

Activity Recognition yang Novel dengan Sensor Passive Infrared (PIR) pada Smart Lighting untuk Meningkatkan User Comfort

1st Aji Gautama Putrada
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
ajigautama@students.telkomuniversity.ac.id

2nd Maman Abdurrohman
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
abdurrohman@telkomuniversity.ac.id

3rd Doan Perdana
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
doanperdana@telkomuniversity.ac.id

Abstrak - Beberapa penelitian mengenai smart lighting telah mengusulkan kendali lampu berdasarkan activity recognition yang akurat, namun dengan solusi yang mahal. Di sisi lain, beberapa penelitian telah menerapkan bentuk-bentuk lain dari activity recognition-based smart lighting dengan menggunakan passive infrared (PIR) sensor yang terjangkau, namun dengan kinerja yang terbatas. Terdapat research opportunity untuk suatu solusi novel yang terjangkau namun akurat dan juga terbukti meningkatkan user comfort. Tujuan dari disertasi ini adalah menemukan solusi novel yang terjangkau dan akurat kemudian mengevaluasi keterkaitan kinerja solusi novel tersebut dengan user comfort. Pertama, diusulkan penerapan metode yang novel bernama classification integrated moving average (CIMA) yang dapat meningkatkan akurasi activity recognition pada smart lighting menggunakan sensor PIR yang secara relative lebih low-price dari solusi state-of-the-art (SoTA). Kemudian menerapkan arsitektur novel EdgeSL, yaitu arsitektur edge computing pada smart lighting memanfaatkan distilled KNN (DistilKNN) untuk processing time yang optimum. Terakhir, membuktikan bahwa metode novel yang telah diusulkan dapat meningkatkan user comfort. Hal ini adalah dengan memanfaatkan technology acceptance model (TAM). Penelitian disertasi ini memperlihatkan bahwa CIMA lebih baik dari penelitian SoTA lain. Kemudian disertasi ini membuktikan bahwa user comfort dapat diukur dengan TAM. Uji Wilcoxon memperlihatkan perbedaan signifikan pada TAM yang dibuat untuk dua perangkat: perangkat smart lighting tanpa CIMA dan dengan CIMA. Hal tersebut memperlihatkan bahwa AI dengan CIMA adalah signifikan penting dalam user comfort pada smart lighting.

Kata kunci : smart lighting, classification-integrated moving average, user comfort, edge computing, technology acceptance model

Smart lighting merupakan sebuah inovasi yang produknya sudah ada di pasaran, umumnya dalam bentuk bohlam Wi-Fi yang terhubung ke Internet sehingga menjadi bagian dari konsep Internet of Things (IoT). Dengan menggabungkan kemampuan IoT dan lampu light emitting diode (LED) *smart lighting* mempunyai beberapa kemampuan, antara lain, kendali lewat aplikasi *smartphone*, kendali warna, kendali keredupan, perintah suara, dan penjadwalan. Arah utama penelitian *smart lighting* adalah penghematan energi, di mana salah satu penyebabnya adalah besarnya proporsi energi yang dikonsumsi oleh sistem pencahayaan [1] [2]. Penerapan peredupan otomatis pada *smart lighting*, dengan memanfaatkan sensor cahaya, dapat memberikan penghematan hingga 25% [3] [4].

Di sisi lain, keluhan pengguna mungkin muncul ketika strategi efisiensi energi diterapkan pada sistem yang ditargetkan karena kualitas pencahayaan yang buruk [5]. Hal ini dapat dimaklumi karena menurut prinsip hemat energi, semakin sering lampu diredupkan, semakin baik [6]. Fenomena ini bertentangan dengan kebutuhan manusia akan penerangan yang memadai untuk menjalankan aktivitas sehari-hari dengan produktif [7] [8]. Beberapa penelitian telah menekankan pentingnya menjaga *user comfort* saat mengejar efisiensi lewat *smart lighting* [9] [10] [11].

Machine learning adalah metode yang menangani masalah kompleks dan secara otomatis menghasilkan solusi dalam model [12]. Beberapa sistem *smart lighting* telah menerapkan teknik *machine learning*, misalnya, kontrol *smart lighting* yang canggih menggunakan *convolutional neural network* (CNN) dan *computer vision* [13], kemudian *reinforcement learning* untuk *smart lighting* yang adaptif [14]. Ada kemungkinan bahwa *machine learning* dapat menjadi solusi terhadap masalah kompleks dalam menjaga kenyamanan pengguna dan efisiensi energi. Terutama karena Gartner mengatakan bahwa *intelligence*

I. PENDAHULUAN

A. Latar Belakang

adalah salah satu dari enam faktor mendorong teknologi *smart lighting*.

