

OPTIMASI STOCHASTIC GRADIENT DESCENT ADAPTIF UNTUK PREDIKSI OEE REAL-TIME PADA SISTEM PENGISIAN BOTOL ELEKTRONIK BERBASIS PLC

Hosea Okta Christanta¹, Ii Munadhif², Ryan Yudha Adhitya³, Noorman Rinanto⁴,
Muhammad Khoirul Hasin⁵, M. Alfin Rizki Nurhidayat⁶

^{1,2,3,4,5,6} Jurusan Teknik kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya
E-mail: iimunadhif.its@gmail.com

Abstract

This study develops an adaptive Stochastic Gradient Descent (SGD) optimization method for real-time Overall Equipment Effectiveness (OEE) prediction in industrial PLC-based electronic bottle filling systems. A neural network model was implemented using a dataset of 40,000 production samples with the format [operating_time, downtime, total_count, good_count, pressure, OEE]. Experimental results showed high accuracy ($R^2 = 0.9906$; MAE = 0.0076) with an inference time of 1.2 ms per cycle. Analysis revealed that good_count (59.41%) and system pressure (25.42%) are the dominant factors for OEE. The implementation of adaptive control increased production efficiency by 22.7% in a system with a 30L capacity and a speed of 4 bottles per minute

Keywords: *OEE prediction, bottle filling systems, SGD optimization, Omron CP2E, PLC integration*

PENDAHULUAN

Sistem pengisian botol elektronik merupakan komponen kritis dalam industri farmasi dan minuman, dengan toleransi pengisian $\pm 0,5$ ml sesuai standar ISO 22400. Fluktuasi OEE pada sistem ini disebabkan oleh dinamika parameter operasional seperti variasi tekanan pneumatik (6,0–8,5 bar) (Trentini et al., 2015) dan gangguan mekatronik (G, 2022) (Abashar et al., 2017). Analisis keterbatasan metode hybrid pada perangkat edge computing berdaya rendah. Berdasarkan studi yang telah dilakukan bahwa optimasi SGD machine learning (Xue et al., 2022) untuk predictive maintenance murni dengan teknik adaptif lebih efektif untuk embedded systems dibandingkan pendekatan konvensional (Susto et al., 2014) (Hesabi et al., 2022) (Yeganeh et al., 2023) (An Adaptive Gradient Method with Energy and Momentum, 2022). Namun, implementasinya pada PLC industri kelas dasar belum dieksplorasi secara mendalam

Pada penelitian ini adalah untuk mengembangkan model prediksi *Overall Equipment Effectiveness* (OEE) yang kompatibel dengan perangkat *Programmable Logic Controller* (PLC) industri dengan arsitektur minimalis dan efisien (Li et al., n.d.). Penelitian ini juga bertujuan mencapai tingkat akurasi prediksi lebih dari 98 persen dengan waktu inferensi kurang

^{1*} Penulis korespondensi


dari 5 milidetik agar dapat diterapkan dalam sistem kendali waktu nyata. Selain itu, penelitian ini ditujukan untuk mengidentifikasi parameter kontrol yang paling berpengaruh terhadap OEE melalui analisis kontribusi fitur, guna mendukung pengambilan keputusan yang lebih presisi dalam optimalisasi proses produksi (de Ron & Rooda, 2006).

METODE PENELITIAN

Metode penelitian ini menggunakan pendekatan eksperimental pada sistem pengisian botol elektronik berbasis PLC, dengan populasi penelitian berupa data produksi dan sampel sebanyak 40.000 data. Variabel yang diamati meliputi waktu operasional, waktu jeda, total produksi, produksi berkualitas, tekanan sistem, dan Overall Equipment Effectiveness (Santos, 2018) (OEE). Data didapatkan melalui sensor yang terhubung ke PLC untuk menggerakkan aktuator, dan analisis data dilakukan menggunakan model neural network yang dioptimalkan dengan SGD adaptif.

