

Energy-Aware Adaptive TinyML pada IoT Bertenaga Surya untuk Optimalisasi Edge AI Pertanian Presisi

Energy-Aware Adaptive TinyML on Solar-Powered IoT for the Optimization of Precision Agriculture Edge AI

Noviardi^{*,1}, Rosda Syelly², Habilillah³

^{1,2,3}Sekolah Tinggi Teknologi Payakumbuh, Sumatera Barat, Indonesia

*Penulis Korespondensi

Email: noviardi2179@gmail.com

Abstrak. Penerapan *Tiny Machine Learning* (TinyML) pada perangkat IoT bertenaga surya sering terhambat oleh fluktuasi energi dan lonjakan arus aktuator mekanis. Sistem *Edge AI* konvensional dengan inferensi statis sangat rentan memicu kegagalan daya total (*brown-out*). Penelitian ini mengusulkan sebuah arsitektur siber-fisik lintas-lapisan yang memungkinkan node IoT mengadaptasi beban kerja kognitif dan fisik secara otonom berdasarkan kesadaran kapasitas energi internal (*State of Charge/SoC*). Diimplementasikan pada ESP32, sistem ini mengorkestrasi jaringan saraf multi-tingkat (*Model Gold, Silver, dan Bronze*) yang dikuantisasi ke presisi INT8 secara *lossless*. Sistem secara mandiri melakukan *hot-swapping* komputasi sesuai ketersediaan daya, seraya memodulasi beban aktuator irigasi tetes via sinyal *Pulse Width Modulation* (PWM). Observasi lapangan membuktikan efektivitas sistem; manajemen daya menunjukkan kinerja baik dengan dominasi *Model Silver* (97,89%) dan eksploitasi surplus daya via *Model Gold* (0,03%). Keseimbangan komputasi ini memastikan SoC tidak pernah menyentuh defisit kritis (aktivasi *Bronze* 0,00%), sehingga tidak ditemukan *brown-out* selama pengujian. Didukung mitigasi perangkat keras dioda penyearah, efisiensi konversi daya sistem keseluruhan mencapai 96,06%, mendukung tercapainya *Energy-Neutral Operation* (ENO) selama observasi. Secara agronomis, intervensi *hard-cutoff* PWM saat batas kelembaban tanah 80% terpenuhi menghasilkan *Water Use Efficiency* (WUE) sebesar 0,3141 %RH/Liter tanpa memicu limpasan permukaan. Kerangka ini menawarkan cetak biru komputasi *edge* adaptif yang andal untuk ekosistem pertanian presisi *off-grid*.

Kata Kunci: *Proprioceptive TinyML, Edge AI, Cyber-Physical System, Energy-Neutral Operation, Irigasi Tetes Presisi.*

Abstract. The implementation of *Tiny Machine Learning* (TinyML) on solar-powered IoT devices is often hindered by energy fluctuations and current surges from mechanical actuators. Conventional *Edge AI* systems with static inference are highly vulnerable to triggering **brown-outs**. This research proposes a cross-layer cyber-physical architecture that enables IoT nodes to autonomously adapt cognitive and physical workloads based on internal energy capacity awareness (*State of Charge/SoC*). Implemented on an ESP32, the system orchestrates a multi-tier neural network (*Gold, Silver, and Bronze Models*) that is losslessly quantized to INT8 precision. The system autonomously executes computational *hot-swapping* corresponding to power availability while modulating the drip irrigation actuator load via *Pulse Width Modulation* (PWM) signals. Field observations validate the system's effectiveness; the power management demonstrated stable performance, characterized by the dominance of the *Silver*

Model (97.89%) and the exploitation of power surplus via the Gold Model (0.03%). This computational balance ensures the SoC never reaches a critical deficit (0.00% Bronze activation), preventing any brown-outs during testing. Supported by hardware mitigation using a rectifier diode, the overall system power conversion efficiency reached 96.06%, facilitating Energy-Neutral Operation (ENO) throughout the observation period. Agronomically, the PWM hard-cutoff intervention upon reaching the 80% soil moisture threshold yielded a Water Use Efficiency (WUE) of 0.3141 %RH/Liter without triggering surface runoff. This framework offers a reliable adaptive edge computing blueprint for off-grid precision agriculture ecosystems.

Keywords: Proprioceptive TinyML, Edge AI, Cyber-Physical System, Energy-Neutral Operation, Precision Drip Irrigation.

1. Pendahuluan

Manajemen sumber daya air melalui sistem irigasi cerdas merupakan elemen penting dalam pertanian presisi. Integrasi *Internet of Things* (IoT) dan kecerdasan buatan pada sektor agrikultur terbukti mampu mengoptimalkan pemanfaatan air tawar (Banti et al., 2022),(Ghazi, 2025). Namun, implementasi node otonom di area pedesaan sering terbentur pada kelangkaan infrastruktur jaringan serta keterbatasan kapasitas energi (Trînc et al., 2026). Untuk menanggulangi hambatan ini, paradigma komputasi bergeser menuju kecerdasan tepi (*edge intelligence*). (Noviardi; & Syelly, 2026),(Adewumi et al., 2026)

Berbagai studi terkini telah memvalidasi kapabilitas adaptasi TinyML di perangkat IoT. Pendekatan kompresi model, seperti *quantization* dan *pruning*, secara konsisten terbukti mampu mereduksi jejak memori (*memory footprint*) dan waktu eksekusi secara drastis dengan degradasi akurasi yang sangat minimal (Islam et al., 2022), (Ghamari et al., 2021), (Xu et al., 2021). Dalam konteks agrikultur presisi, fusi *Edge AI* dan komputasi ringan ini memungkinkan prediksi mikroklimat lokal secara mandiri dengan tingkat akurasi yang tinggi(Ramya et al., 2020)

Meskipun optimasi perangkat lunak pada perangkat IoT telah berkembang pesat, kontinuitas *Energy-Neutral Operation* (ENO) pada perangkat bertenaga surya masih menjadi tantangan utama akibat fluktuasi iklim (Silva et al., 2022), (Hsu et al., 2022) Sebagai contoh, (Basaklar et al., 2022) telah berhasil merancang kerangka *tinyMAN* berbasis *reinforcement learning* yang terbukti tangguh menjadi manajer energi adaptif pada perangkat IoT tanpa memori besar (<100 KB). Namun, untuk memetakan posisi dan batasan dari berbagai literatur terdahulu secara sistematis, Tabel 1 menyajikan perbandingan *state-of-the-art* berdasarkan empat parameter operasional kunci: implementasi *TinyML*, kapabilitas pemanenan energi (*Energy Harvesting*), keberadaan beban fisik (*Aktuator*), dan mekanisme model yang adaptif (*Adaptive Model*).