B. Topik dan Batasannya

Berdasarkan tiga kata kunci tersebut: *smart lighting*, *user comfort*, dan *machine learning*, maka dilakukan penelusuran paper dengan metode *systematic literature review* (SLR), dengan membaca 332 paper mengenai *machine learning* pada *smart lighting* untuk meningkatkan *user comfort*. Hasil studi memperlihatkan beberapa penelitian state-of-the-art (SoTA) telah menerapkan *machine learning* untuk mengontrol *smart lighting* berdasarkan *user activity*, umumnya disebut *activity recognition*. Dai et al. [15] menerapkan *activity recognition* pada *smart lighting* dengan menggunakan lima kamera, Chun et al. [16] menggunakan *depth camera* (Kinect) untuk *activity recognition* dalam *smart lighting*, *activity recognition* dari Lupion et al. [17] melibatkan *multi-device*, termasuk *smartwatch* dan *real time location system* (RTLS). Penelitian-penelitian tersebut adalah *activity recognition* yang melibatkan perangkat kompleks dan tidak terjangkau.

Selanjutnya, beberapa penelitian lain menerapkan *smart lighting* berbasis *activity recognition* dengan sensor *passive infrared* (PIR) yang terjangkau. Jin et al. [18] menggunakan sensor PIR dan temporal sequential-artificial neural network (TS-ANN) dengan akurasi kendali 97%, Putrada et al. [19] menggunakan PIR sensor dengan *hierarchical hidden Markov model* (HHMM) dengan akurasi 87,6%, Fakhruddin et al. [20] menggunakan PIR sensor dengan *principal component analysis* (PCA) dengan *k-nearest neighbor* (KNN) dengan akurasi 94%. Penelitian dengan PIR sensor menunjukkan akurasi yang masih dapat ditingkatkan. *Research gap* dari penelitian-penelitian tersebut adalah bagaimana memanfaatkan sensor PIR yang terjangkau dan namun akurasinya optimum.

Beberapa penelitian menggunakan *moving average* pada *time-series data* untuk meningkatkan kinerja dari fitur-fitur dataset mereka dalam *machine learning* [21] [22] [23] [24] [25]. Terdapat *research opportunity* untuk menerapkan *moving average* pada data PIR sensor untuk meningkatkan kinerja fitur tersebut untuk mendapatkan metode *machine learning* untuk mendapatkan metode *machine learning* yang akurasi nya lebih optimum dari penelitian-penelitian SoTA.

Lebih lanjut, penerapan *machine learning* pada *smart lighting* dapat meningkatkan *computational time*. Metode memampatkan *machine learning model* untuk dapat berjalan pada *edge device* dinamakan *model compression*, di mana teknik-teknik yang populer adalah *pruning*, *quantization*, dan *knowledge distillation* [26]. Penelitian Dai et al. [27] dan Yu et al. [28] mengompresi DNN dengan metode *pruning* yang novel, masing-masing dengan akurasi terbaik yaitu 91% dan 94%. Prakash et al. [29], mengompresi DNN dengan metode novel pembelajaran gabungan

dengan *quantization* dan *pruning* (GWEP), menggunakan kombinasi *pruning* dan *quantization*. Akurasi terbaik GWEP adalah 99%. Matsubara et al. [30] mengompresi DNN menggunakan *knowledge distillation* dengan akurasi terbaik yaitu 78% pada model ResNet. *Research gap* nya adalah bagaimana menerapkan *model compression* pada metode *machine learning* dalam *smart lighting* dengan arsitektur *edge computing* sehingga mendapatkan *processing time* yang optimal.

Terakhir, setelah *machine learning model* yang novel didapatkan, harus diukur apakah *user comfort* pada *smart lighting* meningkat. Beberapa paper telah mencoba mengukur *user comfort* menggunakan *smart lighting* yang mereka usulkan. Park et al. [36] mengukur *user comfort* dengan menggunakan kuesioner. Wang et al. [37] menerapkan *multivariate analysis of variance* (MANOVA) untuk melihat keterkaitan *color correlated temperature* (CCT) lampu berkaitan dengan *user comfort*. Pocu et al. [38] menggunakan MANOVA untuk melihat signifikansi *lighting* sebagai factor dalam *user comfort* saat menikmati siaran TV. Saad [39] mengatakan bahwa kenyamanan erat kaitannya dengan penerimaan pengguna. Paper dia adalah tentang *technology acceptance model* (TAM). TAM terdiri dari tiga construct: *Perceived ease of use* (PEOU), *Perceived usefulness* (PU), dan *behavioral intention* (BI). Sprenger et al. [40] membandingkan PEOU, PU, dan BI dari empat teknologi pembelajaran digital yang berbeda untuk melihat teknologi mana yang paling diterima oleh pengguna. Ada *research opportunity* untuk menggunakan perbandingan tiga construct TAM antara *smart lighting* tanpa AI dan *smart lighting* dengan AI untuk mengukur kenyamanan pengguna.

C. Tujuan

Masing-masing rumusan permasalahan dapat dipetakan menjadi tujuan penelitian atau research objective yang menjadi arahan dari disertasi ini. Berikut adalah tujuan penelitian dari disertasi ini: Pertama, menemukan strategi paling efektif untuk meningkatkan akurasi *activity recognition* berbasis sensor PIR pada *smart lighting*. Kedua, mengevaluasi pengaruh arsitektur novel *smart lighting* berbasis *edge computing* pada *processing time* dibandingkan dengan *cloud* dan *fog computing*. Ketiga, mengevaluasi signifikansi metode *machine learning* novel pada *smart lighting* dengan *user comfort* melalui perbandingan TAM.

