

# PREDIKSI BEBAN LISTRIK MENGGUNAKAN JARINGAN SYARAF TIRUAN CEREBELLAR MODEL ARTICULATION CONTROLLER (CMAC) DENGAN FORMULASI PEMETAAN MASUKAN BARU

Muhamad Iradat Achmad<sup>1\*</sup>

<sup>1</sup>Teknik Informatika, Fakultas Teknik, Universitas Dayanu Ikhsanuddin

<sup>1</sup>[irad4t@gmail.com](mailto:irad4t@gmail.com)

\*Penulis Korespondensi

diajukan: 28 Juli 2025,

diterima: 19 Agustus 2025.

## Abstract

Electric load forecasting is a critical component in power system management to maintain the balance between energy supply and demand. This study implements the Cerebellar Model Articulation Controller (CMAC) neural network with a novel input mapping formulation to improve load prediction accuracy. The dataset consists of 34,167 historical records, with 23,916 samples used for training and 10,251 samples for testing. The training process was carried out for 10 epochs with a learning rate of 0.12, quantization level of 256, and generalization parameter of 6. Experimental results demonstrate that CMAC can achieve reliable forecasting performance, as indicated by RMSE of 0.30272, MAE of 0.23252, and MAPE of 25.735. Further analysis on the early, middle, and final segments of the testing data confirmed consistent performance, despite variations under extreme load conditions. The findings highlight that the refined input mapping formulation plays a crucial role in maintaining computational efficiency, prediction stability, and CMAC adaptability to load dynamics. This study contributes to the advancement of more reliable and efficient load forecasting methods for modern power systems.

**Keywords:** *CMAC, electric load forecasting, input mapping, neural networks, power systems*

## Abstrak

Prediksi beban listrik menjadi elemen penting dalam pengelolaan sistem tenaga, terutama untuk menjaga keseimbangan antara suplai dan permintaan energi. Penelitian ini mengimplementasikan jaringan syaraf tiruan Cerebellar Model Articulation Controller (CMAC) dengan formulasi baru pada pemetaan masukan untuk meningkatkan akurasi prediksi beban. Dataset yang digunakan terdiri dari 34.167 data historis, dengan 23.916 data untuk pelatihan dan 10.251 data untuk pengujian. Proses pelatihan dilakukan selama 10 epoch dengan laju belajar 0,12, level kuantisasi 256, dan generalisasi 6. Hasil pengujian menunjukkan bahwa model CMAC mampu memberikan prediksi dengan tingkat akurasi yang memadai, ditunjukkan oleh nilai RMSE sebesar 0,30272, MAE sebesar 0,23252, dan MAPE sebesar 25,735. Analisis lebih lanjut pada segmen awal, tengah, dan akhir data pengujian mengonfirmasi konsistensi performa meskipun terdapat variasi pada kondisi beban ekstrem. Penelitian ini menegaskan bahwa perbaikan formulasi pemetaan masukan berperan penting dalam menjaga efisiensi komputasi, stabilitas prediksi, dan kemampuan adaptasi CMAC terhadap dinamika beban listrik. Temuan ini memberikan kontribusi nyata dalam pengembangan metode prediksi beban yang lebih andal dan efisien untuk sistem tenaga listrik modern.

**Kata kunci:** *CMAC, prediksi beban listrik, pemetaan masukan, jaringan syaraf tiruan, sistem tenaga*

## 1. PENDAHULUAN

### 1.1 Latar Belakang

Prediksi beban listrik merupakan aspek krusial dalam manajemen sistem tenaga listrik modern, di mana keseimbangan antara pasokan dan permintaan listrik sangat penting untuk menghindari gangguan yang besar secara teknis maupun ekonomi. Ketidakseimbangan sekecil apa pun dapat menyebabkan kerugian signifikan, sehingga kebutuhan untuk akurasi dalam perhitungan sangat mendesak. Operator sistem tenaga listrik bertugas untuk memprediksi beban ini secara

akurat dalam berbagai periode jangka pendek, menengah, dan panjang. Untuk jangka pendek, seperti dalam skala harian hingga mingguan, prediksi beban sangat penting untuk mengatur operasi pembangkit dan penjadwalan pemeliharaan, serta untuk menjaga keandalan pasokan saat permintaan yang mendadak meningkat (Caessar et al., 2024; Pratama & Endah, 2021). Dalam jangka menengah dan panjang, prediksi beban membantu dalam perencanaan investasi dan ekspansi jaringan distribusi, serta dalam perumusan kebijakan energi yang lebih berkelanjutan (Ihsan et al., 2020). Tentu saja, kualitas prediksi berpengaruh pada efektivitas pengelolaan sistem tenaga listrik. Berbagai penelitian menunjukkan bahwa penerapan metode statistik dan kecerdasan buatan dalam prediksi beban listrik membantu menghadapi tantangan ini. Misalnya, penelitian yang dilakukan oleh Fadilah et al. mengungkapkan bahwa penggunaan jaringan saraf tiruan dalam memprediksi beban dapat memberikan hasil yang kompetitif meskipun terdapat ketidakstabilan dalam permintaan listrik (Fadilah et al., 2021). Di sisi lain, analisis yang dilakukan oleh Rizqulloh et al. mengarah pada perbandingan beberapa metode seperti Neural Network Backpropagation dan Regresi Linear, menekankan pentingnya algoritma yang tepat untuk meningkatkan akurasi prediksi (Rizqulloh et al., 2020).

