

Evaluasi Performa Prototipe Sistem Monitoring dan Proteksi Termal Motor DC Berbasis *Edge Machine Learning* pada ESP32

Muflikhul Hakim^{1*}, Ahmad Syamsuri², Muhammad Dana Shulkhi³, Fariz Rifqi Zul Fahmi⁴, Fressy Nugroho⁵, Fuad Dwi Hanggara⁶

^{1,2,3,4,5,6}Jurusan Teknik Mesin, Universitas Islam Negeri Maulana Malik Ibrahim Malang, Indonesia

250903110025@student.uin-malang.ac.id

250903110001@student.uin-malang.ac.id

250903110027@student.uin-malang.ac.id

farizrifqizf@uin-malang.ac.id

fresy@ti.uin-malang.ac.id

*Corresponding author email: fuaddh31@uin-malang.ac.id

Abstrak— *Overheating* merupakan penyebab utama kerusakan motor DC, sementara sistem proteksi konvensional berbasis ambang batas statis belum mampu memberikan respons bertingkat terhadap pola kenaikan suhu yang dinamis. Penelitian ini mengevaluasi performa prototipe sistem monitoring dan proteksi termal motor DC berbasis *edge machine learning* pada ESP32, dengan fokus pada kemampuan deteksi kondisi *thermal rise* dan latensi respons mekanisme proteksi hierarkis. Deteksi dini dilakukan menggunakan model *edge machine learning* yang dilatih melalui platform Edge Impulse untuk mengklasifikasikan pola kenaikan suhu (*rise*) berdasarkan lima data terakhir sensor DS18B20, kemudian mengaktifkan kipas pendingin dan buzzer sebagai respons awal. Apabila suhu motor melampaui ambang batas kritis 40°C, sistem secara deterministik memutus suplai daya motor melalui modul relay tanpa bergantung pada proses inferensi *machine learning*. Seluruh data suhu, status klasifikasi, dan status aktuator ditransmisikan secara *real-time* melalui protokol MQTT ke *dashboard* pemantauan pada perangkat seluler, sementara tampilan lokal disediakan melalui LCD. Pendekatan *hybrid* yang menggabungkan adaptivitas *edge machine learning* dengan keandalan proteksi deterministik berbasis relay ini diharapkan dapat menjadi referensi arsitektur prototipe sistem proteksi termal motor DC skala kecil berbasis IoT.

Kata Kunci— motor DC, *edge machine learning*, proteksi termal, *relay cutoff*, ESP32, IoT, MQTT.

I. PENDAHULUAN

Motor arus searah (DC) merupakan salah satu aktuator listrik yang paling banyak digunakan dalam sistem otomasi, robotika, dan perangkat elektronik konsumen karena konstruksinya yang sederhana serta kemudahan pengaturan kecepatan dan torsi [1]. Dalam pengoperasiannya, motor DC menghasilkan panas sebagai konsekuensi dari rugi-rugi resistif pada lilitan, gesekan mekanik antarkomponen, serta beban

kerja yang melebihi kapasitas nominal. Apabila panas tersebut tidak dikelola dengan baik, suhu motor akan meningkat secara progresif dan berpotensi mendegradasi sistem isolasi lilitan, yang menurut standar IEC 60034-1 merupakan parameter kritis yang menentukan umur operasional motor [2]. Setiap kenaikan suhu sebesar 10°C di atas nilai rating *insulation class* motor secara empiris dapat mengurangi umur isolasi hingga setengahnya [3].

Perkembangan teknologi *Internet of Things* (IoT) telah membuka peluang baru dalam sistem *monitoring* kondisi motor secara *real-time* [4]. Integrasi sensor, mikrokontroler, dan protokol komunikasi ringan seperti Message Queuing Telemetry Transport (MQTT) memungkinkan pemantauan parameter suhu dilakukan secara kontinu dengan latensi rendah [5]. Namun demikian, sebagian besar implementasi *monitoring* motor berbasis IoT yang telah dipublikasikan masih bersifat pasif — menampilkan data suhu tanpa mekanisme proteksi otomatis yang terintegrasi [6], [7]. Di sisi lain, pendekatan proteksi konvensional berbasis ambang batas statis (*static threshold*) memiliki keterbatasan dalam mengenali pola kenaikan suhu yang dinamis sebelum kondisi kritis tercapai [8].