D. Organisasi Tulisan

Sistematika disertasi ini mengikuti runut sebagai berikut: Bagian 2 melaporkan *systematic literature review* (SLR) yang telah dilakukan untuk mengidentifikasi literatur yang terkait dengan judul disertasi, memperoleh pemahaman yang komprehensif tentang topik penelitian, melakukan sintesis kuantitatif maupun kualitatif dari berbagai

paper dengan cara yang obyektif, dan mengidentifikasi tren, pola, dan celah dalam penelitian yang ada. Bagian 3 menjawab RQ1, yaitu “Apa strategi paling efektif untuk meningkatkan akurasi *activity recognition* berbasis sensor PIR pada *smart lighting*?” Bab ini juga menjawab RQ2, yaitu “Bagaimana pengaruh arsitektur novel *smart lighting* berbasis *edge computing* pada *processing time* dibandingkan dengan *cloud* dan *fog computing*?” Bab ini juga menjawab RQ3, yaitu “Apakah metode *activity recognition* novel punya pengaruh signifikan bagi *user comfort* pada *smart lighting*?” Bab 4 memperlihatkan hasil pengujian dan diskusi. Terakhir Bab 5 adalah kesimpulan dan saran.


II. STUDI TERKAIT

Sub-bab ini membahas mengenai *critical review* terhadap paper-paper SoTA dalam bidang *activity recognition* dan pengukuran *user comfort* pada *smart lighting*. Beberapa penelitian telah menerapkan *machine learning* untuk kendali *smart lighting* berdasarkan *user behaviour*. Umumnya, metode yang digunakan adalah *activity recognition*, yaitu metode pengenalan aktifitas pengguna berdasarkan sensor-sensor dengan menerapkan *machine learning*. Dai *et al.* [15] menerapkan *activity recognition* pada *smart lighting* dengan menggunakan kamera resolusi rendah untuk menjaga *privacy* pengguna. Kamera yang digunakan untuk satu lampu dalam satu ruangan ada lima. Chun *et al.* [16] Berhasil mengimplementasikan *depth camera* untuk *activity recognition* pada *smart lighting*. *Depth camera* yang digunakan dalam sistem adalah Kinect di mana requirement sistem nya adalah dua *depth camera* dan harga pasaran Kinect adalah Rp. dua juta. Lupion *et al.* [17] membuat a Distributed On-Line Activity Recognition System (DOLARS), sebuah *activity recognition* pada *smart home* yang juga menerapkan *smart lighting*. Metode yang diusulkan mempunyai akurasi hingga 99,2% namun solusi hardware yang ditawarkan sangat ekstensif, melibatkan hingga *smartwatch* dan real-time location system (RTLS) yang mempunyai biaya tinggi. Total harga sensor yang digunakan untuk *activity recognition* adalah 16 juta rupiah. *Research gap* dari penelitian tersebut adalah bagaimana mempertahankan akurasi yang baik namun dengan harga yang terjangkau dan solusi minimum.

III. SISTEM YANG DIBANGUN


Perangkat *end device* pada *smart lighting* merupakan satu set dan mendeteksi keberadaan satu orang di satu lokasi dalam satu ruangan. Bagan yang menggambarkan penempatan perangkat dalam suatu ruangan seperti terlihat pada Sensor PIR, NodeMCU, dan *relay* berada di langit-langit sebagai bagian dari *end-device*. Sensor PIR ditempatkan kira-kira di atas tempat *user* melakukan aktivitas, misalnya bekerja.

End-device, terutama *relay*, dihubungkan ke lampu LED. Lampu LED ada di langit-langit di tengah ruangan. NodeMCU menerima data sensor gerak, mengontrol lampu LED melalui *relay*, dan berkomunikasi dengan *platform IoT* melalui WiFi. Router WiFi-4G yang terpasang di dinding menghubungkan jaringan WiFi dengan Internet.



GAMBAR 1.
Bagan yang menggambarkan penempatan perangkat di dalam ruangan.


Siklus hidup proyek *machine learning* memiliki beberapa tahapan sebagai berikut: Pengumpulan data, pra-pemrosesan data, pelatihan model, pengujian model, dan *deployment* model [41]. Di sini disertasi ini membuat metodologi berdasarkan tahapan siklus hidup tersebut. Dalam metodologi disertasi ini, pertama-tama disertasi ini mengeksplorasi mengapa dan apa itu *edge computing* berdasarkan *related works*. Langkah selanjutnya adalah mengembangkan kontrol cerdas untuk *smart lighting*, yang novel dan berdasarkan CIMA. Kemudian dibuat arsitektur *fog computing* dan *cloud computing*. Disertasi ini membuat tiga metode *model compression* novel untuk model KNN-nya CIMA. Metode tersebut agar model dapat berjalan dalam model *edge computing*. Terakhir, disertasi ini membandingkan evaluasi *processing time* dari ketiga arsitektur tersebut. Dalam evaluasi disertasi ini, disertasi ini menggunakan beberapa metrik, termasuk *accuracy*, *processing time* rata-rata, uji Shapiro-Wilk, *kernel density estimation* (KDE), *boxplot* dengan Q1, Q3, *lower whisker* dan *upper whisker*, deviasi standar *processing time*, uji Wilcoxon, dan *cummulative distribution function* (CDF). GAMBAR 2 menunjukkan ilustrasi metodologi disertasi ini.