Adapun pergeseran ke sumber energi terbarukan juga membawa kompleksitas baru dalam prediksi beban listrik. Misalnya, penetrasi kendaraan listrik yang semakin meningkat dapat mengubah pola konsumsi listrik secara drastis (Ihsan et al., 2020). Hal ini membuat prediksi beban menjadi lebih menantang dan penting dalam perencanaan jangka panjang untuk menghindari kekurangan energi yang berujung pada pemadaman. Pejabat dan perencana di sektor energi perlu beradaptasi dengan penggunaan model prediksi yang lebih dinamis dan responsif terhadap perubahan pola konsumsi, serta memanfaatkan teknologi kecerdasan buatan yang terus berkembang untuk mencapai tujuan ini (Cahyono & Wirawan, 2021). Dengan adanya tuntutan yang semakin meningkat untuk efisiensi operasional dan pengurangan emisi, pendekatan yang tepat dalam prediksi beban listrik tidak hanya memberikan manfaat teknis tetapi juga dampak yang positif terhadap ekonomi dan lingkungan. Oleh karena itu, penelitian yang konstan mengenai metode prediksi beban serta implementasi teknologi baru adalah langkah yang tidak terpisahkan dalam menciptakan sistem tenaga listrik yang lebih andal dan berkelanjutan di masa depan (Salma et al., 2022).

Prediksi beban listrik merupakan tugas yang sangat kompleks, dipengaruhi oleh berbagai faktor yang berinteraksi secara nonlinear dan sering kali tidak terduga. Ketidaklinieran sifat beban listrik muncul karena perubahan konsumsi energi tidak selalu sebanding dengan faktor-faktor seperti suhu udara atau aktivitas masyarakat. Misalnya, saat suhu udara meningkat, kemungkinan penggunaan pendingin ruangan meningkat, tetapi perilaku masyarakat juga turut memengaruhi seberapa banyak beban yang dijadwalkan (Fadilah et al., 2021; Purnomo et al., 2021). Perilaku pengguna listrik, pola perilaku industri, serta kebijakan tarif listrik oleh penyedia juga berkontribusi signifikan terhadap fluktuasi konsumsi listrik, yang menghimpun tantangan dalam memprediksi kebutuhan energi yang akurat (Hasan, 2023; Pratama & Endah, 2021). Ketidakpastian dari banyak variabel eksternal, termasuk kondisi cuaca, pertumbuhan ekonomi, dan perubahan kebiasaan masyarakat, berpotensi menambah kerumitan dalam proses prediksi. Model-model prediksi tradisional kadang gagal dalam menghadapi data yang sangat bervariasi dan mengalami ketidakpastian tinggi. Hasil penelitian menunjukkan bahwa teknik berbasis kecerdasan buatan, seperti jaringan syaraf tiruan (JST), telah terbukti lebih efektif dalam menangani masalah ini, memberikan prediksi yang lebih akurat mengenai beban listrik jangka pendek (Fadilah et al., 2021; Purnomo et al., 2021; Caessar et al., 2024). Terlebih lagi, kombinasi antara teknik-teknik canggih dan pendalaman data memungkinkan model untuk tidak hanya mengidentifikasi tren tetapi juga beradaptasi terhadap fluktuasi jangka pendek dalam pola konsumsi listrik (Caessar et al., 2024; Dewi & Nugroho, 2021).

Keterbatasan dalam kualitas dan ketersediaan data historis juga menjadi tantangan dalam prediksi beban listrik. Data historis seringkali mengandung noise, nilai yang hilang, dan inkonsistensi yang dapat menyebabkan bias dalam hasil analisis. Oleh karena itu, penting untuk

melakukan pengolahan data dengan cermat sebelum diterapkan pada model prediksi. Hal ini termasuk penggunaan algoritma yang canggih untuk mengeliminasi noise dan memaksimalkan integritas data sebelum analisis dilakukan (Hamdhani et al., 2022; Dharmawan et al., 2023). Selain itu, pengenalan metode seleksi fitur yang efektif juga membantu dalam menyaring variabel-variabel yang paling berpengaruh terhadap konsumsi listrik, menambah presisi dalam model prediksi yang dibangun (Dharmawan et al., 2023; Leni et al., 2023). Untuk merespons kompleksitas dalam prediksi beban, penggunaan sistem klasifikasi berbasis machine learning dapat diimplementasikan untuk identifikasi pola perilaku pengguna. Misalnya, penelitian yang mengembangkan metode K-Nearest Neighbors untuk klasifikasi beban listrik menunjukkan bahwa penggunaan teknik ini dapat meningkatkan efisiensi manajemen penggunaan energi dan penghematan (Salma et al., 2022; Alwi et al., 2021). Dengan cara ini, para penyedia layanan listrik dapat mengembangkan strategi yang lebih adaptif dengan melihat pola konsumsi yang berubah sesuai dengan variabel eksternal yang terlibat. Secara keseluruhan, tugas memprediksi beban listrik mewajibkan pendekatan yang tidak hanya matematis tetapi juga yang meliputi pemahaman mendalam tentang interaksi variabel-variabel kompleks yang menghimpun data konsumsi listrik. Oleh sebab itu, pengembangan serta penerapan metode cerdas berbasis AI, seperti JST dan model pembelajaran mendalam, menjadi sangat penting untuk mengatasi tantangan dalam akurasi dan validitas prediksi dalam sistem tenaga listrik modern (Purnomo et al., 2021; Caessar et al., 2024; Ihsan et al., 2020).