Sementara itu, penerapan *edge machine learning* pada mikrokontroler telah terbukti mampu melakukan klasifikasi pola data sensor secara langsung di perangkat tanpa ketergantungan pada komputasi awan, dengan latensi inferensi yang rendah dan konsumsi daya yang efisien [9], [10]. Secara umum, *edge machine learning* merujuk pada penerapan model *machine learning* yang telah dilatih agar dapat dijalankan langsung pada perangkat dengan sumber daya komputasi terbatas, seperti mikrokontroler, sehingga proses inferensi dilakukan secara *on-device* tanpa harus mengirimkan data ke server *cloud* [9], [10]. Pendekatan ini memungkinkan sistem mengambil keputusan secara mandiri dengan latensi rendah, mengurangi ketergantungan pada konektivitas jaringan, serta

menjaga privasi data karena pemrosesan dilakukan secara lokal [14]. Berdasarkan kesenjangan tersebut, penelitian ini menguji apakah prototipe sistem monitoring dan proteksi termal motor DC berbasis *edge ML* pada ESP32 mampu mendeteksi kondisi *thermal rise* dengan akurasi $\geq 95\%$ serta mengaktifkan mekanisme proteksi secara hierarkis dalam latensi $\leq 500\text{ms}$.

II. METODOLOGI

A. Arsitektur Sistem

Prototipe sistem terdiri dari lima subsistem utama yang bekerja secara terintegrasi: (1) akuisisi suhu menggunakan sensor DS18B20 pada bodi motor DC RS-540; (2) pemrosesan dan inferensi berbasis ESP32; (3) proteksi bertingkat berupa kipas pendingin, buzzer, dan relay; (4) tampilan lokal LCD; serta (5) *monitoring* jarak jauh berbasis MQTT. Dua jalur keputusan paralel dijalankan oleh ESP32: inferensi model *edge ML* untuk mendeteksi kondisi *rise*, dan pemeriksaan *rule-based* deterministik terhadap ambang batas suhu kritis. Diagram blok arsitektur keseluruhan sistem ditunjukkan pada Gbr. 1.




Gambar. 1 Diagram blok arsitektur sistem monitoring dan proteksi termal motor DC berbasis IoT

B. Spesifikasi Perangkat Keras

Motor DC RS-540 dipilih sebagai objek penelitian (9V, 24.400 RPM, 1,6A) karena merepresentasikan kelas motor DC *brushed* skala kecil yang umum pada robotika dan otomasi ringan. Sensor DS18B20 dipilih atas keunggulan resolusinya ($0,0625^\circ\text{C}$) dan antarmuka OneWire yang efisien. Pemasangan sensor menggunakan *thermal glue* untuk memaksimalkan kontak termal pada bodi motor. Rincian spesifikasi seluruh komponen perangkat keras ditunjukkan pada Tabel I, sedangkan skema rangkaian elektronik keseluruhan sistem ditampilkan pada Gbr. 2.

TABEL I SPESIFIKASI PERANGKAT KERAS

KOMPONEN	SPESIFIKASI	FUNGSI
ESP32	240MHz, Wi-Fi, BLE	Proses, ML, MQTT
DS18B20	$0,0625^\circ\text{C}$, OneWire	Akuisisi suhu
Relay 5V	1-ch, optocoupler	Pemutus daya motor
Cooling Fan	5V DC	Pendingin aktif
Buzzer	Aktif, 5V	Indikator audio
LCD I2C	16x2, I2C	Tampilan lokal
Motor RS-540	9V, 1,6A, 24.400 RPM	Objek penelitian



Gambar. 2 Skema rangkaian elektronik sistem

C. Akuisisi dan Persiapan Dataset

Dataset diperoleh dari pengukuran langsung sensor DS18B20 pada motor RS-540 dalam dua kondisi: *normal* (suhu stabil) dan *rise* (kenaikan suhu progresif). Kelas *rise* didefinisikan secara kuantitatif sebagai segmen di mana slope regresi linear dari setiap *window* lima pembacaan bernilai positif dengan gradien minimum $0,2^\circ\text{C}$ per interval. Pengambilan data dilakukan melalui ESP32 yang terhubung ke Edge Impulse via fitur *data forwarder*. Ringkasan komposisi dataset hasil akuisisi dan augmentasi ditunjukkan pada Tabel II.