GAMBAR 2.

Methodology EdgeSL untuk pembuktian processing time yang optimum.

Penelitian disertasi ini mengusulkan metodologi penelitian untuk research question pada bab ini. Untuk memulai penyelidikan ini, penelitian ini membuat kerangka kerja untuk TAM. Kemudian dilakukan jajak pendapat. Selama survei, penelitian disertasi ini mengukur TPR lampu dari lampu dengan dan tanpa CIMA. Data survei untuk setiap lampu, baik dengan CIMA maupun tanpa CIMA, diproses pada langkah berikutnya. Terakhir, penelitian disertasi ini menghasilkan model TAM yang sesuai untuk fase TAM. QoE *prediction* adalah fase selanjutnya. Relevansi hubungan antara ketiga *construct* TAM penelitian disertasi ini (PEOU, PU, dan BI) pertama kali ditunjukkan secara akurat. Terakhir, penelitian disertasi ini melakukan QoE *prediction* dan memilih model yang memiliki performa terbaik. **Error! Reference source not found.** merangkum penjelasan penelitian disertasi ini dalam bentuk diagram alur.




GAMBAR 3.

Metodologi untuk TAM dan QoE Prediction.

IV. EVALUASI

A. Hasil Pengujian


Berikut adalah empat model klasifikasi optimum dapat dibandingkan: KNN dengan $k = 1$, SVM dengan kernel RBF, DT dengan $max\ depth = 12$, dan EV. Perbandingan kinerja keempat pengklasifikasi ditunjukkan pada GAMBAR 4. Perbandingan tersebut dalam bentuk diagram batang. Empat metrik menguji model: *accuracy*, *precision*, *recall*, dan *f1-score*. SVM memiliki kinerja terendah di keempat metrik dari empat model. Di antara ketiga model yang lain, EV adalah model dengan nilai *recall* di bawah 0,99. KNN unggul dalam keempat metrik, juga dibandingkan dengan DT. Model klasifikasi yang optimum untuk kehadiran *user* berdasarkan data pergerakan adalah KNN dengan $k = 1$.



GAMBAR 4.

Perbandingan kinerja empat model usulan untuk CIMA.


Disertasi ini membandingkan *processing time* *cloud*, *fog*, dan *edge computing* pada tahap akhir penelitian disertasi ini. Disertasi ini menguji setiap arsitektur dengan perkiraan waktu 20 menit hingga setiap arsitektur memproses *lighting control* dengan CIMA sebanyak 295 kali. GAMBAR 5 menunjukkan visualisasi *processing time* dari ketiga arsitektur tersebut. Arsitektur *cloud* memiliki *processing time* rata-rata tertinggi yaitu 207,6 ms. Arsitektur *edge* memiliki *processing time* paling rendah, dengan nilai 9,0 ms. Sementara itu, *fog computing* memiliki *processing time* 60,1 ms. Disertasi ini perlu mengeksplorasi apakah ketiga dataset tersebut memiliki distribusi normal untuk menguji signifikansi perbedaan rata-rata ini.



GAMBAR 5.

Perbandingan processing time edge, fog, dan cloud computing

Jika setiap *construct* berdistribusi normal, maka digunakan uji ANOVA untuk membuktikan signifikansi perbedaan mean setiap *construct*. Untuk membandingkan setiap *construct*, kita harus melakukan uji Shapiro-Wilk untuk menganalisis apakah semua *construct* mempunyai distribusi normal. Hasil pengujian Shapiro-Wilk menunjukkan skor PEOU kedua sistem *smart lighting* berdistribusi normal. Sedangkan skor PU dan BI pada kedua sistem *smart lighting* tidak berdistribusi normal. Karena beberapa *construct* tidak mempunyai distribusi normal, penelitian disertasi ini memilih uji Wilcoxon untuk menguji signifikansi *construct* antara teknologi *smart lighting*. GAMBAR 6 membandingkan *construct* PU dalam bentuk *boxplot*. Setiap perbandingan juga menunjukkan hasil uji Wilcoxon yang menunjukkan bahwa ketiga nilai *construct* kedua teknologi mempunyai perbedaan yang signifikan.



GAMBAR 6.

Perbandingan boxplot dari teknologi smart lighting tanpa CIMA dan dengan CIMA berdasarkan (a) PEOU (b) PU (c) BI.