Cerebellar Model Articulation Controller (CMAC) merupakan pendekatan yang menarik dalam prediksi beban listrik, terinspirasi oleh cara kerja otak manusia, khususnya otak kecil (cerebellum). Model ini mengandalkan kemampuannya untuk melakukan pemetaan masukan ke keluaran dengan cepat dan efisien, menghasilkan kecepatan proses pembelajaran dan eksekusi yang lebih baik dibandingkan dengan jaringan syaraf tiruan konvensional. CMAC, dengan struktur jaringannya yang sederhana, beroperasi menggunakan memori asosiatif, di mana setiap masukan dipetakan ke lokasi memori tertentu yang berhubungan dengan keluaran spesifik (Li et al., 2023; Achmad, M.I. et al., 2014). Hal ini membangun dasar yang kuat untuk merespons perubahan pola masukan dengan cepat, sehingga cocok untuk menangani variasi beban listrik yang dapat terjadi secara fluktuatif. Keunggulan lain dari CMAC adalah kemampuan generalisasi yang baik meskipun hanya dengan data pelatihan yang terbatas, yang merupakan keuntungan signifikan pada situasi di mana data historis tidak memadai (Ahmad et al., 2022; Achmad & Sunantyo, 2009). Banyak metode pemodelan lainnya, seperti jaringan syaraf dan teknik pembelajaran mesin lainnya, memerlukan data yang lebih banyak untuk mencapai akurasi tinggi (Lee & Cho, 2022). Sementara itu, CMAC dikenal hemat dalam hal penggunaan memori karena teknik pemetaan input-overlapping yang menjadikannya efisien dalam kapasitas penyimpanan (Li et al., 2023; Achmad et al., 2014).

Namun, meskipun memiliki banyak keunggulan, CMAC juga memiliki keterbatasan sebagai model yang cenderung sederhana dalam pemetaan masukan. Model ini mungkin kurang fleksibel dalam menghadapi variasi pola konsumsi yang kompleks. Penelitian lebih lanjut diperlukan untuk meningkatkan dan memperluas kapasitas CMAC, terutama dalam pengembangan formulasi baru yang dapat menangani kompleksitas pola konsumsi di dunia nyata (Lee & Cho, 2022). Dengan memanfaatkan pendekatan pembelajaran yang lebih dalam atau hibrida, diharapkan efektivitas CMAC dalam prediksi beban listrik dapat lebih ditingkatkan (Farsi et al., 2021). Keandalan dalam sistem prediksi beban listrik menjadi semakin penting, terutama mengingat meningkatnya kompleksitas dan variabilitas dalam permintaan energi (Khan, 2023; Syed et al., 2021). Dengan memanfaatkan karakteristik unik dari CMAC, diharapkan dapat menawarkan alternatif yang menjanjikan dalam optimisasi dan peningkatan efisiensi prediksi beban listrik, terutama dalam lingkungan jaringan listrik yang semakin pintar.

CMAC merupakan model yang sering digunakan dalam pemodelan sistem nonlinier dan pengendalian; namun, model ini memiliki kelemahan yang memengaruhi akurasi dan efektivitas implementasinya, termasuk dalam aplikasi prediksi beban listrik. Salah satu kelemahan mencolok

dari CMAC adalah mekanisme pemetaan masukan yang relatif sederhana. Implementasi klasik CMAC menggunakan metode kuantisasi, yang membagi interval masukan ke dalam ruang memori. Ini dapat mengakibatkan pengurangan fleksibilitas dan kemampuan dalam merepresentasikan pola input yang kompleks dan nonlinier (Morimoto et al., 2020; Ran et al., 2022). Mengingat bahwa pola konsumsi listrik sering kali terpengaruh oleh variasi dan fluktuasi yang sangat dinamis akibat banyak faktor eksternal, pemetaan berbasis kuantisasi ini sering kali gagal untuk menangkap detail penting dalam data, berpotensi merugikan akurasi prediksi yang diharapkan (Omogoroye et al., 2023; Shabani et al., 2023). Selain kurangnya fleksibilitas, pemetaan masukan standar pada CMAC dapat menyebabkan ketidakefisienan dalam penggunaan memori. Meskipun teknik overlapping memungkinkan CMAC untuk lebih hemat memori, pendekatan pemetaan yang terlalu sederhana dapat menciptakan redundansi dan distribusi memori yang tidak merata, di mana sebagian besar ruang memori menjadi jarang digunakan sementara area lainnya overload (Morimoto et al., 2020; Li et al., 2023). Hal ini dapat mengurangi efektivitas proses pembelajaran, terutama dalam situasi di mana data memerlukan pemrosesan yang lebih mendalam (Kong et al., 2020; Alves et al., 2022).

Tantangan lain terkait generalisasi dan sensitivitas terhadap perubahan pola input adalah masalah yang krusial. Dengan pemetaan masukan yang kaku, CMAC sering kali kesulitan beradaptasi dengan variasi jangka pendek yang umum terjadi dalam data, seperti lonjakan permintaan listrik akibat cuaca ekstrem atau pergeseran dalam aktivitas masyarakat (Zhao et al., 2022; Tang et al., 2022). Penelitian menunjukkan bahwa fleksibilitas dalam pemodelan input sangat penting untuk meningkatkan akurasi prediksi dalam sistem tenaga listrik yang dinamis, dan ini juga mengindikasikan bahwa pengembangan skema pemetaan berbasis formula matematis yang lebih adaptif dapat meningkatkan performa CMAC (Morimoto et al., 2020; Shabani et al., 2023). Upaya pengembangan demikian bertujuan untuk menciptakan representasi input yang lebih sistematis, kaya informasi, dan adaptif tanpa mengorbankan kecepatan dan efisiensi yang menjadi ciri khas CMAC. Dengan demikian, harapannya adalah proses prediksi beban listrik dapat dilaksanakan dengan lebih akurat, mencerminkan realitas kompleks penggunaan energi dalam masyarakat (Omogoroye et al., 2023; Zhao et al., 2022).