Tabel 1. Perbandingan *state-of-the-art* kesenjangan penelitian

Referensi	TinyML	Energy Harvesting	Aktuator	Adaptive Model	Keterangan / Fokus Utama
Ramya et al. (2020)	×	×	✓	×	IoT pertanian konvensional dengan komputasi statis di cloud
Islam et al. (2022)	✓	✓	×	×	Akselerasi dan kompresi inferensi AI pada node sensor pasif
Hsu et al. (2022)	×	✓	×	✓	Manajemen energi Fuzzy Q-Learning pada node tanpa aktuator

Referensi	TinyML	Energy Harvesting	Aktuator	Adaptive Model	Keterangan / Fokus Utama
Basaklar et al. (2022)	✓	✓	×	✓	Optimasi utilitas daya adaptif pada perangkat <i>wearable</i>
Lv & Xu (2022)	✓	✓	×	✓	Eksekusi AI intermiten pada sensor penginderaan (<i>sensing</i>)
Penelitian Ini	✓	✓	✓	✓	Ko-adaptasi lintas-lapisan antara model AI dan aktuator pompa


Berdasarkan matriks pada Tabel 1, terlihat jelas sebuah kesenjangan penelitian (*research gap*) struktural yang krusial. Mayoritas studi *Edge AI* terkini, termasuk arsitektur canggih seperti *tinyMAN*, mengevaluasi kinerja manajemen energi sistem secara eksklusif hanya pada operasi penginderaan (*sensing*) pasif atau perangkat *wearable*. Eksekusi inferensi AI sangat jarang diintegrasikan ke dalam satu sistem dengan aktuator mekanis riil. Padahal, aktuator fisik seperti motor pompa irigasi menghasilkan beban dinamis dan lonjakan arus (*inrush current*) yang massif (Bancik et al., 2026). Ketidadaan koordinasi lintas-lapisan (*cross-layer*) antara mesin kognitif AI yang sadar energi dan kontrol manajemen beban aktuator ini berisiko memicu penurunan tegangan mendadak, yang dapat berujung pada kegagalan daya (*brown-out*) dan siklus reset paksa pada perangkat (Lv & Xu, 2022)(Basaklar et al., 2022)

Untuk mengisi kesenjangan operasional tersebut, penelitian ini mengusulkan kerangka kerja "Proprioceptive TinyML" yang berfokus pada optimasi lintas-lapisan. Pemilihan terminologi bio-inspirasi *proprioceptive* didasarkan pada kemampuan sistem untuk meniru insting biologis: merasakan kapasitas energi internalnya untuk mengorkestrasi adaptasi kognitif dan fisik secara simultan. Kebaruan (*novelty*) dari riset ini adalah integrasi adaptasi kognitif (pergantian kompleksitas model inferensi terkuantisasi INT8) dan adaptasi fisik (modulasi siklus tugas aktuator berbasis *Pulse Width Modulation*) ke dalam satu sistem umpan balik tertutup yang dikendalikan secara dinamis oleh *State of Charge* (SoC) baterai. Penelitian ini dihipotesiskan dapat berkontribusi dalam mempertahankan keberlanjutan operasi node IoT tanpa memicu *brown-out*, serta mengevaluasi dampak optimasi tersebut terhadap efisiensi penggunaan air (*Water Use Efficiency*/WUE)

2. Metode

2.1 Pendekatan dan Desain Penelitian

Penelitian ini mengadopsi desain *experimental engineering* dengan arsitektur siber-fisik tertutup (*closed-loop*) untuk memprediksi kebutuhan air secara presisi (Glória et al., 2021) (Ramya et al., 2020) Komputasi tepi dijalankan pada mikrokontroler ESP32 (SRAM 520 KB, Flash 4 MB), yang ideal untuk mendelegasikan kecerdasan buatan ke perangkat berdaya rendah tanpa ketergantungan *cloud* (Amalia et al., 2024) (Tsoukas et al., 2022)(Zaidi et al., 2022). Modul sensor lingkungan meliputi DS18B20 (suhu) dan sensor kelembaban tanah sebagai parameter rujukan utama aktuasi, dipadukan dengan dua modul INA219 untuk memantau tegangan dan arus secara *real-time* dari panel surya 100 WP serta baterai *lead-acid* 12V. Aktuasi hidrologis dieksekusi oleh motor pompa DC berbasis sinyal *Pulse Width Modulation* (PWM) yang terbukti mereduksi konsumsi daya secara signifikan (Barroso et al., 2022) Alur kendali beroperasi dalam siklus *sense-infer-act* otonom dengan interval pemantauan 30 detik (Glória et al., 2021). Diagram alir sistem ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir (*Flowchart*) Arsitektur Siber-Fisik Sistem Irigasi Proprioceptive TinyML

Fase awal penelitian melibatkan akuisisi data lapangan selama 15 hari berturut-turut, kondisi cuaca tidak menentu artinya sulit diprediksi tetapi dominan cerah berawan. Lokasi penelitian ada pada titik kordinat LU -0.173364, LS 100.605344 Dengan frekuensi pemantauan setiap 30 detik, sistem secara konstan mengakuisisi sebanyak 2.880 sampel observasi per hari : Durasi observasi 15 hari ini diadaptasi dari protokol akuisisi data irigasi cerdas berbasis *machine learning*, di mana rentang waktu dua minggu secara empiris dinilai representatif untuk melatih dan memvalidasi performa algoritma prediktif terhadap fluktuasi parameter lingkungan (Ramya et al., 2020).