B. Analisis Hasil Pengujian

Kami membuat perbandingan langsung dari metode yang kami usulkan dengan SoTA untuk menekankan kontribusi dan kebaruan metode yang kami usulkan. Studi terkait adalah kontrol *smart lighting* berbasis kehadiran *user* menggunakan peralatan lain. Perbandingannya diberikan pada

TABEL 1. Nilai superior dari setiap kolom dicetak tebal. Dibandingkan dengan studi benchmark, metode yang kami usulkan memiliki kinerja terbaik, 99,8%. Penelitian [17] memiliki hasil perkiraan, yaitu 99,3%. Studi ini menggunakan konsep yang mirip dengan MA, yaitu sliding window untuk menghitung beberapa fitur statistik seperti mean, standar deviasi, dan maks. Model RF hutan acak adalah model optimal yang menerapkan fitur jendela geser dalam penelitian. Namun, ia menggunakan beberapa sensor berbeda, beberapa di antaranya merupakan sensor mahal, seperti jam tangan pintar dan sistem lokasi real-time. Studi yang juga menggunakan perangkat mahal untuk *activity recognition* adalah [42], yang menggunakan kamera kedalaman; [15], yang menggunakan lima kamera monokrom; dan [36], yang menggunakan Switchmate. Penelitian yang terakhir ini tidak menggunakan ketelitian dalam menghitung kinerja melainkan menggunakan LUR. LUR adalah metrik yang diusulkan mereka yang menggambarkan rasio antara waktu lampu menyala dan waktu seseorang hadir di ruangan. Kami berasumsi bahwa LUR setara dengan akurasi. Metode yang kami usulkan adalah metode dengan kinerja terbaik dan solusi berbiaya rendah.

TABEL 1.

Perbandingan metode novel CIMA dengan metode smart lighting berbasis activity recognition SoTA yang menggunakan perangkat mahal

Reference	Equipment	Cost	Accuracy (%)
Lupion et al. [17]	- PIR sensor - Pressure sensor - Switch sensor - Smartwatches	US\$65	99.3

	• RTLS		
Park <i>et al.</i> [42]	• Light sensor • Switchmate	US\$68	67.0
Dai <i>et al.</i> [15]	Five monochrome cameras	¹ US\$300	90.2
Chun <i>et al.</i> [36]	Depth camera	¹ US\$36	78.3
Proposed method	PIR sensor	US\$13	99.8

Tan *et al.* [43] mengatakan bahwa *fog computing* dapat mengatasi masalah sumber daya yang terbatas pada *end device*. Namun, di sisi lain, solusi tersebut meningkatkan *latency* saat ada gangguan jaringan. Penelitian tersebut membuktikan bahwa menjalankan ResNet dan SqueezeNet di *end device* dapat memiliki *processing time* yang lebih cepat daripada di *fog computing*. Seperti disertasi ini, Lee *et al.* [44] mengasumsikan *processing time* sebagai *computation time* ditambah *transmission time*. Paper tersebut dapat mengurangi *processing time* dalam industrial IoT (IIoT) dengan proporsi sebesar 0,64 dengan memindahkan proses dari *cloud* ke *edge*. Dalam penelitian disertasi ini, *processing time* rata-rata dalam *edge*, *fog*, dan *cloud computing* masing-masing memiliki nilai 9,0, 60,1, dan 207,6 ms. Melalui uji Wilcoxon, dapat dilihat bahwa perbedaan rata-rata tersebut adalah signifikan. Kontribusi penelitian disertasi ini adalah arsitektur *edge computing* novel untuk kontrol *smart lighting* menggunakan metode CIMA yang disebut EdgeSL, yang memiliki *processing time* rata-rata yang lebih rendah secara signifikan daripada *fog computing* dan *cloud computing* [45].

Terakhir, penelitian sebelumnya telah mengeksplorasi QoE *prediction* secara ekstensif, khususnya dalam pencahayaan buatan. Porcu *et al.* [38] menyelidiki dampak pencahayaan pada kualitas menonton TV, sementara Wang *et al.* [46] menyelidiki pengaruh CCT pada QoE, khususnya dalam lingkungan kerja dan istirahat. Kontribusi penelitian disertasi ini memanfaatkan QoE *prediction* untuk memperkirakan PEOU, PU, dan BI berdasarkan TPR. Khususnya, penelitian disertasi ini memastikan bahwa model optimal untuk setiap *construct* melibatkan regresi linier untuk PEOU dan BI, sedangkan regresi polinomial derajat kedua paling cocok untuk PU. Kontribusi penelitian disertasi bagian ini menggarisbawahi pembuatan model QoE *prediction* untuk memperkirakan PEOU, PU, dan BI berdasarkan TPR kontrol *smart lighting*.

V. KESIMPULAN

Metode novel CIMA, yaitu klasifikasi *moving average* terintegrasi untuk pengendalian *smart lighting* berdasarkan kehadiran *user*. Pada pengujian mendalam metode klasifikasi *machine learning*, KNN menjadi model dengan performa terbaik dan paling kuat, dengan nilai akurasi sebesar 0,998. Nilai tersebut lebih akurat dibandingkan keputusan kendali

cahaya langsung berdasarkan sensor PIR dengan nilai 0,676. Solusi ini adalah *low-price* karena berbasis PIR sensor dan akurasi nya lebih optimum dibandingkan metode SoTA.

Arsitektur *edge computing* novel untuk kontrol *smart lighting* yang disebut EdgeSL, yang menggunakan distilKNN, memiliki *processing time* rata-rata yang lebih rendah secara signifikan dibandingkan *fog computing* dan *cloud computing*. *Processing time* rata-rata EdgeSL adalah 9,0 ms, sedangkan *processing time* rata-rata dari *smart lighting* dengan *fog* dan *cloud architecture* adalah 60,1 ms dan 207,6 ms, berturut-turut. EdgeSL adalah *smart lighting architecture* dengan *processing time* optimum.