Untuk mengatasi ketidakseimbangan kelas yang umum pada *condition monitoring embedded* [11], diterapkan *pattern-based data augmentation* pada kelas *rise*. Augmentasi dibatasi ketat pada pola dengan gradien monoton positif ($dT/dt \geq 0$ pada seluruh titik *window*) guna memastikan distribusi *first-order derivative* data sintesis konsisten dengan karakteristik termal *rise* yang sesungguhnya [12]. Data kelas *normal* seluruhnya merupakan data riil tanpa augmentasi.

TABEL II RINGKASAN DATASET

KELAS	JUMLAH	SUMBER DATA
Normal	2.022 baris	Data riil
Rise	2.268 baris	Augmentasi (gradien monoton +)
Data latih	3.432 baris	80% dari total
Data uji	859 baris	Data riil kondisi motor

D. Pengembangan Model Edge Machine Learning

Model dikembangkan secara iteratif melalui tiga konfigurasi pada platform Edge Impulse. Model 1 (3 kelas, data riil) menghasilkan akurasi 70,5% akibat distribusi kelas tidak seimbang. Model 2 (2 kelas, data riil) meningkat ke 85,8% namun masih terbatas data kelas *rise*. Model 3 — model final

— menggunakan 2 kelas dengan augmentasi berbasis pola, mencapai akurasi 99,4%. *Window* input berisi lima data suhu terakhir, kompromis antara responsivitas dan akurasi deteksi pola pada *embedded device* [14]. Perbandingan ketiga konfigurasi model beserta akurasinya disajikan pada Tabel III.

TABEL III PERBANDINGAN KONFIGURASI MODEL

MODEL	KELAS	DATA	AKURASI	KETERANGAN
1	3	Riil	70,5%	Data tak seimbang
2	2	Riil	85,8%	Rise terbatas
3	2	Riil+Aug.	99,4%	Model final

E. Verifikasi Independen Performa Model

Komparasi dilakukan antara dua pendekatan pada dataset uji identik (858 sampel; 438 *normal*, 420 *rise*): (1) Neural Network berbasis fitur spektral FFT (*window* 5, FFT length 16, 13 fitur) via Edge Impulse, dan (2) Random Forest berbasis 13 fitur tren temporal — slope regresi linear, *first difference*, proporsi kenaikan, delta total, dan statistik deskriptif — menggunakan *scikit-learn* Python [15], [16]. Recall kelas *rise* ditetapkan sebagai metrik primer karena konsekuensi asimetris: *false negative* berpotensi menyebabkan kerusakan motor, sedangkan *false positive* hanya menghasilkan alarm yang dapat dikelola oleh *cooldown timer* [17].

F. Mekanisme Proteksi Bertingkat

Sistem mengimplementasikan dua lapisan proteksi hierarkis. Lapisan 1 (*Edge ML*): model mengevaluasi *window* lima data suhu secara kontinu; ketika kondisi *rise* terdeteksi, kipas pendingin dan buzzer diaktifkan dengan *cooldown timer* 30 detik untuk mencegah siklus aktuasi berlebihan. Lapisan 2 (*Rule-Based*): apabila suhu $\geq 40^{\circ}\text{C}$, relay memutuskan suplai daya motor secara deterministik tanpa bergantung pada inferensi ML. Ambang 40°C mengacu pada suhu ambien maksimum IEC 60034-1 sebagai titik proteksi dini yang konservatif [18]. Logika kedua lapisan proteksi tersebut diringkas pada Tabel IV.

TABEL IV LOGIKA PROTEKSI BERTINGKAT


LAPIS	TRIGGER	AKTUATOR	METODE
1	Rise terdeteksi ML	Fan + Buzzer (30s cooldown)	Edge ML
2	Suhu $\geq 40^{\circ}\text{C}$	Relay cutoff	Rule-based

III. HASIL DAN PEMBAHASAN

A. Implementasi Sistem

Prototipe berhasil diimplementasikan sesuai arsitektur yang dirancang. Seluruh komponen — sensor DS18B20, ESP32, relay, kipas, buzzer, LCD, dan MQTT — berfungsi secara terintegrasi. Pemasangan sensor dengan *thermal glue* terbukti meningkatkan kualitas kontak termal dibandingkan pemasangan mekanis pada iterasi sebelumnya. Implementasi


fisik prototipe sistem secara keseluruhan ditunjukkan pada Gbr. 3.