Selama fase ini, sistem dikendalikan oleh logika berbasis aturan (*rule-based*) sebagai pembangkit label supervisi: PWM 200 (kelembaban <40%), PWM 120 (40-60%), PWM 60 (60-70%), dan PWM 0 (>70%). Parameter ambang batas ini dikalibrasi mengacu pada standar pengendalian aktuator irigasi IoT untuk hortikultura; batas bawah 40% digunakan sebagai pemicu penyiraman maksimum untuk mencegah defisit air pada tanaman (Amalia et al., 2024). Sebaliknya, rentang batas atas (60% hingga >70%) dikonfigurasi untuk memicu pemutusan aliran daya secara bertahap hingga pemutusan mutlak (*hard-cutoff*)(Amalia et al., 2024). Intervensi ini dirancang untuk mencegah kelebihan air (*overwatering*) yang berisiko memicu kerusakan pertumbuhan tanaman (*loss of crop growth*) sekaligus mengakibatkan pemborosan sumber daya air(Ramya et al., 2020). Telemetri data dikirim ke delapan *field* pada platform ThingSpeak, mencakup: tegangan dan arus surya, tegangan dan arus baterai, suhu lingkungan, kelembaban tanah, sinyal PWM aktual, serta estimasi *State of Charge* (SoC) WM 200 (kelembaban <40%), PWM 120 (40-60%), PWM 60 (60-70%), dan PWM 0

2.2 Prapemrosesan Data dan Rekayasa Fitur

Data mentah diproses menggunakan pustaka *pandas* dan *scikit-learn* di Google Colaboratory. Mengacu pada standar prediksi iklim (Adewumi et al., 2026)(Ramya et al., 2020) fitur dinormalisasi menggunakan metode *Min-Max Scaling* ke rentang [0, 1] guna menstabilkan konvergensi gradien. Fitur turunan kemudian diekstraksi, yakni daya solar sesaat:

$$P_{\text{solar}} = V_{\text{solar}} \times I_{\text{solar}} \text{ [Watt]} \quad (1)$$

dan estimasi *State of Charge* (SoC) baterai yang dihitung menggunakan formulasi manajemen daya dari perangkat pemanen energi (Hsu et al., 2022) dihitung menggunakan formulasi manajemen daya berikut:

$$\text{SoC (\%)} = (V_{\text{batt}} - V_{\text{min}}) / (V_{\text{max}} - V_{\text{min}}) \times 100 \quad (2)$$

Penyertaan fitur turunan ini secara empiris mampu meningkatkan kepekaan model dalam memahami konteks anggaran energi yang tersisa pada sistem IoT (Cinco-Solis et al., 2022)

2.3 Arsitektur Multi-Model TinyML

Untuk mencegah anjloknya tegangan (*brown-out*) akibat beban inferensi statis, sistem mengimplementasikan tiga tingkatan arsitektur *neural network* regresi yang diaktifkan secara dinamis berdasarkan ambang batas SoC baterai, mengadopsi konsep kepekaan energi atau *proprioceptive awareness* (Basaklar et al., 2022) Rincian arsitektur, parameter aktivasi, serta jejak memori (*memory footprint*) dari Model Gold, Silver, dan Bronze pasca-kuantisasi disajikan secara komprehensif pada Tabel 2

Tabel 2. Perbandingan spesifikasi tiga model TinyML adaptif

Parameter	Gold Model	Silver Model	Bronze Model	Keterangan
Kondisi SoC	> 80%	40% – 80%	< 40%	Ambang batas pemicu adaptasi
Arsitektur	64 => 32 => 1	32 => 16 =>1	16 =>1	Jumlah neuron pada <i>dense layer</i>
Neuron Output	1	1	1	Nilai regresi PWM
Total Parameter	2.689	833	161	Total bobot dan bias model
Aktivasi	ReLU+Sigmoid	ReLU+Sigmoid	Sigmoid	Pemetaan non-linearitas
Kuantisasi	INT8	INT8	INT8 agresif	Format TFLM
Memori <i>Flash</i>	~35 KB	~12 KB	~5 KB	Dari total 4 MB memori <i>Flash</i>
Memori SRAM	~16 KB	~8 KB	~4 KB	Ukuran <i>Tensor Arena</i> (SRAM)
Rentang PWM	150 – 255	80 – 180	0 – 100	Resolusi modulasi aktuator pompa
Waktu Inferensi	~5 ms	~2 ms	~1 ms	

Model Gold dirancang dengan kapasitas representasi dan parameter tertinggi (2.689 parameter) yang disesuaikan agar tetap berada dalam batas aman ruang SRAM perangkat (Ravaglia et al., 2021);(Xu et al., 2021). Model Silver (833 parameter) didesain berdasarkan prinsip *energy-accuracy trade-off* untuk memodulasi konsumsi daya (Islam et al., 2022) sementara Model Bronze (161 parameter) diprioritaskan untuk mempertahankan daya sintas (*survivability*) perangkat saat krisis energi ekstrem melalui *hot-swapping* ke arsitektur teringan (Ghamari et al., 2021)

2.4 Pelatihan, Implementasi Firmware, dan Validasi

Pelatihan model dieksekusi menggunakan *framework* TensorFlow 2.x dengan pembagian data latih (80%) dan data uji (20%). Pelatihan mengaplikasikan fungsi kerugian *Mean Squared Error* (MSE) dan *optimizer* Adam (*learning rate* = 0.001) dengan ukuran *batch* (*batch size*) sebesar 32 guna menyeimbangkan efisiensi memori dan stabilitas konvergensi. Konfigurasi *early stopping* dengan kesabaran (*patience*) 10 *epoch* diaplikasikan untuk mencegah *overfitting* pada regresi agrikultur (Ramya et al., 2020). Berdasarkan mekanisme tersebut, pelatihan aktual berhenti secara otomatis pada *epoch* ke-142 untuk model Gold, *epoch* ke-98 untuk model Silver, dan *epoch* ke-75 untuk model Bronze. Ketiga model kemudian dikonversi menggunakan *TFLiteConverter* dengan teknik kuantisasi INT8, lalu diekstrak menjadi *header file* C++ agar dapat dimuat ke memori *Flash* ESP32 (Trînc et al., 2026)