Desain metodologi pengujian *user comfort* yang melibatkan prediksi TAM dan QoE telah berhasil dibuat dan diimplementasikan, dimana TAM untuk *smart lighting* tanpa CIMA menunjukkan rata-rata PEOU, PU, dan BI senilai 4,07, 4,01, dan 4,02, berturut-turut. Sedangkan TAM untuk *smart lighting* dengan CIMA menunjukkan rata-rata PEOU, PU, dan BI senilai 4,33, 4,42, dan 4,31, berturut-turut. Pengujian Wilcoxon menunjukkan bahwa PEOU, PU, dan BI dari *smart lighting* dengan CIMA lebih tinggi secara signifikan dibandingkan dengan *smart lighting* tanpa CIMA. Kesimpulan nya adalah *smart lighting* dengan CIMA lebih diterima oleh *user* dibandingkan dengan *smart lighting* tanpa CIMA.

QoE *prediction* dibuat untuk memprediksi *construct* dari TAM berdasarkan akurasi atau TPR *smart lighting*. Hasil QoE *prediction* yang kami design menggunakan *regression* menunjukkan PEOU, PU, dan BI mempunyai skor 4,1, 4,0, dan 4,0 jika TPR 0.1. Kemudian PEOU, PU, dan BI mempunyai skor 4,3, 4,5, dan 4,3 jika TPR mempunyai skor 1,0.

REFERENSI

- [1] M. S. Padmini, R. Rajkumar, Prahlada, S. Kuzhalivaimozhi, S. S. Galagali, and K. N. Reddy, "Energy Efficient Smart Street Lighting System," in *2022 International Conference on Artificial Intelligence and Data Engineering (AIDE)*, Karkala, India: IEEE, Dec. 2022, pp. 162–170. doi: 10.1109/AIDE57180.2022.10060318.
- [2] G. Dhivya, K. Hariharan, P. Poonguzhali, M. Vaibhav, S. Lokeshwar, and S. Bhattacharya, "ILLUMINATE - ViSiBLe Light CommUnication enabled SMart Indoor lightiNg And control SysTEm," in *2023 25th International Conference on Advanced Communication Technology (ICACT)*, Pyeongchang, Korea, Republic of: IEEE, Feb. 2023, pp. 11–17. doi: 10.23919/ICACT56868.2023.10079560.
- [3] H. Attia, M. Takruri, and A. Omar, "Design and Implementation of Decentralized