Menyadari adanya keterbatasan dalam pemetaan masukan pada CMAC standar, muncul kebutuhan mendesak untuk menghadirkan pendekatan yang lebih sistematis dan adaptif. Sejauh ini, sebagian besar penelitian tentang CMAC lebih berfokus pada aspek struktur jaringan, algoritma pembelajaran, atau optimasi parameter, sementara mekanisme pemetaan masukan sering kali masih mengandalkan teknik dasar seperti kuantisasi langsung atau pembagian interval sederhana. Hal ini menimbulkan sebuah celah penelitian yang cukup signifikan, yaitu belum adanya formulasi matematis yang terstruktur dan dapat dijadikan acuan dalam proses pemetaan masukan pada CMAC. Padahal, dalam konteks prediksi beban listrik yang sangat dinamis, kualitas pemetaan masukan menjadi salah satu faktor penentu performa model. Tanpa representasi input yang tepat, CMAC berisiko gagal menangkap variasi pola konsumsi yang kompleks, sehingga akurasi prediksi tidak mencapai potensi maksimalnya. Celah ini semakin jelas jika dibandingkan dengan perkembangan metode prediksi lain, seperti jaringan syaraf tiruan multilayer, Support Vector Machine, atau model berbasis deep learning yang secara eksplisit memanfaatkan transformasi input lebih kaya untuk meningkatkan kemampuan generalisasi.

Ketiadaan formulasi pemetaan masukan yang kuat juga berdampak pada keterbatasan dalam pengembangan teori maupun praktik. Bagi para peneliti, hal ini menyulitkan proses analisis komparatif karena hasil yang diperoleh sering kali bergantung pada pemetaan input yang ditentukan secara heuristik. Sementara bagi praktisi di lapangan, kurangnya formulasi baku membuat implementasi CMAC untuk prediksi beban listrik kurang optimal, terutama ketika dihadapkan pada data dengan karakteristik yang bervariasi. Oleh karena itu, pengembangan rumus pemetaan masukan yang sistematis bukan hanya akan memperkaya literatur akademik, tetapi juga memberikan kontribusi nyata bagi aplikasi praktis. Dengan adanya formulasi yang terdefinisi jelas,

CMAC berpotensi menjadi lebih andal dan kompetitif dalam menghadapi tantangan prediksi beban listrik di era modern yang menuntut kecepatan, efisiensi, sekaligus akurasi tinggi.

## 1.2 Tujuan Penelitian

Berdasarkan permasalahan yang telah dipaparkan, tujuan penelitian ini adalah mengimplementasikan dan menguji model CMAC standar sebagai salah satu metode prediksi beban listrik. Penelitian ini berupaya menunjukkan bagaimana mekanisme pemetaan masukan sederhana melalui proses kuantisasi dapat digunakan secara efektif untuk membangun sistem prediksi yang cepat dan efisien. Dengan menggunakan pendekatan standar tersebut, penelitian ini juga bermaksud mengevaluasi sejauh mana CMAC mampu menangani karakteristik data beban listrik yang nonlinear, fluktuatif, dan dipengaruhi berbagai faktor eksternal. Selain implementasi, penelitian ini bertujuan untuk melakukan pengujian kinerja CMAC standar pada data historis beban listrik melalui skema pelatihan dan pengujian yang terukur. Evaluasi dilakukan dengan menggunakan metrik umum dalam prediksi, seperti RMSE, MAE, dan MAPE, sehingga performa CMAC dapat dianalisis secara kuantitatif. Hasil pengujian ini tidak hanya akan menunjukkan tingkat akurasi prediksi, tetapi juga memberikan gambaran tentang efisiensi komputasi dan kemampuan generalisasi dari model CMAC standar. Dengan kata lain, penelitian ini diarahkan untuk memberikan kontribusi empiris terhadap pemahaman mengenai potensi dan keterbatasan CMAC standar dalam aplikasi prediksi beban listrik. Temuan yang diperoleh diharapkan dapat menjadi pijakan awal untuk pengembangan metode yang lebih lanjut, baik melalui peningkatan pemetaan masukan, optimasi parameter, maupun integrasi dengan model kecerdasan buatan lainnya.

## 1.3 Kebaruan Penelitian

Kebaruan (novelty) dalam penelitian ini terletak pada integrasi formulasi matematis CMAC standar dengan studi kasus nyata pada prediksi beban listrik. Meskipun CMAC telah lama dikenal sebagai salah satu model jaringan syaraf tiruan yang sederhana dan efisien, penerapannya masih jarang difokuskan secara khusus pada konteks prediksi beban listrik yang memiliki dinamika kompleks, nonlinier, serta sangat dipengaruhi oleh faktor waktu. Dalam penelitian ini, formulasi matematis CMAC standar—yang mencakup proses kuantisasi masukan, pemetaan ke dalam ruang memori asosiatif, serta mekanisme pembaruan bobot—diterapkan secara langsung pada data historis beban listrik. Dengan pendekatan ini, penelitian tidak hanya menekankan pada implementasi algoritme, tetapi juga mengaitkannya dengan perhitungan matematis yang jelas dan terukur, sehingga hasil prediksi dapat dianalisis secara sistematis baik dari sisi akurasi maupun dari sisi efisiensi komputasi. Aspek kebaruan lainnya adalah pada evaluasi kuantitatif performa CMAC standar dalam konteks prediksi beban listrik dengan membandingkan hasil prediksi terhadap data aktual menggunakan metrik RMSE, MAE, dan MAPE. Dengan demikian, penelitian ini menghadirkan jembatan antara teori matematis CMAC dengan kebutuhan praktis di bidang ketenagalistrikan, khususnya dalam penyusunan model prediksi beban yang sederhana, cepat, dan cukup akurat untuk diaplikasikan pada sistem energi berskala besar.