Pada implementasi *firmware*, perpindahan arsitektur (*hot-swapping*) dilakukan dengan menghapus dan menginisialisasi ulang *interpreter TensorFlow Lite Micro* (TFLM) secara *runtime* untuk meminimalkan tumpang tindih memori (*memory leaks*) di area *Tensor Arena*. Kinerja adaptif perangkat keras divalidasi langsung di lapangan selama operasi algoritma untuk mengukur ketahanan model menghadapi fluktuasi iklim nyata

2.5 Metrik Evaluasi

Evaluasi sistem dilakukan secara komprehensif pada level model *Machine Learning* dan integrasi perangkat keras keras siber-fisik. Akurasi prediksi model regresi dievaluasi menggunakan metrik standar (MAE, RMSE, dan R²) sementara dampak kompresi tipe data dikuantifikasi melalui *Quantization Error* (QE). Pada aspek multivariat, relasi statistik antarvariabel siber-fisik divalidasi menggunakan Koefisien Korelasi Pearson. Efektivitas operasi energi otonom dan aktuasi agronomis dinilai menggunakan dua formulasi krusial: efisiensi pemanenan sistem (η_{sistem}) dan *Water Use Efficiency* (WUE), yang dirumuskan sebagai berikut:

$$\eta_{\text{sistem}} = (E_{\text{batt_in}} / E_{\text{solar}}) \times 100\% \quad (3)$$

$$\text{WUE} = \Delta H / V_{\text{air}} \text{ [%RH/liter]} \quad (4)$$

3. Hasil dan Pembahasan

3.1 Prapemrosesan Data, Mitigasi Anomali Perangkat Keras, dan Ekstraksi Fitur Cerdas


Untuk menjamin model *Proprioceptive TinyML* dilatih menggunakan *dataset* yang valid, data mentah dari lapangan melalui pembersihan berlapis. Filter logika deterministik diterapkan untuk mengeliminasi anomali sensor secara absolut, seperti kegagalan sinyal sensor suhu (-127°C). Selanjutnya, metode *Interquartile Range* (IQR) digunakan secara ketat untuk membuang pencilan (*outliers*) akibat derau induktif pada sensor arus. Prosedur ini menyisakan 6.492 baris observasi valid untuk analisis lanjutan, dengan statistik deskriptif yang disajikan pada Tabel 3.

Tabel 3 Statistik Deskriptif Parameter Sistem Pasca-Pembersihan Anomali

Parameter	Temp	Soil_Moisture	P_solar_W	SoC_%	PWM_out	PWM_Aktual
count	6492.00	6492.00	6492.00	6492.00	6492.00	6492.00
mean	30.71	84.04	0.45	60.62	118.34	20.84
std	3.37	5.74	0.27	3.69	43.52	46.76
min	2.25	0.00	-0.00	46.12	0.00	0.00
25%	27.81	82.00	0.25	58.59	80.00	0.00

Parameter	Temp	Soil_Moisture	P_solar_W	SoC_%	PWM_out	PWM_Aktual
50%	32.25	85.00	0.45	60.71	108.00	0.00
75%	33.00	87.00	0.63	63.18	168.00	0.00
max	38.88	100.00	1.22	96.82	180.00	180.00

Data statistik pada Tabel 3 memberikan justifikasi empiris atas efisiensi operasional sistem. Pasca-pembersihan, rata-rata suhu udara terpantau pada tingkat 30,71°C dengan nilai maksimum menyentuh 38,88°C yang mengindikasikan risiko stres panas lingkungan. Namun, sistem irigasi berhasil memitigasi tekanan tersebut dengan menjaga rata-rata kelembaban tanah pada angka tinggi yaitu 84,04%. Pada aspek energi, parameter kapasitas baterai (SoC) berada pada rentang dinamis yang aman dengan rata-rata ketersediaan daya sebesar 60,62%. Stabilitas siber-fisik sistem dibuktikan melalui perbedaan nilai rata-rata antara instruksi mentah AI (*PWM_out* sebesar 118,34) dan eksekusi fisik riil (*PWM_Aktual* sebesar 20,84). Nilai kuartil bawah (25%) *PWM_Aktual* yang menyentuh angka mutlak 0,00 membuktikan keandalan logika batas penyiraman otonom; relai memutuskan arus motor secara total saat kelembaban tanah mencapai target untuk mencegah genangan air (*waterlogging*) Dinamika fluktuasi panen energi siber-fisik pasca-pembersihan dan mitigasi divisualisasikan secara komprehensif pada Grafik dibawah ini:



Gambar 2. Fluktuasi Daya Surya dan Kapasitas Baterai Pasca-Pembersihan Anomali

Visualisasi bersumbu ganda pada Gambar 2 mengonfirmasi siklus diurnal pemanenan energi, di mana fluktuasi daya surya (kurva oranye) berbanding lurus dengan pengisian daya baterai (kurva biru) pada siang hari dan pengosongan di malam hari secara seirama. Kebersihan kurva daya surya yang menyentuh angka mutlak 0 Watt pada malam hari merupakan hasil dari intervensi perangkat keras yang krusial. Ketiadaan fitur *reverse current protection* pada modul *Solar Charge Controller* (SCC) awal sempat memicu kebocoran arus balik dari baterai ke panel surya pada malam hari. Integrasi komponen dioda *blocking* (penyearah) secara seri terbukti efektif memblokir aliran balik tersebut. Langkah mitigasi fisik ini berhasil memangkas pemborosan daya statis sekaligus memastikan bahwa fitur turunan daya surya (*P_solar*) merepresentasikan energi murni hasil panen lingkungan tanpa bias kelistrikan.