- Streetlight Dimming System for Different Motion Sensor Strengths and Unlimited Light Poles,” in *2022 International Conference on Electrical and Computing Technologies and Applications (ICECTA)*, Ras Al Khaimah, United Arab Emirates: IEEE, Nov. 2022, pp. 63–67. doi: 10.1109/ICECTA57148.2022.9990126.
- [4] A. Estaji and T. Sauter, “Street Lighting Simulation for Energy Efficiency Improvement,” in *2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA)*, Stuttgart, Germany: IEEE, Sep. 2022, pp. 1–8. doi: 10.1109/ETFA52439.2022.9921570.
 - [5] A. G. Putrada, M. Abdurrohman, D. Perdana, and H. H. Nuha, “Machine Learning Methods in Smart Lighting Towards Achieving User Comfort: A Survey,” *IEEE Access*, 2022.
 - [6] W.-C. Yang, Y.-J. Chen, and C.-S. Moo, “An efficient driver for dimmable LED lighting,” in *2011 6th IEEE Conference on Industrial Electronics and Applications*, Beijing, China: IEEE, Jun. 2011, pp. 2331–2336. doi: 10.1109/ICIEA.2011.5975982.
 - [7] H. Espejo, L. Morris, C. Cachimuel, and J. Segura, “Lighting applied to textile industries to increase the welfare of personnel and business productivity,” presented at the 13th International Conference on Applied Human Factors and Ergonomics (AHFE 2022), 2022. doi: 10.54941/ahfe1001558.
 - [8] O. Stefani and C. Cajochen, “Should we re-think regulations and standards for lighting at workplaces? A practice review on existing lighting recommendations,” *Front. Psychiatry*, vol. 12, p. 671, 2021.
 - [9] S. Altomonte *et al.*, “Ten questions concerning well-being in the built environment,” *Build. Environ.*, vol. 180, p. 106949, Aug. 2020, doi: 10.1016/j.buildenv.2020.106949.
 - [10] M. A. ul Haq *et al.*, “A review on lighting control technologies in commercial buildings, their performance and affecting factors,” *Renew. Sustain. Energy Rev.*, vol. 33, pp. 268–279, May 2014, doi: 10.1016/j.rser.2014.01.090.
 - [11] P. Hanselaer, C. Lootens, W. R. Ryckaert, G. Deconinck, and P. Rombauts, “Power density targets for efficient lighting of interior task areas,” *Light. Res. Technol.*, vol. 39, no. 2, pp. 171–184, Jun. 2007, doi: 10.1177/1365782807076737.
 - [12] Dr. H. R. Vyawahare, “Machine Learning: A Solution Approach for Complex Problems,” *INTERANTIONAL J. Sci. Res. Eng. Manag.*, vol. 06, no. 04, Jun. 2022, doi: 10.55041/IJSREM16123.
 - [13] S. Prabowo, A. G. Putrada, I. D. Oktaviani, and M. Abdurrohman, “Camera-Based Smart Lighting System that complies with Indonesia’s Personal Data Protection Act,” in *2023 International Conference on Advancement in Data Science, E-learning and Information System (ICADEIS)*, IEEE, 2023, pp. 1–6. Accessed: Mar. 23, 2024. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10271086/>
 - [14] S. Yin *et al.*, “Reinforcement-learning-based parameter adaptation method for particle swarm optimization,” *Complex Intell. Syst.*, vol. 9, no. 5, pp. 5585–5609, Oct. 2023, doi: 10.1007/s40747-023-01012-8.
 - [15] J. Dai, J. Wu, B. Saghafi, J. Konrad, and P. Ishwar, “Towards privacy-preserving activity recognition using extremely low temporal and spatial resolution cameras,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2015, pp. 68–76.
 - [16] S. Chun, C.-S. Lee, and J.-S. Jang, “Real-time smart lighting control using human motion tracking from depth camera,” *J. Real-Time Image Process.*, vol. 10, no. 4, pp. 805–820, 2015.
 - [17] M. Lupión, J. Medina-Quero, J. F. Sanjuan, and P. M. Ortigosa, “DOLARS, a Distributed On-Line Activity Recognition System by Means of Heterogeneous Sensors in Real-Life Deployments—A Case Study in the Smart Lab of The University of Almería,” *Sensors*, vol. 21, no. 2, p. 405, 2021.
 - [18] Y. Jin, D. Yan, X. Zhang, J. An, and M. Han, “A data-driven model predictive control for lighting system based on historical occupancy in an office building: Methodology development,” in *Building Simulation*, Springer, 2021, pp. 219–235.
 - [19] A. G. Putrada, N. G. Ramadhan, and M. A. Makky, “An Evaluation of Activity Recognition with Hierarchical Hidden Markov Model and Other Methods for Smart Lighting in Office Buildings,” 2022, Accessed: Nov. 29, 2021. [Online]. Available: <https://doi.org/10.24507/icicel.16.01.91>
 - [20] R. I. Fakhruddin, M. Abdurrohman, and A. G. Putrada, “Improving PIR Sensor Network-Based Activity Recognition with PCA and KNN,” in *2021 International Conference on Intelligent Cybernetics Technology & Applications (ICICyTA)*, IEEE, 2021, pp. 138–143.
 - [21] A. Husnayain, A. Fuad, and L. Lazuardi, “Correlation between Google Trends on dengue fever and national surveillance report in Indonesia,” *Glob. Health Action*, vol. 12, no. 1, p. 1552652, Jan. 2019, doi: 10.1080/16549716.2018.1552652.