## 1.4 Manfaat Penelitian

Penelitian ini memiliki manfaat yang dapat dirasakan baik dari sisi akademik maupun praktis. Dari sisi akademik, penelitian ini memberikan kontribusi dalam memperkaya pemahaman mengenai bagaimana model CMAC standar dapat diformulasikan secara matematis dan diterapkan secara nyata pada masalah prediksi beban listrik. Hasil penelitian ini diharapkan menjadi rujukan bagi kajian-kajian selanjutnya, terutama dalam bidang jaringan syaraf tiruan yang berfokus pada metode sederhana, efisien, namun tetap relevan untuk persoalan prediksi berbasis deret waktu. Dengan kata lain, penelitian ini tidak hanya menambah khasanah literatur ilmiah, tetapi juga menegaskan kembali bahwa model-model yang ringan secara komputasi masih memiliki peran penting di tengah berkembangnya model-model yang kompleks dan mahal secara perhitungan.

Sementara itu, dari sisi praktis, penelitian ini berpotensi membantu penyedia energi listrik dalam menyusun strategi operasional yang lebih adaptif. Melalui pemanfaatan CMAC standar yang cepat dilatih dan dieksekusi, prediksi beban listrik jangka pendek dapat dilakukan dengan lebih efisien tanpa memerlukan perangkat keras berspesifikasi tinggi. Hal ini tentu penting bagi sistem ketenagalistrikan yang setiap hari dihadapkan pada fluktuasi permintaan energi, karena prediksi yang akurat dan cepat dapat menjadi dasar pengambilan keputusan dalam menjaga keseimbangan antara ketersediaan pasokan dan kebutuhan beban. Dengan demikian, penelitian ini diharapkan mampu memberikan manfaat ganda: memperkuat landasan teoritis dalam kajian kecerdasan buatan, sekaligus menawarkan solusi praktis yang aplikatif di sektor energi.

### 1.5 Tinjauan Pustaka

CMAC adalah salah satu inovasi dalam bidang kontrol yang terinspirasi oleh fungsi otak kecil (cerebellum) dalam mengoordinasikan respon cepat melalui asosiasi pola. Arsitektur CMAC difokuskan pada efisiensi lokal, di mana ruang masukan yang kontinu dipetakan ke indeks-indeks diskret melalui kuantisasi, yang mengaktifkan sel-sel memori yang memiliki bobot sebagai kontribusi terhadap keluaran. Karakteristik ini memungkinkan CMAC untuk belajar dengan cepat dan mempertahankan performa yang baik meskipun dengan pembaruan yang terbatas pada memori lokal (Li et al., 2024; Wang et al., 2021; Le et al., 2020; Achmad et al., 2014). Salah satu aspek kunci dari CMAC adalah kemampuannya untuk generalisasi. Berkat cara aktivasi lokal dan overlapping dari sel memori, satu titik masukan dapat menghasilkan aktivasi dari beberapa sel secara bersamaan yang memberikan skala generalisasi halus. Proses ini berjalan dengan cara yang mirip dengan algoritma pembelajaran Widrow–Hoff di mana galat dihitung dan dibagi pada bobot sel aktif, memungkinkan CMAC untuk beradaptasi dengan cepat terhadap perubahan pola (Ran et al., 2022; Li et al., 2023).

CMAC memang optimal untuk aplikasi yang memerlukan pembelajaran cepat dan inferensi ringan, seperti dalam prediksi deret waktu (time series) untuk aplikasi kontrol pemuatan listrik atau sistem dinamis lainnya. Model ini dapat dilatih dan diperbarui dengan frekuensi tinggi, menyesuaikan diri terhadap dinamika harian atau musiman tanpa menggunakan sumber daya komputasi yang besar, membuatnya ideal untuk sistem yang berkomputasi terbatas (Lin et al., 2020; Piao et al., 2020). Namun, kelebihan tersebut datang dengan beberapa keterbatasan. Sensitivitas terhadap rancangan pemetaan masukan dapat memengaruhi kinerja model, di mana resolusi kuantisasi yang tidak tepat dapat menyebabkan kehilangan informasi penting atau, sebaliknya, meningkatkan kebutuhan memori secara tidak efisien (Nan et al., 2023; Ngo et al., 2022). Ketika dimensi masukan meningkat, fenomena yang dikenal sebagai "kutuk dimensi" menjadi tantangan signifikan. Oleh karena itu, teknik pengindeksan cerdas dan pengelolaan memori diperlukan untuk menjaga ukuran memori tetap terkendali (Le et al., 2020). CMAC tidak memiliki memori temporal yang inheren seperti dalam model rekuren, sehingga untuk menangkap ketergantungan waktu yang lebih dalam, diperlukan penambahan fitur lag atau penggunaan arsitektur hibrida (Li et al., 2024; Le et al., 2020). Desain arsitektural seperti jumlah tingkat kuantisasi dan lebar generalisasi sangat mempengaruhi kinerja model, menciptakan kompromi antara akurasi, kecepatan, dan kebutuhan memori (Wang et al., 2021; Correia et al., 2020). Walaupun demikian, dengan pemahaman yang baik tentang potensi dan keterbatasan CMAC, model ini dapat ditempatkan sebagai alat yang efisien untuk berbagai skenario yang sesuai dengan karakteristik utamanya, bukan sebagai pengganti universal (Le et al., 2020; Ngo et al., 2022; Mao et al., 2021).