Gambar. 3 Implementasi fisik prototipe sistem

B. Analisis Karakteristik Temporal Sinyal Suhu

Pengujian akuisisi data kontinu selama ± 1 jam (Gbr. 4) mengungkap dinamika termal kompleks motor RS-540 berupa tiga fase siklus: *thermal rise* (kenaikan progresif akibat rugi-rugi resistif), *active cooling* (penurunan suhu dipicu aktivasi kipas oleh Lapisan 1), dan *thermal stabilization* (kondisi kuasi-statis). Ringkasan tiap segmen akuisisi suhu beserta label klasifikasinya disajikan pada Tabel V.

Gambar. 4 Grafik suhu terhadap waktu selama pengujian kontinu ± 1 jam motor DC RS-540

TABEL V RINGKASAN SEGMENT AKUISISI SUHU

KONDISI	$T_0 (^{\circ}\text{C})$	$T_1 (^{\circ}\text{C})$	$\Delta T (^{\circ}\text{C})$	DURASI	LABEL ML
Normal stabil	28,5	29,1	+0,6	± 5 mnt	Normal
Thermal rise	29,1	38,4	+9,3	± 18 mnt	Rise
Active cooling	38,4	33,2	-5,2	± 8 mnt	Normal*
Stabilization	33,2	34,0	+0,8	± 12 mnt	Normal
Pre-relay rise	37,1	40,1	+3,0	± 7 mnt	Rise

Normal = target label; berpotensi *false positive* pada fase cooling — lihat analisis di bawah.

Fase *active cooling* memunculkan tantangan klasifikasi kritis. Ketika kipas aktif, laju penurunan suhu ($dT/dt < 0$) dapat memiliki magnitudo sebanding dengan laju kenaikan selama fase *rise* ($dT/dt > 0$). Representasi domain frekuensi melalui Fast Fourier Transform (FFT) — basis ekstraksi fitur model Neural Network — bersifat *even-symmetric* terhadap polaritas sinyal: untuk sinyal diskrit $x[n]$, FFT menghasilkan $X[k] = \Sigma$

$x[n] \cdot e^{(-j2\pi kn/N)}$, dan komponen $|X[k]|$ yang digunakan bersifat identik untuk sinyal kenaikan dan penurunan dengan kecepatan ekuivalen. Akibatnya, model mengalami *polarity-invariant misclassification* — ketidakmampuan membedakan arah perubahan suhu karena representasi fitur yang bersifat *magnitude-only*. Fenomena ini konsisten dengan satu insiden *false alarm* yang terekam selama pengujian 1 jam, terjadi tepat pada fase *active cooling*.

Temuan ini mengindikasikan bahwa keterbatasan bukan pada kapasitas model, melainkan pada representasi fitur FFT yang tidak mempertahankan informasi direksionalitas (polaritas) perubahan suhu. Untuk penelitian lanjutan, penambahan fitur berbasis *signed first-order derivative* (dT/dt) direkomendasikan sebagai komplemen fitur spektral.

C. Performa Model dan Verifikasi Independen

Komparasi independen antara Neural Network + FFT (Edge Impulse) dan Random Forest + fitur tren temporal (*scikit-learn*) disajikan pada Tabel VI. Grafik akurasi pelatihan model final ditunjukkan pada Gbr. 5. Confusion matrix Random Forest ditampilkan pada Gbr. 6 dengan $TP = 420$, $TN = 416$, $FP = 18$, $FN = 0$.



Gambar. 5 Grafik akurasi pelatihan Model 3 (Neural Network + FFT)

TABEL VI KOMPARASI METODE KLASIFIKASI

METRIK	NN + FFT (EDGE IMPULSE)	RANDOM FOREST (SCIKIT-LEARN)
Accuracy	99,40%	97,89%
Precision (rise)	99,00%	95,89%
Recall (rise)*	99,00%	100,00%
F1-Score (rise)	99,00%	97,90%

*Recall ditetapkan sebagai metrik primer ($FN = 0$ pada Random Forest)