- [22] Z. Hu *et al.*, “A Water Quality Prediction Method Based on the Deep LSTM Network Considering Correlation in Smart Mariculture,” *Sensors*, vol. 19, no. 6, p. 1420, Mar. 2019, doi: 10.3390/s19061420.
- [23] Y. Peng, S. Long, J. Ma, J. Song, and Z. Liu, “Temporal-spatial variability in correlations of drought and flood during recent 500 years in Inner Mongolia, China,” *Sci. Total Environ.*, vol. 633, pp. 484–491, Aug. 2018, doi: 10.1016/j.scitotenv.2018.03.200.
- [24] H. S. Badr, H. Du, M. Marshall, E. Dong, M. M. Squire, and L. M. Gardner, “Association between mobility patterns and COVID-19 transmission in the USA: a mathematical modelling study,” *Lancet Infect. Dis.*, vol. 20, no. 11, pp. 1247–1254, Nov. 2020, doi: 10.1016/S1473-3099(20)30553-3.
- [25] O. P. Singh, T. A. Howe, and M. Malarvili, “Real-time human respiration carbon dioxide measurement device for cardiorespiratory assessment,” *J. Breath Res.*, vol. 12, no. 2, p. 026003, Jan. 2018, doi: 10.1088/1752-7163/aa8dbd.
- [26] G. Crocioni, D. Pau, J.-M. Delorme, and G. Gruosso, “Li-ion batteries parameter estimation with tiny neural networks embedded on intelligent iot microcontrollers,” *IEEE Access*, vol. 8, pp. 122135–122146, 2020.
- [27] C. Dai, X. Liu, H. Cheng, L. T. Yang, and M. J. Deen, “Compressing Deep Model With Pruning and Tucker Decomposition for Smart Embedded Systems,” *IEEE Internet Things J.*, vol. 9, no. 16, pp. 14490–14500, Aug. 2022, doi: 10.1109/JIOT.2021.3116316.
- [28] F. Yu, L. Cui, P. Wang, C. Han, R. Huang, and X. Huang, “EasiEdge: A Novel Global Deep Neural Networks Pruning Method for Efficient Edge Computing,” *IEEE Internet Things J.*, vol. 8, no. 3, pp. 1259–1271, Feb. 2021, doi: 10.1109/JIOT.2020.3034925.
- [29] P. Prakash *et al.*, “IoT Device Friendly and Communication-Efficient Federated Learning via Joint Model Pruning and Quantization,” *IEEE Internet Things J.*, vol. 9, no. 15, pp. 13638–13650, 2022.
- [30] Y. Matsubara, D. Callegaro, S. Baidya, M. Levorato, and S. Singh, “Head Network Distillation: Splitting Distilled Deep Neural Networks for Resource-Constrained Edge Computing Systems,” *IEEE Access*, vol. 8, pp. 12177–12191, 2020, doi: 10.1109/ACCESS.2020.3039714.
- [31] V. Divya and R. L. Sri, “Docker-Based Intelligent Fall Detection Using Edge-Fog Cloud Infrastructure,” *IEEE Internet Things J.*, vol. 8, no. 10, pp. 8133–8144, May 2021, doi: 10.1109/JIOT.2020.3042502.
- [32] J. Mills, J. Hu, and G. Min, “Communication-Efficient Federated Learning for Wireless Edge Intelligence in IoT,” *IEEE Internet Things J.*, vol. 7, no. 7, pp. 5986–5994, Jul. 2020, doi: 10.1109/JIOT.2019.2956615.
- [33] Z. W. al, “QSFm: Model Pruning Based on Quantified Similarity Between Feature Maps for AI on Edge,” *IEEE Internet Things J.*, vol. 9, no. 23, pp. 24506–24515, Dec. 2022, doi: 10.1109/JIOT.2022.3190873.
- [34] M. Zawish, N. Ashraf, R. I. Ansari, and S. Davy, “Energy-Aware AI-Driven Framework for Edge-Computing-Based IoT Applications,” *IEEE Internet Things J.*, vol. 10, no. 6, pp. 5013–5023, Mar. 2023, doi: 10.1109/JIOT.2022.3219202.
- [35] I. Jang, H. Kim, D. Lee, Y.-S. Son, and S. Kim, “Knowledge Transfer for On-Device Deep Reinforcement Learning in Resource Constrained Edge Computing Systems,” *IEEE Access*, vol. 8, pp. 46588–46599, 2020, doi: 10.1109/ACCESS.2020.3014922.
- [36] J. Y. Park, T. Dougherty, H. Fritz, and Z. Nagy, “LightLearn: An adaptive and occupant centered controller for lighting based on reinforcement learning,” *Build. Environ.*, vol. 147, pp. 397–414, Jan. 2019, doi: 10.1016/j.buildenv.2018.10.028.
- [37] Q. Wang, H. Xu, F. Zhang, and Z. Wang, “Influence of color temperature on comfort and preference for LED indoor lighting,” *Optik*, vol. 129, pp. 21–29, 2017.
- [38] S. Porcu, A. Floris, and L. Atzori, “Towards the Evaluation of the Effects of Ambient Illumination and Noise on Quality of Experience,” in *2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX)*, Berlin, Germany: IEEE, Jun. 2019, pp. 1–6, doi: 10.1109/QoMEX.2019.8743227.
- [39] A. Saad, “The Influence of Users Privacy and Discomfort on Using Healthcare Information System,” in *Proceedings of the 5th International Conference on e-Society, e-Learning and e-Technologies*, 2019, pp. 68–72.
- [40] D. A. Sprenger and A. Schwaninger, “Technology acceptance of four digital learning technologies (classroom response system, classroom chat, e-lectures, and mobile virtual reality) after three months’ usage,” *Int. J. Educ. Technol. High. Educ.*, vol. 18, no. 1, p. 8, 2021.
- [41] O. Spjuth, J. Frid, and A. Hellander, “The machine learning life cycle and the cloud: implications for drug discovery,” *Expert Opin Drug Discov*, vol. 16, no. 9, pp. 1071–1079, 2021.
- [42] S. Chun and C.-S. Lee, “Applications of human motion tracking: Smart lighting control,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2013, pp. 387–392.

- [43] T. Tan and G. Cao, "Deep learning video analytics through edge computing and neural processing units on mobile devices," *IEEE Trans. Mob. Comput.*, 2021.
- [44] C. K. Lee, Y. Huo, S. Zhang, and K. K. Ng, "Design of a smart manufacturing system with the application of multi-access edge computing and blockchain technology," *IEEE Access*, vol. 8, pp. 28659–28667, 2020.
- [45] A. G. Putrada, M. Abdurrohman, D. Perdana, and H. H. Nuha, "EdgeSL: Edge-Computing Architecture on Smart Lighting Control With Distilled KNN for Optimum Processing Time," *IEEE Access*, vol. 11, pp. 64697–64712, 2023, doi: <https://doi.org/10.1109/ACCESS.2023.3288425>.
- [46] Q. Wang, H. Xu, F. Zhang, and Z. Wang, "Influence of color temperature on comfort and preference for LED indoor lighting," *Optik*, vol. 129, pp. 21–29, 2017.