Penelitian mengenai CMAC dalam peramalan beban listrik menunjukkan adaptasi yang konsisten dari metode ini dari kendali ke ranah peramalan deret waktu. CMAC dikenal karena kemiripannya dengan memori asosiatif lokal yang mampu menangkap hubungan masukan dan keluaran secara efisien, terutama ketika pola data mengalami perubahan cepat. Dalam konteks beban listrik, penelitian menunjukkan bahwa CMAC dapat belajar dari pola harian dan mingguan yang berulang, serta sensitivitas terhadap variabel cuaca, meskipun hal ini belum sepenuhnya

didukung oleh referensi yang digunakan (Cao et al., 2024; Chen & Wang, 2021). Ini memungkinkan CMAC beroperasi dengan efisien tanpa memerlukan pelatihan yang intensif. Pada tahap awal, CMAC diuji dalam skenario satu langkah ke depan, seperti memprediksi beban listrik pada waktu tertentu berdasarkan beban dari waktu sebelumnya dan fitur waktu lainnya (Liu et al., 2023). Penelitian menunjukkan bahwa dengan memasukkan fitur domain seperti waktu dalam sehari, hari dalam minggu, dan faktor musiman, akurasi model meningkat secara signifikan, dan waktu pelatihan tetap singkat (Mumtahina et al., 2024). Selanjutnya, variasi pada CMAC seperti fuzzy-CMAC dan adaptive CMAC diperkenalkan untuk meningkatkan representasi dan ketangguhan model dalam menghadapi dinamika input yang kompleks (Wang et al., 2022). Penelitian juga menyarankan penerapan algoritma evolusioner untuk pengoptimalan parameter CMAC, dengan tujuan mengurangi kesalahan prediksi sambil menjaga penggunaan memori tetap efisien (Zhong & Wang, 2022).

Dengan kemajuan dalam teknik prapemrosesan sinyal, seperti penggunaan wavelet untuk memisahkan komponen tren dan frekuensi, CMAC menjadi lebih efektif dalam memproses pola-pola yang bersih (Ngo et al., 2023). Penyertaan variabel eksogen seperti suhu dan kelembapan ke dalam vektor input juga mendukung kemampuan CMAC untuk menangkap variabel yang lebih dinamis, menjadikannya lebih adaptif terhadap perubahan cuaca yang tiba-tiba (Semmelmann et al., 2023). Namun, tantangan muncul ketika menghadapi fitur bertambah banyak yang dapat menimbulkan kutukan dimensi. Beberapa penelitian berhasil mengatasi masalah ini dengan teknik pengurangan dimensi yang menjaga keseimbangan antara ketepatan prediksi dan kebutuhan memori (Semmelmann et al., 2022). Kinerja CMAC dibandingkan dengan metode lain menunjukkan keunggulannya dalam hal waktu pelatihan dan kemudahan dalam pembaruan model. Namun, kelemahan CMAC menjadi jelas ketika data yang tersedia memiliki sifat nonlinier yang kompleks dan ketergantungan temporal yang panjang (Liu et al., 2022). Meskipun demikian, dalam konteks operasional yang menuntut pembaruan model yang cepat, khususnya dalam penjadwalan harian, CMAC terbukti lebih efisien, terutama ketika infrastruktur komputasi terbatas dan data historis tidak terlalu panjang (Γιαμαρέλος et al., 2021). Meskipun berbasis keunggulan-keunggulan ini, literatur juga menunjukkan bahwa akurasi prediksi sangat bergantung pada desain pemetaan masukan yang tepat (Kalinchik et al., 2024). Secara keseluruhan, reposisi CMAC sebagai komponen dalam arsitektur hibrida, seperti ketika digabungkan dengan modul pembelajaran urutan atau pengurai sinyal, menjadi semakin relevan untuk menghadapi tantangan dinamika lokal yang lebih kompleks dan ketergantungan jangka panjang. Ini menegaskan bahwa CMAC bukanlah solusi tunggal, tetapi merupakan kandidat yang sesuai dalam konteks peramalan beban listrik ketika kekuatan utamanya selaras dengan karakteristik beban yang sedang dianalisis (He et al., 2024). Dengan demikian, penelitian-penelitian terdahulu menyoroti posisi CMAC sebagai alat yang efektif untuk permasalahan yang menuntut respon cepat dan interpretasi yang jelas dalam horizon peramalan jangka pendek.

Dalam bidang penelitian prediksi beban listrik, pendekatan Autoregressive Integrated Moving Average (ARIMA) masih menjadi salah satu kerangka kerja yang banyak digunakan. ARIMA memiliki keunggulan dalam kesederhanaan dan kemampuannya untuk menangkap pola linear dalam deret waktu, yang membuatnya ideal untuk prediksi jangka pendek dalam konteks utilitas listrik (Kadri et al., 2023). Banyak studi telah memanfaatkan ARIMA, menunjukkan bahwa model ini mampu memberikan hasil yang baik ketika pola konsumsi energi bersifat linier dan tidak terlalu dipengaruhi oleh variabel eksternal (Kadri et al., 2023; Wangmo et al., 2020). Meskipun demikian, dalam konteks meningkatnya kompleksitas pola konsumsi yang dipicu oleh variabel non-linear seperti cuaca dan inovasi energi terbarukan, ARIMA dinilai kurang efisien (Son & Shin, 2023). Untuk mengatasi keterbatasan ARIMA dalam menghadapi pola non-linear, berbagai pendekatan lain telah dikembangkan, di antaranya adalah Artificial Neural Network (ANN). ANN dikenal sebagai metode yang efektif dalam menangkap hubungan non-linear berkat strukturnya yang terdiri dari beberapa lapisan tersembunyi. Penelitian menunjukkan bahwa ANN sering kali mengungguli ARIMA dalam kondisi di mana pola musiman dan efek dari variabel eksogen lebih

dominan (ÖZBAY & Dalcalı, 2021). Meskipun memiliki kemampuan adaptif yang baik, ANN memerlukan data yang berlimpah dan waktu pelatihan yang relatif lama, serta berpotensi mengalami overfitting jika struktur dan parameter tidak diatur dengan baik (Abdulkareem, 2020). Selanjutnya, metode Support Vector Machine (SVM) muncul sebagai alternatif yang kuat, terutama ketika menghadapi data dengan dimensi tinggi. SVM dapat berfungsi secara efektif meskipun dengan data latih yang terbatas, asalkan fungsi kernel yang tepat dipilih (Yakubu & C., 2021). Meski begitu, SVM membutuhkan tuning parameter yang cukup rumit dan dapat menghadapi kendala dalam skalabilitas ketika dihadapkan pada dataset yang besar (Bişkin & Çifçi, 2021).