2.1 Konfigurasi Sistem Eksperimen

Sistem pengisian botol elektronik ini dirancang untuk menguji efisiensi kendali berbasis data dengan integrasi antara perangkat keras industri dan sistem pembelajaran mesin. Komponen utama meliputi PLC Omron CP2E-N30DR-A. Sensor yang digunakan terdiri atas transduser tekanan yang dari data mikrokontroler external dengan akurasi $\pm 0,1$ bar dan sensor fotoelektrik E3Z-T61 dengan resolusi 1 mm untuk mendeteksi keberadaan botol secara presisi. Aktuasi dilakukan melalui katup solenoid SMC VQZ215U-5G-C6 yang memiliki waktu respons 15 ms guna memastikan kecepatan reaksi terhadap sinyal kontrol. Sistem ini beroperasi dengan spesifikasi kapasitas tangki 30 liter dan kecepatan produksi sebesar 4 botol per menit, dengan tingkat akurasi pengisian mencapai $\pm 0,5$ ml. Semua proses pengendalian dan monitoring dilakukan dari server melalui protokol Modbus TCP yang mengakses PLC secara real-time. memungkinkan komunikasi data dua arah antara PLC dan server eksternal tempat algoritma dijalankan. Gambar 1 menunjukkan sistem pengisian botol elektronik berbasis PLC yang memiliki empat sensor yaitu sensor water level sensor untuk mengetahui level fluida di dalam botol, sensor photoelectric untuk mendeteksi objek, sensor pressure untuk mendeteksi tekanan fluida dari sumber, dan sensor load cell untuk mendeteksi berat fluida yang telah diisi. Sedangkan aktuatornya terdiri dari pneumatik valve, pneumatik gate, dan DC motor.



Gambar 1. Sistem Pengisian Botol Elektronik Berbasis PLC

2.2 Alur Pemrosesan Data

Pemrosesan data tidak dilakukan langsung di dalam PLC, melainkan dijalankan pada server eksternal yang mengakses data dari PLC melalui protokol Modbus TCP. Tahapan awal mencakup *preprocessing*, di mana data dinormalisasi menggunakan metode min-max scaling dengan rumus serta diberi tambahan gangguan *Gaussian noise* sebesar $\pm 0,05$ bar agar dapat mensimulasikan kondisi fluktuatif lapangan (Yu et al., 2019). Model pembelajaran mesin yang digunakan berupa jaringan saraf tiruan (neural network) tiga lapis dengan struktur 5-16-8-1, menghasilkan total 185 parameter dengan ukuran memori sekitar 0,8 KB. Fungsi aktivasi yang diterapkan adalah ReLU, dan proses pelatihan model menggunakan algoritma optimisasi SGD dengan momentum Nesterov (learning rate 0,005 dan momentum 0,85), serta pengaturan laju belajar adaptif melalui scheduler Reduce LR On Plateau. Ukuran *batch* ditetapkan sebanyak 8, disesuaikan dengan keterbatasan memori sistem. Untuk mengukur kesalahan prediksi, digunakan fungsi Mean Absolute Error (MAE) yang cocok untuk konteks industri karena toleransi terhadap kesalahan absolut lebih relevan dibandingkan kuadrat kesalahan. (Su et al., 2018)

HASIL DAN PEMBAHASAN

3.1 Implementasi Algoritma Kontrol Adaptif

Implementasi algoritma kontrol adaptif yang secara otomatis melakukan koreksi tekanan sebesar +0,1 bar ketika nilai predicted OEE berada di bawah 0,80 terbukti efektif berdasarkan hasil uji coba selama 4 siklus tank dengan kapasitas 30 liter dalam satu siklus dan 150 ml per botol pada set pengisian dengan kecepatan produksi 4 botol per menit. Intervensi ini menghasilkan peningkatan OEE signifikan dari 68,2% menjadi 83,7% serta penurunan jumlah botol cacat sebesar 29%. Selain itu, ditemukan bahwa rentang tekanan optimal berada pada kisaran 7,2–7,5 bar untuk mempertahankan OEE di atas 85%. Temuan ini menunjukkan bahwa pendekatan adaptif tidak hanya responsif terhadap kondisi proses, tetapi juga mampu meningkatkan efisiensi secara nyata dan terukur.

Tabel 1. Evaluasi Kinerja Model pada PLC Omron CP2E-N30DR-A

Metrik	Nilai	Batas PLC
R ²	0,9821	-
MAE	0,0093	-
Waktu Inferensi	1,2 ms	50 ms
Penggunaan Memori	1,8 MB	2 MB

Tabel 1 menunjukkan hasil evaluasi kinerja model pada PLC Omron CP2E-N30DR-A. Pada kolom nilai menunjukkan bahwa waktu inferensi dan penggunaan memori pada alat berada di bawah batas PLC sehingga hasil pembacaan bernilai valid.

3.2 Analisis Kontribusi Fitur

Analisis kontribusi fitur dilakukan untuk mengidentifikasi parameter yang paling berpengaruh terhadap prediksi nilai Overall Equipment Effectiveness (OEE). Hasil visualisasi pada Gambar 2 menunjukkan bahwa `good_count` memberikan kontribusi terbesar sebesar 59,41%, yang menegaskan bahwa aspek kualitas merupakan faktor dominan dalam perhitungan OEE. Parameter `pressure` menyumbang sebesar 25,42%, mencerminkan peran penting stabilitas tekanan dalam sistem pneumatik terhadap performa produksi (Trentini et al., 2015; Khayyati et al., 2021). Sementara itu, `operating_time` menunjukkan kontribusi nol, yang disebabkan oleh korelasi sangat tinggi dengan variabel `downtime` ($r = 0,998$), sehingga dianggap redundant dalam model. Temuan ini sejalan dengan formulasi dasar OEE, yaitu:

$$OEE = \frac{\text{Good Count} \times \text{Ideal Cycle Time}}{\text{Operating Time}}$$

(de Ron & Rooda, 2006), di mana parameter `good_count` secara langsung berada di bagian pembilang dan menjadi indikator utama efisiensi.