Keempat metrik dihitung menggunakan rumus standar evaluasi klasifikasi biner sebagai berikut:

$$Precision = \frac{TP}{TP + FP}$$

$$Recall = \frac{TP}{TP + FN}$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

di mana TP (True Positive) adalah jumlah sampel rise yang diprediksi benar sebagai rise, TN (True Negative) adalah sampel normal yang diprediksi benar sebagai normal, FP (False Positive) adalah sampel normal yang salah diprediksi sebagai rise, dan FN (False Negative) adalah sampel rise yang tidak terdeteksi. Berdasarkan confusion matrix hasil komparasi independen (Gbr. 3), diperoleh nilai $TP = 420$, $TN = 416$, $FP = 18$, $FN = 0$, sehingga nilai recall sempurna (100%) dikonfirmasi oleh kondisi $FN = 0$.



Gambar. 6 Confusion matrix Model Random Forest (komparasi independen)


Model Neural Network + FFT mencapai F1-Score 99,00% dengan keseimbangan *precision-recall* yang lebih baik, menjadikannya pilihan final untuk *deployment* pada ESP32. Meskipun Random Forest menghasilkan recall sempurna ($FN = 0$), nilai $FP = 18$ akan menimbulkan beban aktuasi kipas yang tidak perlu dalam operasi jangka panjang. Temuan komparatif ini sekaligus mengkonfirmasi bahwa fitur tren temporal berbasis gradien — yang mempertahankan informasi polaritas — secara inheren lebih tepat untuk deteksi kenaikan suhu terarah, membuka arah pengembangan lanjutan berupa penggabungan kedua jenis representasi fitur.

D. Pengujian Sistem Proteksi Bertingkat

Hasil pengujian respons sistem proteksi bertingkat pada tiga skenario suhu disajikan pada Tabel VII, sementara grafik respons sistem pada transisi normal → rise → relay cutoff ditunjukkan pada Gbr. 7.

TABEL VII HASIL PENGUJIAN RESPONS PROTEKSI

SKENARIO	SUHU (°C)	RESPONS (MS)	AKTUATOR	HASIL
Rise terdeteksi ML	32,7	300	Fan + Buzzer	Proteksi awal
Suhu $\geq 40^\circ\text{C}$	40,1	200	Relay cutoff	Motor mati
Suhu kembali normal	35,0	200	Semua nonaktif	Reset



Gambar. 7 Grafik respons sistem pada transisi normal → rise → relay cutoff


E. Keandalan Operasi Kontinu dan Monitoring MQTT

Hasil pengujian keandalan operasi sistem selama ± 1 jam, mencakup jumlah pembacaan suhu, keberhasilan inferensi ML, dan status komunikasi MQTT, disajikan pada Tabel VIII.

TABEL VIII HASIL PENGUJIAN KEANDALAN ± 1 JAM

PARAMETER	HASIL
Durasi pengujian	± 1 jam
Jumlah pembacaan suhu	2.968
Inferensi ML berhasil	100%
Kegagalan komunikasi MQTT	0
False alarm (fase active cooling)	1x
Missed detection	0
Gangguan aktuator	0

Sistem monitoring berbasis MQTT berhasil menampilkan data suhu, label klasifikasi, confidence, dan status aktuator secara *real-time*. Latensi transmisi terpantau stabil selama pengujian, sesuai karakteristik protokol MQTT untuk perangkat IoT [19]. Tampilan *dashboard* MQTT pada tiga kondisi operasi sistem ditunjukkan pada Gbr. 8.



Gambar. 8 Tampilan dashboard MQTT pada tiga kondisi operasi

IV. KESIMPULAN

Prototipe sistem monitoring dan proteksi termal motor DC RS-540 berbasis *edge machine learning* dan *relay cutoff* pada ESP32 berhasil dikembangkan dengan empat temuan utama. Pengujian menunjukkan bahwa prototipe berhasil memenuhi

kedua kriteria yang ditetapkan: model Neural Network + FFT mencapai akurasi 99,4% (melampaui *threshold* $\geq 95\%$), sementara mekanisme proteksi bertingkat — aktivasi kipas dalam 300ms dan relay cutoff dalam 200ms — seluruhnya berada di bawah batas latensi ≤ 500 ms yang disyaratkan.