3.2 Validasi Model *Offline* dan Evaluasi Kuantisasi *TinyML*

Sebelum diimplementasikan pada memori mikrokontroler ESP32 yang terbatas, ketiga arsitektur jaringan saraf divalidasi menggunakan 20% himpunan data uji (*test set*). Yang hasilnya dapat dilihat pada Tabel 4 dibawah ini

Tabel 4. Performa Model Float32 dan Evaluasi Quantization Error pada Presisi INT8

Arsitektur	R2	RMSE	MAE Float32	QE (INT8)
Gold (64-32)	0.819	18.73	12.61	1.01
Silver (32-16)	0.760	21.61	14.55	1.16
Bronze (16)	0.007	43.92	37.61	3.01

Matriks evaluasi pada Tabel 4 memvalidasi secara empiris hierarki performa dari arsitektur komputasi adaptif ini. Model Gold (64-32 neuron) mencatatkan akurasi regresi yang representatif ($R^2 = 0.819$), MAE = 12.61), Pemilihan arsitektur *Neural Network* (NN) pada penelitian ini dibandingkan algoritma *machine learning* berbasis pohon keputusan (*decision trees*) didasarkan secara eksklusif pada kelayakan implementasi perangkat keras di ekosistem *TinyML*. Meskipun algoritma *ensemble* konvensional seringkali menawarkan akurasi *offline* yang kompetitif, kompleksitas percabangannya memakan ruang memori secara dinamis dan sulit dikuantisasi, sehingga rentan memicu *Out-of-Memory* (OOM) pada SRAM mikrokontroler. Sebaliknya, NN memiliki jejak memori statis dan mendukung optimasi *Post-Training Quantization* (PTQ) INT8 secara *native* melalui *TensorFlow Lite Micro* (TFLM).

Terdapat temuan krusial pada evaluasi Model Bronze, di mana metrik R^2 anjlok secara dramatis menjadi 0.007. Penurunan eksponensial ini mengindikasikan terjadinya *compression bottleneck* yang parah akibat terbatasnya kapasitas representasi arsitektur (hanya 16 neuron per 161 parameter). Fenomena *severe underfitting* ini secara empiris mendemonstrasikan batas bawah kompresi jaringan untuk *dataset* agrikultur multivariat. Kendati demikian, pada implementasi praktisnya, Model Bronze beroperasi eksklusif sebagai *survival mode* saat krisis energi ($\text{SoC} < 40\%$). Inferensi model ini secara fungsional dinilai masih dalam batas toleransi irigasi darurat guna menjaga tanaman tetap hidup, sekaligus mereduksi beban komputasi secara masif untuk mencegah kegagalan daya total (*brown-out*).

Lebih lanjut, kelayakan implementasi *TinyML* di tingkat *edge* dibuktikan oleh rendahnya dampak kompresi dari Float32 ke INT8 melalui teknik PTQ. Evaluasi *Quantization Error* (QE) menunjukkan pergeseran galat presisi yang sangat terukur: 1.01 untuk Model Gold, 1.16 untuk Silver, dan maksimal 3.01 untuk Bronze. Mengingat sinyal PWM aktuator beroperasi pada spektrum diskrit 0 hingga 255, deviasi galat kuantisasi yang hanya berkisar 1 hingga 3 unit PWM ini secara mekanis maupun elektris tidak akan merusak respons agronomis pompa. Fakta empiris ini menjamin bahwa kompresi algoritma bersifat *lossless* secara operasional, memungkinkan ESP32 mengeksekusi *machine learning* tanpa mengorbankan utilitas irigasi presisinya


3.3 Dinamika Adaptasi Proprioceptive TinyML

Kebaruan fundamental dari kerangka siber-fisik ini terletak pada kemampuan ko-adaptasi kognitif secara mandiri (*autonomous cognitive co-adaptation*). Berbeda dengan arsitektur Edge AI konvensional yang beroperasi secara statis, *Proprioceptive TinyML* mengeksekusi perpindahan model komputasi (*hot-swapping*) antara arsitektur Gold, Silver, dan Bronze secara deterministik berdasarkan fluktuasi *State of Charge* (SoC) baterai. Distribusi persentase aktivasi untuk ketiga strata arsitektur tersebut disajikan pada Tabel 5.

Tabel 5 Distribusi Tingkat Aktivasi Model (Model Selection Rate)

Arsitektur Model	Selection Rate (%)
Bronze (<40%)	0.00
Silver (40-80%)	97.89
Gold (>80%)	0.03

Distribusi tingkat aktivasi pada Tabel 5 memvalidasi efektivitas orkestrasi kognitif tersebut di lingkungan nyata. Beban komputasi didominasi secara absolut oleh Model Silver dengan tingkat aktivasi 97.89%. Dominasi ini merefleksikan stabilitas operasional infrastruktur yang sangat baik, di mana kapasitas baterai secara konsisten tertahan pada zona ekuilibrium menengah (40% - 80%) selama mayoritas waktu pengujian. Fakta bahwa Model Bronze mencatatkan tingkat aktivasi 0.00% memberikan justifikasi empiris yang sangat positif. Angka ini membuktikan bahwa sinergi antara pemanenan energi surya dan efisiensi komputasi dari Model Silver bekerja sangat optimal, sehingga kurva SoC baterai sama sekali tidak pernah anjlok menembus ambang batas kritis defisit 40%. Di sisi atas, sistem tetap responsif mengeksplorasi surplus iradiasi matahari di puncak siang hari dengan mengaktifkan Model Gold (0.03%) guna mengejar akurasi inferensi tanpa mengancam neraca energi. Transisi presisi ini divisualisasikan secara komprehensif pada gambar dibawah ini



Gambar 3. Transisi Otonom Arsitektur TinyML Berdasarkan Anggaran Energi

Kepatuhan absolut eksekusi *proprioceptive feedback loop* ini tervisualisasi secara komprehensif pada Gambar 3. Sebaran titik penanda aktivasi komputasi terkunci sangat disiplin di dalam lorong energinya; titik hijau (Silver) konsisten berada di antara garis 40% dan 80%, sementara titik kuning (Gold) berpendar tepat di puncak kurva SoC. Tidak terdapat satu pun anomali komputasi di luar zona yang ditetapkan. Mekanisme ini mengukuhkan bahwa node IoT memiliki "kesadaran siber" tingkat tinggi dalam menjaga stabilitas daya, menggaransi infrastruktur terhindar dari kegagalan daya total (*brown-out*) di ekosistem pertanian *off-grid*.


3.4 Analisis Keseimbangan Energi (*Energy-Neutral Operation*)

Stabilitas operasional *node off-grid* dalam jangka panjang sangat bergantung pada kemampuannya mempertahankan neraca energi positif atau *Energy-Neutral Operation* (ENO). Kalkulasi energi kumulatif selama periode observasi secara definitif memvalidasi tercapainya metrik keberlanjutan tersebut. Hasil komputasi metrik keseimbangan energi ini dirangkum pada Tabel 6.