3.3 Analisis Konvergensi Model

Proses pelatihan model neural network menunjukkan pola konvergensi yang stabil, sebagaimana ditunjukkan pada Gambar 3. Konvergensi tercapai pada epoch ke-57, dengan nilai validation loss sebesar 0,00043 yang lebih rendah dibandingkan training loss sebesar 0,00142. Hal ini mengindikasikan bahwa model tidak mengalami overfitting dan mampu melakukan generalisasi dengan baik terhadap data baru. Selain itu, mekanisme penyesuaian laju pembelajaran (learning rate) secara otomatis aktif pada epoch ke-20, 30, dan 40 melalui strategi `ReduceLROnPlateau`, yang secara adaptif menurunkan learning rate ketika tidak terjadi peningkatan performa validasi. Kecepatan konvergensi model turut dipercepat oleh penggunaan momentum Nesterov dengan koefisien $\mu = 0,85$, yang terbukti efektif dalam mempercepat pembelajaran pada area gradien yang stabil (Duchi et al., 2011; Herrera-Alcántara, 2020; Iiduka, 2020). Temuan ini menunjukkan bahwa arsitektur dan strategi pelatihan yang digunakan telah dioptimalkan secara tepat untuk konteks sistem industri.

SIMPULAN

Model *Stochastic Gradient Descent* (SGD) adaptif dengan jumlah 185 parameter terbukti kompatibel dengan unit PLC Omron CP2E-E14SDR-A, dengan waktu inferensi rata-rata sebesar 1,2 milidetik atau 76 persen lebih cepat dibandingkan ambang batas waktu kritis yang dapat ditoleransi oleh PLC tersebut. Penerapan pengendalian tekanan secara waktu nyata mampu meningkatkan *Overall Equipment Effectiveness* (OEE) sebesar 22,7 persen melalui pengoptimalan titik setel tekanan pada kisaran 7,2 hingga 7,5 bar. Berdasarkan analisis kontribusi variabel terhadap OEE, ditemukan bahwa faktor yang paling dominan adalah jumlah produk baik (*good count*) sebesar 59,41 persen dan tekanan sistem sebesar 25,42 persen, sedangkan waktu operasi (*operating time*) dinyatakan redundan karena tidak memberikan pengaruh signifikan. Berdasarkan hasil tersebut dapat direkomendasikan beberapa arah pengembangan lanjutan, antara lain penghapusan fitur *operating time* untuk efisiensi komputasi, perluasan sistem ke lingkungan produksi multi-lini menggunakan pendekatan

federated learning, serta integrasi teknologi *digital twin* guna memungkinkan simulasi preskriptif terhadap dinamika proses sebelum diterapkan secara langsung pada sistem fisik.

DAFTAR PUSTAKA

Trentini, R., Campos, A., Espindola, G., & Silveira, A. da S. (2015). Parameter identification of a pneumatic proportional pressure valve. *Journal of The Brazilian Society of Mechanical Sciences and Engineering*. <https://doi.org/10.1007/S40430-014-0144-0>

G, L. (2022, December 28). *Cost Efficient Automatic Filling System for Differently Sized Bottles*. <https://doi.org/10.1109/ICMACC54824.2022.10093437>

Abashar, A. I., Mohammedeltoum, M. A., & Abaker, O. D. (2017, January 1). *Automated and monitored liquid filling system using PLC technology*. <https://doi.org/10.1109/ICCCCEE.2017.7866699>

Xue, F., Hai, Q., Dong, T., Cui, Z., & Gong, Y. (2022). A deep reinforcement learning based hybrid algorithm for efficient resource scheduling in edge computing environment. *Information Sciences*. <https://doi.org/10.1016/j.ins.2022.06.078>

Xie, W., Tang, W., & Kuang, Y. (2022). A new hybrid optimizer for stochastic optimization acceleration of deep neural networks: Dynamical system perspective. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2022.09.147>

Susto, G. A., Wan, J., Pampuri, S., Zanon, M., Johnston, A., O'Hara, P. G., & McLoone, S. (2014, October 30). An adaptive machine learning decision system for flexible predictive maintenance. *Conference on Automation Science and Engineering*. <https://doi.org/10.1109/COASE.2014.6899418>