Pertama, *pattern-based data augmentation* yang dibatasi pada pola gradien monoton positif terbukti efektif mengatasi keterbatasan data abnormal pada motor skala kecil, menghasilkan model dengan akurasi 99,4%. Kedua, arsitektur proteksi bertingkat (ML *rise detection* + *relay cutoff* deterministik pada $\geq 40^\circ\text{C}$) memberikan respons protektif berjenjang tanpa ketergantungan pada intervensi operator. Ketiga, analisis komparatif mengungkap keterbatasan inheren representasi fitur FFT berupa *polarity-invariant misclassification* pada fase *active cooling*, membuka rekomendasi penambahan fitur *signed first-order derivative* untuk penelitian lanjutan. Keempat, integrasi MQTT dan LCD memberikan fleksibilitas *monitoring* jarak jauh maupun lokal dengan reliabilitas 100% selama pengujian 1 jam.

. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Jurusan Teknik Mesin UIN Maulana Malik Ibrahim Malang atas dukungan fasilitas penelitian, serta kepada seluruh pihak yang telah berkontribusi dalam penyelesaian penelitian ini.

. REFERENSI

- [1] S. J. Chapman, *Electric Machinery Fundamentals*, 5th ed. New York, NY, USA: McGraw-Hill, 2012.
- [2] International Electrotechnical Commission, IEC 60034-1: Rotating Electrical Machines — Part 1: Rating and Performance, Geneva, Switzerland: IEC, 2017.
- [3] J. Pyrhonen, T. Jokinen, and V. Hrabovcova, *Design of Rotating Electrical Machines*. Chichester, UK: Wiley, 2014.
- [4] J. Gubbi, R. Buyya, S. Marusic, and M. Palaniswami, "Internet of Things (IoT): A vision, architectural elements, and future directions," *Future Generation Computer Systems*, vol. 29, no. 7, pp. 1645–1660, 2013.
- [5] A. Banks and R. Gupta, MQTT Version 3.1.1, OASIS Standard, 2014.
- [6] C. B. Sogen, "Monitoring suhu pada kamar mesin kapal berbasis Arduino Uno," *Jurnal Politeknik ATI Makassar*, vol. 5, no. 1, pp. 12–18, 2023.
- [7] D. A. N. K. Suhermanto et al., "Monitoring DC Motor Based on LoRa and IoT," *Journal of Robotics and Control (JRC)*, vol. 5, no. 1, pp. 54–61, 2024.
- [8] X. Yang and Y. Liu, "Thermal monitoring and protection of DC motors based on temperature threshold," *IEEE Access*, vol. 6, pp. 74215–74223, 2018.
- [9] W. Shi, J. Cao, Q. Zhang, Y. Li, and L. Xu, "Edge computing: Vision and challenges," *IEEE Internet of Things Journal*, vol. 3, no. 5, pp. 637–646, 2016.
- [10] C. R. Banbury et al., "Benchmarking TinyML systems," *Proc. Machine Learning and Systems*, vol. 3, pp. 211–244, 2021.
- [11] M. Rußwurm et al., "Self-attention for raw optical satellite time series classification," *ISPRS J. Photogramm. Remote Sens.*, vol. 169, pp. 421–435, 2020.
- [12] B. K. Iwana and S. Uchida, "An empirical survey of data augmentation for time series classification with neural networks," *PLOS ONE*, vol. 16, no. 7, e0254841, 2021.
- [13] Edge Impulse Inc., *Edge Impulse Documentation: Embedded Machine Learning*, 2023. <https://docs.edgeimpulse.com/>
- [14] S. Sakr et al., "Machine learning on edge devices: A survey," *IEEE Internet of Things Journal*, vol. 7, no. 10, pp. 9341–9356, 2020.
- [15] A. V. Oppenheim and R. W. Schaffer, *Discrete-Time Signal Processing*, 3rd ed. Upper Saddle River, NJ, USA: Prentice-Hall, 2010.

- [16] L. Breiman, "Random Forests," Machine Learning, vol. 45, no. 1, pp. 5–32, 2001.
- [17] T. Saito and M. Rehmsmeier, "The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets," PLOS ONE, vol. 10, no. 3, 2015.
- [18] H. W. Penrose, A Practical Guide to Electrical Motor Predictive and Preventive Maintenance. ALL-TEST Pro, LLC, 2008.
- [19] U. Hunkeler, H. L. Truong, and A. Stanford-Clark, "MQTT-S — A publish/subscribe protocol for wireless sensor networks," IEEE COMSWARE, 2008.