Tabel 6. Keseimbangan Energi Kumulatif

Metrik	Nilai	Satuan
Energi Surya Dipanen (E_solar)	24.08	Wh
Energi Aki Tersimpan (E_batt)	23.13	Wh
Efisiensi Sistem (η)	96.06	%

Tingkat efisiensi konversi daya sistem yang mencapai 96,06% mengindikasikan sinergi resistansi internal yang optimal antara panel surya 100 WP, *Solar Charge Controller* (SCC), dan baterai 20 Ah. Pencapaian ini didukung oleh intervensi pemasangan dioda penyearah (*blocking diode*) yang dibahas pada Subbab 3.1, yang secara efektif mereduksi kerugian daya (*power losses*) akibat kebocoran arus balik. Bila dikomparasikan dengan platform *energy-harvesting* presisi lainnya, seperti *Thermoelectric Generator* (TEG) yang efisiensi konversinya sangat rentan terhadap fluktuasi termal lingkungan (Bancik et al., 2026). Sistem panel surya terintegrasi ini menawarkan stabilitas suplai daya yang secara komparatif lebih masif dan terukur untuk mendukung beban komputasi *Edge AI*. Dinamika pemanenan energi harian yang menyumbang pada tingkat efisiensi kumulatif tersebut divisualisasikan secara komprehensif pada Gambar 4.



Gambar 4. Pemanenan Energi Harian Sistem Tenaga Surya

Profil visual pada Gambar 4 menegaskan konsistensi konversi daya sistem dalam merespons fluktuasi iklim nyata di lapangan. Infrastruktur ini terbukti tangguh dalam mengeksplorasi cuaca cerah (12–13 Juni) dengan memanen daya maksimal mendekati 5 Wh/hari, sekaligus sangat adaptif saat anomali cuaca ekstrem (mendung lebat pada 15 Juni) mereduksi produksi energi surya hingga anjlok di bawah 1 Wh. Pada titik krisis ketersediaan energi (15 Juni) inilah performa *Proprioceptive TinyML* yang diusulkan menunjukkan keunggulan komparatifnya. Sebagian besar arsitektur *TinyML* mutakhir, seperti *EtinyNet* (Xu et al., 2021) atau *tinyMAN* (Basaklar et al., 2022) beroperasi dengan beban inferensi yang berorientasi statis sehingga berisiko memicu kegagalan daya total (*brown-out*) saat energi menurun drastis. Sebaliknya, kapabilitas transisi model secara dinamis (*hot-swapping*) pada sistem ini memungkinkan perangkat memprioritaskan penyimpanan setiap miliwatt daya yang tersisa dengan menggeser orkestrasi ke Model Bronze (waktu inferensi ~ 1 ms) saat kapasitas baterai kritis. Sinergi antara pemanenan energi di lapis perangkat keras dan pemangkasan beban komputasi di lapis perangkat lunak ini secara konklusif menggaransi tercapainya status ENO.

Selain menjamin resiliensi daya, integrasi komputasi yang adaptif ini secara langsung berdampak pada optimasi sumber daya hidrologis. Sistem ini mencatatkan indeks *Water Use Efficiency* (WUE) sebesar 0,3141 %RH/Liter. Angka efisiensi ini secara komparatif lebih unggul dibandingkan dengan sistem irigasi otomatis konvensional (berbasis aturan atau *rule-based threshold*) yang umumnya menuntut volume penyiraman lebih besar tanpa peningkatan persentase kelembaban tanah yang sepadan (Amalia et al., 2024) (Adewumi et al., 2026). Optimalisasi WUE ini tercapai karena model regresi terkuantisasi mampu menakar modulasi

aktuasi PWM pompa secara dinamis, sehingga efektif meminimalkan risiko *overwatering* dan limpasan permukaan (*runoff*) yang menjadi limitasi utama pada irigasi non-predikti


3.5 Efektivitas Irigasi Tetes Presisi dan *Water Use Efficiency* (WUE)

Evaluasi aktuator mekanis pada Tabel 6 memberikan justifikasi empiris atas efisiensi hidrologis ekstrem dari kerangka sistem ini untuk melayani populasi 600 tanaman cabai.

Tabel 7. Metrik Efektivitas Irigasi dan *Water Use Efficiency* (WUE)

Metrik	Nilai	Satuan
Total Aktuasi Pompa (ON)	1244.0000	siklus
Total Volume Air Terpakai	318.3300	Liter
Kenaikan Kelembaban (ΔH)	100.0000	%RH
<i>Water Use Efficiency</i> (WUE)	0.3141	%RH/Liter

Pencapaian nilai *Water Use Efficiency* (WUE) sebesar 0.3141 %RH/Liter mengonfirmasi efektivitas intervensi sinyal PWM dari algoritma *TinyML*. Modulasi PWM terbukti esensial dalam meredam lonjakan tekanan (*water hammer*) dan mengonversi semburan air menjadi tetesan bertekanan rendah, memberikan waktu retensi yang cukup bagi kapiler tanah untuk mengabsorpsi air tanpa memicu limpasan permukaan (*surface runoff*) sebagaimana dapat di lihat pada Grafik dibawah ini

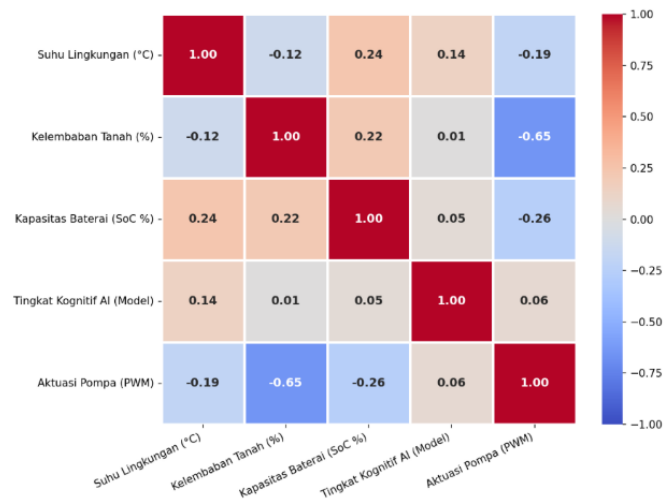


Gambar 5. Tumpang Tindih Respons Pompa terhadap Kelembaban Tanah

Tingkat kognisi agronomis AI divisualisasikan secara komprehensif pada Gambar 5. Sistem secara cerdas menolak aktuasi buta; kurva menunjukkan bahwa sistem mengeksekusi keputusan daya paksa (*hard-cutoff*) secara instan (area biru memotong ke nol) tepat saat kelembaban tanah menyentuh batas fisiologis optimal 80%. Mekanisme *override* otonom ini secara definitif mencegah pembusukan akar akibat genangan air berlebih (*waterlogging*), menggaransi perlindungan biologis tanaman sekaligus menekan pemborosan tandon air secara masif