Hesabi, H., Nourelfath, M., & Hajji, A. (2022). A deep learning predictive model for selective maintenance optimization. *Reliability Engineering & System Safety*. <https://doi.org/10.1016/J.RESS.2021.108191>

Yeganeh, S., Babazadeh Sangar, A., & Azizi, S. (2023). A novel Q-learning-based hybrid algorithm for the optimal offloading and scheduling in mobile edge computing environments. *Journal of Network and Computer Applications*. <https://doi.org/10.1016/j.jnca.2023.103617>

An Adaptive Gradient Method with Energy and Momentum. (2022). <https://doi.org/10.4208/aam.0a-2021-0095>

Li, D., Abhadiomhen, S. E., Zhou, D., Shen, X.-J., Shi, L., Cui, Y., & Abhadiomhen, S. E. (n.d.). *Asthma prediction via affinity graph enhanced classifier: a machine learning approach based on routine blood biomarkers*.

de Ron, A. J., & Rooda, J. E. (2006). OEE and equipment effectiveness: an evaluation. *International Journal of Production Research*.
<https://doi.org/10.1080/00207540600573402>

Santos, P. V. S. (2018). Aplicação do indicador overall equipment effectiveness (oeo): um estudo de caso numa retífica e oficina mecânica. *Brazilian Journal of Production Engineering - BJPE*.

Razavi, M., Ziyadidegan, S., Jahromi, R., Kazeminasab, S., Janfaza, V., Mahmoudzadeh, A., Baharlouei, E., & Sasangohar, F. (n.d.). *Machine Learning, Deep Learning and Data Preprocessing Techniques for Detection, Prediction, and Monitoring of Stress and Stress-related Mental Disorders: A Scoping Review*.

Uvarov, I. V., Melenev, A. E., Selyukov, R. V., & Svetovoy, V. B. (2020). Improving the performance of the fast electrochemical actuator. *Sensors and Actuators A-Physical*.
<https://doi.org/10.1016/J.SNA.2020.112346>

Aulia, D., Sar, R., Hidayat, C., Rivai, M., & Sarno, R. (n.d.). *Optimization of the Electronic Nose Sensor Array for Asthma Detection Based on Genetic Algorithm*.

Yu, L., Wu, W., He, G., & Yu, W. (2019). *Dynamic Variance Analysis of One-Dimensional Signal in Gaussian Noise Based on Recursive Formula*. https://doi.org/10.1007/978-3-030-34387-3_89

Chella, A., & Sorbello, F. (1992). *Fast Convergence of Neural Networks by Application of a New Min-Max Algorithm*. <https://doi.org/10.1016/B978-0-444-89488-5.50040-3>

Liu, C., & Belkin, M. (2020, April 30). Accelerating SGD with momentum for over-parameterized learning. *International Conference on Learning Representations*.

Zhou, K., Jin, Y., Ding, Q., & Cheng, J. (2020, August 27). Amortized Nesterov's Momentum: A Robust Momentum and Its Application to Deep Learning. *Uncertainty in Artificial Intelligence*.

Su, S., Wu, Y., & Qian, W. (2018, June 24). Efficient batch statistical error estimation for iterative multi-level approximate logic synthesis. *Design Automation Conference*.
<https://doi.org/10.1145/3195970.3196038>

Duchi, J., Hazan, E., & Singer, Y. (2011). Adaptive subgradient methods for online learning and stochastic optimization. *Journal of Machine Learning Research*, 12, 2121–2159.

Khayyati, S., Bobarshad, H., Liu, Z., & Wang, X. (2021). A lab-scale manufacturing system for data-driven production control. *Journal of Manufacturing Systems*, 60, 132–145.
<https://doi.org/10.1016/j.jmsy.2021.05.011>

Omron Corporation. (2023). CP2E CPU Unit Manual. Kyoto, Japan: Omron.

Trentini, R., Campos, A., Espindola, G., & Silveira, A. da S. (2015). Parameter identification of a pneumatic proportional pressure valve. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 37(3), 1047–1055. <https://doi.org/10.1007/s40430-014-0144-0>

de Ron, A. J., & Rooda, J. E. (2006). OEE and equipment effectiveness: An evaluation. *International Journal of Production Research*, 44(23), 4987–5006. <https://doi.org/10.1080/00207540600573402>

Herrera-Alcántara, O. (2020). Fractional-order gradient descent optimization. *Fractional Calculus and Applied Analysis*, 23(4), 1090–1105. <https://doi.org/10.1515/fca-2020-0056>

Iiduka, H. (2020). Appropriate learning rates of adaptive learning rate optimization algorithms. *arXiv preprint arXiv:2002.09647*. <https://doi.org/10.48550/arXiv.2002.09647>