentifikasi celah penelitian untuk disusunnya agenda riset ke depan.

3. Hasil dan Pembahasan

Berdasarkan tinjauan pustaka terhadap literatur yang membahas terkait integrasi Monte Carlo dan *machine learning* dalam merepresentasikan terobosan dalam manajemen risiko yang didasarkan pada peran dominan pada masing-masing metode, terdapat 3 pola integrasi metode Monte Carlo dan *machine learning* dalam manajemen risiko yaitu (1) *Machine learning* sebagai akselerator simulasi Monte Carlo; (2) Monte Carlo sebagai pengkuantifikasi ketidakpastian *machine learning*; dan (3) *Machine learning* sebagai generator skenario untuk Monte Carlo. Diagram Integrasi dapat dilihat dalam Gambar 1.



Gambar 1. Diagram integrasi.

3.1. *Machine learning* sebagai akselerator simulasi Monte Carlo

Dalam pola ini, model *machine learning* terutama *deep neural networks* atau *Gaussian process regression* bertindak sebagai *surrogate model* atau emulator. Model ini menggunakan subset hasil dari simulasi MC penuh, kemudian digunakan untuk memprediksi output simulasi secara langsung untuk input parameter baru. Studi-studi seperti Shi *et al.* (2024) menunjukkan jika *Deep Neural Network* banyak digunakan dalam simulasi Monte Carlo untuk manajemen risiko karena memiliki kemampuan dalam memperkirakan nilai harapan (*expected value*) dan kuantitas fungsional secara efisien. Namun, efektivitas pola ini sangat bergantung pada kualitas data pelatihan. Risiko utamanya adalah *extrapolation error*, di mana *surrogate*

model menghasilkan prediksi yang tidak akurat untuk input yang berada di luar rentang data pelatihannya, yang justru kritis dalam menilai *tail risk*. Oleh karena itu, pola ini paling cocok untuk masalah dengan ruang parameter yang terdefinisi dengan baik dan memerlukan skema validasi yang ketat.

3.2. Monte Carlo sebagai pengkuantifikasi ketidakpastian pada *machine learning*

Model ML konvensional sering dikritik sebagai "kotak hitam" yang menghasilkan prediksi deterministik tanpa ukuran kepercayaan. Teknik MC seperti *Monte Carlo Dropout* dan *Deep Ensembles* mengatasi keterbatasan ini dengan mengubah model ML menjadi model probabilistik. Dalam penerapannya, seperti pada prediksi probabilitas gagal bayar (*credit default*), pendekatan ini tidak hanya memberikan titik estimasi tetapi juga interval kepercayaan (Yu *et al.*, 2023). Hal ini memungkinkan manajer risiko untuk membedakan antara prediksi yang memiliki keyakinan tinggi dan prediksi yang ambigu, sehingga memfasilitasi pengambilan keputusan yang lebih bernuansa dan berbasis risiko. Tantangan dari pola ini adalah meningkatnya kompleksitas komputasi selama inferensi dan kesulitan dalam menginterpretasikan distribusi posterior yang dihasilkan, terutama untuk pemangku kepentingan non-teknis.

3.3. *Machine learning* sebagai generator skenario untuk Monte Carlo

Teknik seperti *Generative Adversarial Networks (GANs)* dan *Variational Autoencoders (VAEs)* dapat mempelajari distribusi data pasar yang kompleks dan non-stasioner, lalu menghasilkan skenario stres sintesis yang *plausible* namun ekstrem (Coursera, 2025). Skenario-skenario ini, yang mungkin belum pernah terjadi dalam data historis, kemudian menjadi input bagi simulasi MC untuk mengevaluasi ketahanan portofolio. Pola ini mengatasi kelemahan utama *stress testing* tradisional yang sering terbatas pada skenario historis atau hipotetis yang disederhanakan. Kendala utamanya adalah fenomena *mode collapse* pada GAN, yang dapat menghasilkan variasi skenario yang terbatas, serta kesulitan objektif dalam memvalidasi "realisme" skenario ekstrem yang dihasilkan.