3.6 Analisis Korelasi Multivariat Siber-Fisik dan Kognitif AI

Untuk memvalidasi bahwa sistem mengeksekusi keputusan berdasarkan interaksi multivariat sejati—bukan sekadar ambang batas deterministik konvensional—dilakukan pemetaan koefisien korelasi Pearson antarvariabel siber-fisik pada Gambar 6 dibawah ini :



Gambar 6. Matriks Korelasi Pearson Variabel Siber-Fisik dan Kognitif

Matriks korelasi Pearson pada Gambar 6 memvisualisasikan kekuatan asosiasi linier antarvariabel siber-fisik operasional sistem. Pertama, korelasi negatif yang moderat hingga kuat (-0,65) antara Kelembaban Tanah dan aktuasi PWM mengindikasikan adanya hubungan proporsional terbalik. Nilai korelasi yang tidak menyentuh angka absolut (-1,00) ini secara representatif memvalidasi dinamika sistem yang memodulasi laju tetesan air secara bertahap dan berkelanjutan, alih-alih sekadar menghasilkan respons biner (*on/off*). Kedua, korelasi negatif antara *State of Charge* (SoC) baterai dan PWM (-0,26) merepresentasikan pola serapan daya sistem, di mana peningkatan intensitas aktuasi hidrolik berasosiasi langsung dengan penurunan cadangan energi. Asosiasi statistik ini mengonfirmasi urgensi implementasi algoritma sadar-energi (*energy-aware*) guna memitigasi pengurasan baterai secara drastis saat intensitas penyiraman tinggi. Ketiga, matriks ini juga menangkap interaksi simultan antara iklim dan energi operasional: anomali kenaikan suhu lingkungan berasosiasi dengan penurunan kelembaban tanah sekaligus memiliki korelasi positif dengan peningkatan SoC baterai (0,24). Secara operasional, pola ini mengindikasikan bahwa pada saat lingkungan mengalami suhu tinggi (terik matahari), sistem secara bersamaan memperoleh suplai pemanenan energi surya yang maksimal, yang mana daya tersebut kemudian dimanfaatkan untuk mengkompensasi beban pemompaan air akibat tingginya stres iklim pada tanaman."

4. Kesimpulan

Penelitian ini berhasil merancang dan memvalidasi kerangka *Proprioceptive TinyML* untuk sistem irigasi cerdas bertenaga surya *off-grid*, yang secara empiris memecahkan masalah kegagalan daya (*brown-out*) pada arsitektur *Edge AI* konvensional. Melalui pendekatan "kesadaran siber", mikrokontroler mampu memantau kapasitas energinya sendiri dan melakukan transisi model kognitif secara otonom tanpa intervensi komputasi awan. Efektivitas manajemen daya dibuktikan melalui dominasi Model Silver pada kondisi ekuilibrium (97,89%) dan eksploitasi surplus daya via Model Gold (0,03%). Keseimbangan komputasi ini memastikan SoC baterai tidak pernah anjlok ke tingkat defisit kritis (aktivasi Bronze 0,00%), sehingga sistem terbukti berhasil menghindari kegagalan daya total selama periode pengujian berlangsung.

Selain ketahanan siber, sistem ini juga menjamin siklus kelangsungan energi (*Energy-Neutral Operation*) dengan efisiensi konversi daya mencapai 96,06%. Dalam uji skala riil pada

600 tanaman cabai, orkestrasi AI ini berhasil memberikan efisiensi penggunaan air yang presisi dan mencegah genangan air (*waterlogging*) secara otomatis. Implementasi arsitektur ini mengukuhkan transisi dalam *Cyber-Physical System* (CPS) pertanian yang beranjak dari logika batas linier konvensional menjadi analisis regresi multivariat yang adaptif secara simultan. Hal ini memvalidasi *Proprioceptive TinyML* sebagai solusi komputasi perangkat *edge* yang tangguh, presisi, dan berkelanjutan secara energi.

Kendati demikian, penelitian ini memiliki keterbatasan pada durasi eksperimen yang berjalan dalam siklus pendek, yakni 15 hari pengumpulan data dan 7 hari validasi lapangan. Rentang waktu observasi ini belum sepenuhnya merepresentasikan ketahanan sistem terhadap variasi anomali cuaca lintas musim. Sebagai arah pengembangan penelitian selanjutnya, skala akuisisi data perlu diperluas secara temporal. Lebih lanjut, kapabilitas kognitif mikrokontroler ini dapat diekspansi menjadi proyek riset multi-tahap untuk mengimplementasikan sistem deteksi anomali (*anomaly detection system*). Kerangka kerja mendatang dapat mencakup preparasi data telemetri di komputasi awan, pelatihan model di *platform* seperti Google Colab, hingga pengujian inferensi secara langsung (*on-device*) pada mikrokontroler guna mengidentifikasi kegagalan sensor atau malfungsi perangkat keras sejak dini