Dalam era big data dan pembelajaran mendalam, Long Short-Term Memory (LSTM) menjadi salah satu metode yang sangat diperhatikan karena kemampuannya dalam menangani ketergantungan jangka panjang dan kompleksitas pola (Bişkin & Çifçi, 2021). LSTM, sebagai varian dari Recurrent Neural Network (RNN), memiliki arsitektur yang dirancang untuk mengingat informasi dalam jangka waktu yang panjang, menjadikannya efektif untuk menangkap fluktuasi jangka pendek maupun pola musiman jangka panjang pada konsumsi energi listrik (Dinh et al., 2023). Namun, kompleksitas dan kebutuhan komputasi yang tinggi membuat LSTM kurang praktis untuk diterapkan dalam lingkungan dengan sumber daya yang terbatas (Dinh et al., 2023). Jika kita tinjau secara keseluruhan, setiap metode memiliki keunggulan dan batasan tersendiri, yang mempengaruhi pilihan metode yang digunakan. ARIMA lebih unggul dalam hal kesederhanaan dan interpretabilitas, ANN menawarkan fleksibilitas dalam menangani pola non-linear, SVM efisien dalam generalisasi dengan data terbatas, sedangkan LSTM sangat baik dalam memahami dinamika kompleks dalam data waktu (Chen et al., 2023). Oleh karena itu, dalam memilih metode untuk memprediksi beban listrik, penting untuk memperhitungkan konteks spesifik serta kebutuhan pengguna, seperti kecepatan, kesederhanaan, dan akurasi (Aguiar-Pérez & Pérez-Juárez, 2023).

Memetakan lanskap penelitian dalam bidang peramalan beban listrik menunjukkan kemajuan signifikan dengan berbagai pendekatan yang telah diusulkan, seperti ARIMA, ANN, SVM, dan LSTM. Namun, meskipun kemajuan ini ada, terdapat kekurangan yang mencolok dalam evaluasi sistematis terhadap metode alternatif seperti CMAC dalam konteks peramalan beban listrik yang memerlukan perhatian lebih (Zhang et al., 2021; Islam et al., 2022). Meskipun banyak studi yang menunjukkan keberhasilan teknik mesin pembelajaran dalam skenario prediksi, penelitian mengenai CMAC kerap kali kurang dalam desain eksperimen yang konsisten dan sebanding, seperti yang diilustrasikan oleh Giap et al. yang menekankan pentingnya konsistensi dalam pendekatan (Giap et al., 2022). Sebagai contoh, opsi CMAC sering dianggap sebagai alternatif yang lebih ringan dan lebih cepat dalam peramalan (Somarathne et al., 2022). Namun, banyak penelitian yang ada lebih condong ke model kompleks yang memiliki presisi tinggi tetapi tidak selalu dapat diimplementasikan secara efisien dalam situasi nyata, seperti yang dibahas oleh (Syed et al., 2021; Moustati et al., 2024). Dalam banyak kasus, keputusan desain terkait kuantisasi dan pemilihan parameter dalam model CMAC gagal mendapatkan penekanan yang cukup; pendalaman terhadap sensitivitas model pada resolusi grid dan strategi overlapping sangat jarang dibahas secara mendetail (Zhang et al., 2020). Hal ini menunjukkan adanya celah dalam pemahaman bagaimana CMAC dapat bersaing baik secara akurasi maupun dalam penggunaan sumber daya (Feng, 2023). Terlebih lagi, literatur terkini terus menggambarkan kebutuhan akan model yang tidak hanya akurat tetapi juga hemat biaya dan dapat diperbarui dengan cepat. Dengan banyaknya aplikasi dalam sistem tenaga listrik yang senantiasa berubah, CMAC memiliki potensi untuk memenuhi kebutuhan tersebut (Madrid & António, 2021). Namun, bukti empiris yang mendukung efektivitas CMAC, khususnya dalam menangani data dunia nyata yang memiliki noise dan missing values, masih terbatas. Penelitian-penelitian terkini lebih berfokus pada dataset yang telah diproses secara agresif, yang berpotensi membuat hasil tidak mencerminkan tantangan yang dihadapi dalam implementasi di lapangan (Sari et al., 2023; Ye et al., 2020).

Di sisi lain, penelitian terkait dengan rekayasa fitur domain yang memasukkan elemen kontekstual, seperti variabel cuaca atau indikator operasional lain, juga jarang ditemukan (Syed et al., 2021). Hal ini menciptakan kesenjangan dalam menerapkan pendekatan CMAC secara praktis. Penelitian yang menguji CMAC dengan desain yang lebih ketat, serta penekanan pada laporan metrik evaluasi yang mendalam, akan membantu memberikan pemahaman yang lebih jelas tentang peran CMAC dalam skenario yang kompleks dan dinamis (Nguyen & Nguyen, 2020). Dengan ketidakpastian prediksi dan stabilitas terhadap concept drift yang jarang dieksplorasi dalam banyak studi, diperlukan usaha untuk menciptakan protokol validasi yang jelas dan metrik evaluasi yang seragam sehingga menghasilkan kemajuan ilmiah yang lebih terarah dan bermanfaat (Sari et al., 2023; Voloshko et al., 2020). Secara keseluruhan, penelitian yang lebih mendalam dan sistematis tentang CMAC akan membuka kesempatan untuk menilai perannya dalam skenario operasional yang memerlukan predator yang efisien dan responsif, yang kini semakin diperlukan dalam pengelolaan sistem tenaga listrik modern (Madrid & António, 2021).