4. Kesimpulan

Integrasi Monte Carlo dan *machine learning* dalam manajemen risiko terjadi melalui tiga pola yang saling melengkapi. Dampaknya adalah dapat terciptanya kapabilitas baru dalam hal kecepatan, kuantifikasi ketidakpastian, dan generasi skenario. Hasil akhirnya bukan sekedar angka tunggal, tetapi juga berupa distribusi probabilitas yang menjadi informasi penting sehingga mendukung *risk decision making* yang lebih baik. Selanjutnya tantangan utamanya terletak pada kemampuan interpretasi model yang kompleks, kebutuhan data berkualitas tinggi dengan volume besar, dan risiko baru berupa kesalahan spesifikasi model atau kerentanan terhadap *adversarial attack*. Hal ini menunjukkan bahwa integrasi Monte Carlo dan *machine learning* telah melampaui fase konseptual menuju penerapan praktis yang menawarkan nilai transformatif, meskipun disertai dengan tantangan operasional.

Daftar Pustaka

- Aven, T. (2016). Risk assessment and risk management: Review of recent advances on their foundation. *European Journal of Operational Research*, 253(1), 1-13. <https://doi.org/10.1016/j.ejor.2015.12.023>

- Boucher, C. M., Danielsson, J., Kouontchou, P. S., & Maillet, B. B. (2014). Risk models-at-risk. *Journal of Banking & Finance*, 44, 72-92. <https://doi.org/10.1016/j.jbankfin.2014.03.019>
- Coursera. (2025). VAE vs. GAN: What's the difference? <https://www.coursera.org/articles/vae-vs-gan?msocid=1ae2455d6f35617303d350bf6e346029>
- Czaronis, M., Kritzman, M., & Turkington, D. (2023). Relevance-based prediction: A transparent and adaptive alternative to machine learning. *The Journal of Financial Data Science*, 5(1), 27-46. <https://doi.org/10.3905/jfds.2022.1.110>
- Danielsson, J., Valenzuela, M., & Zer, I. (2018). Learning from history: Volatility and financial crises. *The Review of Financial Studies*, 31(7), 2774-2805. <https://doi.org/10.1093/rfs/hhy049>
- Gal, Y., & Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. *Proceedings of the 33rd International Conference on Machine Learning*, 48, 1050-1059.
- Glasserman, P. (2003). *Monte Carlo methods in financial engineering*. Springer Science & Business Media.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer Science & Business Media.
- Hopkin, P. (2018). *Fundamentals of risk management: Understanding, evaluating and implementing effective risk management*. Kogan Page Publishers.
- Jorion, P. (2007). *Value at risk: The new benchmark for managing financial risk* (3rd ed.). McGraw-Hill.
- Jospin, L. V., Laga, H., Boussaid, F., Buntine, W., & Bennamoun, M. (2022). Hands-on Bayesian neural networks—A tutorial for deep learning users. *IEEE Computational Intelligence Magazine*, 17(2), 29-48. <https://doi.org/10.1109/MCI.2022.3155327>
- Kaplan, R. S., & Mikes, A. (2012). Managing risks: A new framework. *Harvard Business Review*, 90(6), 48-60.
- McNeil, A. J., Frey, R., & Embrechts, P. (2015). *Quantitative risk management: Concepts, techniques and tools*. Princeton University Press.
- Noriega, J. P., Rivera, L. A., & Herrera, J. A. (2023). Machine learning for credit risk prediction: A systematic literature review. *Data*, 8(11), 8110169. <https://doi.org/10.3390/data8110169>
- Ruf, J., & Wang, W. (2020). Neural networks for option pricing and hedging: A literature review. *Journal of Computational Finance*, 24(1), 1-46. <https://doi.org/10.21314/JCF.2020.390>
- Selvaraj, A., Selvaraj, A., Venkatachalam, D. (2022). Generative Adversarial Networks (GANs) for syntehtic financial data generation: Enhancing risk modelling and fraud detection in banking and insurance. *Journal of Artificial Intelligence Research*, 2(1), 230-269.
- Shi, L., Pan, B., Chen, W., & Wang, Z. (2024). Deep Learning-based multifidelity surrogate modelling for high-dimensional reliability prediction. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems*, 10(3), 031106. <https://doi.org/10.1115/1.4065846>
- Taleb, N. N. (2007). *The Black Swan: The impact of the highly improbable*. Random House Publishing Group.
- Taleb, N. N. (2025). *Statistical consequences of fat tails: Real world preasymptotics, epistemology, and applications* (3rd. Ed). STEM Academic Press.
- World Economic Forum. (2023). *The global risks report 2023*. Geneva: WEF.
- Yu, Q., Zhang, Q., Cao, X., Zhang, T., He, J., Wang, R., & Ma, Z. (2023). A Bayesian deep learning method for credit card fraud detection with uncertainty quantification.

Proceedings of the Third International Seminar on Artificial Intelligence, Networking, and Information Technology (AINIT 2022), 1258728. <https://doi.org/10.1117/12.2667363>