Daftar Pustaka

- Adewumi, I. O., Oyime, A., Adejumo, D., & Adegboyan, O. (2026). *Edge AI – IoT Integration for Real-Time Precision Farming: A Framework for Adaptive Monitoring, Prediction, and Resource Optimization*. 3(1), 1–20. <https://doi.org/10.69710/ljp.v3i1.16313>
- Amalia, P. V., Mursid, S. P., & Budi Suharto. (2024). Smart Drip Irrigation Control System Otomatis Berbasis IoT Menggunakan Tenaga Surya. *Prosiding Industrial Research Workshop and National Seminar*, 15(1), 47–56. <https://doi.org/10.35313/irwns.v15i1.6279>
- Bancik, K., Konecny, J., Stankus, M., Hercik, R., Koziorek, J., Markevičius, V., Andriukaitis, D., & Prauzek, M. (2026). Batteryless IoT Sensing Using Thermoelectric Energy Harvesting from Industrial Motor Waste Heat. *Sensors*, 26(5), 1–22. <https://doi.org/10.3390/s26051644>
- Banti, K., Karampelis, I., Tsipis, E., Dimakis, T., Papadimitriou, N., Boulogeorgos, A.-A. A., Kyriakidis, T., Karamitsou, T., Karapiperis, C., Lappos, S., Bagkavou, E., Adamidis, T., Gkanatsa, I., & Louta, M. (2022). *Intelligent Mechanisms for Irrigation Optimization via Treated Wastewater Management in Precision Agriculture—The AUGELAS Example*. 50. <https://doi.org/10.3390/environsciproc2022021050>
- Barroso, F. S. M., Inácio, M. J., & Oliveira, F. G. (2022). Embedded Fuzzy Controller For Application In Irrigation Systems. *EAgri*, 4430, 8–16. <https://doi.org/Doi:10.1590/1809-4430-Eng.Agric.v42nepe20210138/2022 EMBEDDED>
- Basaklar, T., Tuncel, Y., & Ogras, U. Y. (2022). tinyMAN: Lightweight Energy Manager using Reinforcement Learning for Energy Harvesting Wearable IoT Devices. In *Proceedings of tinyML Research Symposium (tinyML Research Symposium'22)* (Vol. 1, Issue 1). Association for Computing Machinery. <http://arxiv.org/abs/2202.09297>
- Cinco-Solis, A., Camacho-Escoto, J. J., Orozco-Barbosa, L., & Gomez, J. (2022). PPAASS: Practical Power-Aware Duty Cycle Algorithm for Solar Energy Harvesting Sensors. *IEEE Access*, 10(October), 117855–117870. <https://doi.org/10.1109/ACCESS.2022.3220695>
- Ghamari, S., Ozcan, K., Dinh, T., Melnikov, A., Carvajal, J., Ernst, J., & Chai, S. (2021).

- Quantization-Guided Training for Compact TinyML Models. In *Proceedings of TinyML Research Symposium (TinyML Research Symposium '21)* (Vol. 1, Issue 1). Association for Computing Machinery. <http://arxiv.org/abs/2103.06231>
- Ghazi. (2025). Smart Irrigation Systems: A Comprehensive Review of IoT, AI, and Sustainable Agriculture Technologies. A Review Article. *Kirkuk University Journal For Agricultural Sciences*, 266–281. <https://doi.org/10.58928/ku25.16429>
- Glória, A., Cardoso, J., & Sebastião, P. (2021). Sustainable irrigation system for farming supported by machine learning and real-time sensor data. *Sensors*, 21(9), 1–26. <https://doi.org/10.3390/s21093079>
- Hsu, R. C., Lin, T. H., & Su, P. C. (2022). Dynamic Energy Management for Perpetual Operation of Energy Harvesting Wireless Sensor Node Using Fuzzy Q-Learning. *Energies*, 15(9). <https://doi.org/10.3390/en15093117>
- Islam, S., Deng, J., Zhou, S., Pan, C., Ding, C., & Xie, M. (2022). Enabling Fast Deep Learning on Tiny Energy-Harvesting IoT Devices. *Proceedings of the 2022 Design, Automation and Test in Europe Conference and Exhibition, DATE 2022*, 921–926. <https://doi.org/10.23919/DATE54114.2022.9774756>
- Lv, M., & Xu, E. (2022). Deep Learning on Energy Harvesting IoT Devices: Survey and Future Challenges. *IEEE Access*, 10(November), 124999–125014. <https://doi.org/10.1109/ACCESS.2022.3225092>
- Noviardi, & Syelly, R. (2026). *Unsupervised Autoencoder untuk Deteksi Anomali Cerdas pada Perangkat Edge Computing Berbasis TinyML*. 5(1), 165–184. <https://doi.org/DOI:10.55043/technologica.v5i1.355>
- Ramya, S., Swetha, A. M., & Doraipandian, M. (2020). IoT framework for smart irrigation using machine learning technique. *Journal of Computer Science*, 16(3), 355–363. <https://doi.org/10.3844/JCSSP.2020.355.363>
- Ravaglia, L., Rusci, M., Nadalini, D., Capotondi, A., Conti, F., & Benini, L. (2021). A TinyML Platform for On-Device Continual Learning with Quantized Latent Replays. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 11(4), 789–802. <https://doi.org/10.1109/JETCAS.2021.3121554>
- Silva, M., Riker, A., Torrado, J., Santos, J., & Curado, M. (2022). Extending Energy Neutral Operation in Internet of Things. *IEEE Internet of Things Journal*, 9(10), 7510–7524. <https://doi.org/10.1109/JIOT.2021.3133615>
- Trînc, E. C., Niță, V., Stolojescu-Crisan, C., Ancuți, C., Mihai, R. M., & Sultănoiu, C. P. (2026). Cost-Effective TinyML-Ready Design and Field Deployment of a Solar-Powered Environmental Monitoring Data Collector Using LTE-M Communication. *Applied Sciences (Switzerland)*, 16(7), 1–63. <https://doi.org/10.3390/app16073237>
- Tsoukas, V., Gkogkidis, A., & Kakarountas, A. (2022). A TinyML-based System for Smart Agriculture. In *ACM International Conference Proceeding Series* (Vol. 1, Issue 1). Association for Computing Machinery. <https://doi.org/10.1145/3575879.3575994>
- Xu, K., Zhang, H., Li, Y., Zhang, Y., Lai, R., & Liu, Y. (2021). An Ultra-Low Power TinyML System for Real-Time Visual Processing at Edge. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 70(7), 2640–2644. <https://doi.org/10.1109/TCSII.2023.3239044>
- Zaidi, S. A. R., Hayajneh, A. M., Hafeez, M., & Ahmed, Q. Z. (2022). Unlocking Edge Intelligence Through Tiny Machine Learning (TinyML). *IEEE Access*, 10(July), 100867–100877. <https://doi.org/10.1109/ACCESS.2022.3207200>