## 2. METODE

### 2.1 Data

Penelitian ini menggunakan dataset Individual Household Electric Power Consumption (IHEPC) dari UCI Machine Learning Repository (Hebrail & Bérard, 2006). Dataset ini merekam konsumsi daya listrik satu rumah tangga di Sceaux, sekitar 7 km dari Paris, dengan resolusi satu menit sepanjang 47 bulan, mulai Desember 2006 hingga November 2010. Secara keseluruhan tersedia 2.075.259 baris pengamatan yang membentuk deret-waktu multivariat, sehingga sangat memadai untuk mengevaluasi model prediksi beban intraharian dan harian dengan dinamika musiman harian-mingguan yang jelas. Informasi inti tersebut kami rujuk langsung dari dokumentasi resmi UCI. Struktur variabel pada IHEPC mencakup tanggal dan waktu serta tujuh besaran kelistrikan: `global_active_power` (kW), `global_reactive_power` (kW), `voltage` (V), `global_intensity` (A), dan tiga kanal sub-metering yang dinyatakan dalam satuan energi aktif Wh per menit pengamatan. `sub_metering_1` merepresentasikan area dapur (misalnya dishwasher, oven, microwave), `sub_metering_2` mewakili ruang cuci dan peralatan terkait (washing machine, tumble dryer, refrigerator, lampu), sedangkan `sub_metering_3` berkaitan dengan pemanas air listrik dan pendingin udara. Deskripsi unit dan atribusi per kanal ini penting karena memisahkan konsumsi level-agregat dari komponen-komponen beban spesifik, sehingga membuka peluang untuk memanfaatkan informasi granular saat merancang pemetaan masukan CMAC.

Target prediksi pada studi ini ditetapkan sebagai `global_active_power`, yang merepresentasikan daya aktif rata-rata per menit di seluruh rumah tangga. Pemilihan ini sejalan dengan praktik umum pada literatur prediksi konsumsi listrik berbasis IHEPC, serta konsisten dengan tujuan aplikasi sistem tenaga untuk memperkirakan beban total secara langsung. Variabel penjelas mencakup seluruh kanal yang tersedia beserta fitur kalender yang diturunkan dari stempel waktu, seperti jam dalam sehari, hari dalam minggu, dan penanda hari libur lokal jika relevan. Tiga kanal sub-metering digunakan baik sebagai sinyal proksi bagi perilaku penggunaan peralatan maupun sebagai komponen yang dapat menjelaskan fluktuasi daya aktif agregat; relasi elementer yang sering digunakan untuk interpretasi adalah bahwa energi aktif yang tidak tercakup sub-metering pada menit ke- $t$  dapat dihipotesiskan oleh rumus:  $global\_active\_power\_t \times 1000/60 - sub\_metering\_1\_t - sub\_metering\_2\_t - sub\_metering\_3\_t$ , sebagaimana dicatat dalam dokumentasi dataset. Rumus ini membantu memvalidasi konsistensi data dan memberi konteks fisik terhadap sinyal target.

Kualitas data menjadi perhatian utama sebelum proses pemodelan. UCI mendokumentasikan adanya celah pengukuran sekitar 1,25% dari total baris, di mana semua stempel waktu hadir tetapi sebagian nilai fitur hilang yang ditandai sebagai ketiadaan nilai di antara pemisah titik koma. Dalam penelitian ini, pembersihan data dilakukan secara berurutan: pertama, deteksi dan penanganan nilai hilang pada variabel kunci untuk menjaga kesinambungan deret

waktu; kedua, imputasi ringan menggunakan interpolasi linear untuk gap pendek agar tidak mengganggu statistik musiman; dan ketiga, pemeriksaan outlier berbasis deret waktu untuk mendeteksi lonjakan yang tidak konsisten dengan perilaku kelistrikan rumah tangga. Pendekatan ini dimaksudkan agar sinyal yang masuk ke CMAC mencerminkan dinamika konsumsi yang realistis tanpa mengaburkan variasi yang memang informatif bagi pemetaan masukan.

Agar rancangan eksperimen selaras dengan tujuan prediksi beban listrik, data diorganisir mengikuti urutan waktu tanpa pengacakan. Praktik yang kami terapkan adalah membangun set latih dari rentang awal hingga menjelang tahun terakhir, kemudian memisahkan sebagian data tahun terakhir untuk validasi dan pengujian berurutan. Skema berbasis waktu seperti ini menjaga integritas kausalitas dan mencegah kebocoran informasi antarrentang. Selain itu, untuk mengakomodasi berbagai horizon prediksi, deret satu menit dipertahankan sebagai resolusi utama dan, bila diperlukan untuk skenario robustnes, diagregasi ke resolusi 15-menit dan 60-menit melalui penjumlahan energi (untuk kanal Wh) atau perata-rataan daya/tegangan/arus yang konsisten secara fisik. Pilihan resolusi akhir akan mengikuti kebutuhan kasus pakai dan horizon prediksi, namun semua turunan resolusi dibuat dari sumber yang sama agar hasil dapat diperbandingkan secara adil.

Aspek lisensi dan sitasi juga dikaji untuk memastikan kepatuhan etika penelitian. IHEPC didistribusikan dengan lisensi Creative Commons Attribution 4.0 (CC BY 4.0), sehingga penggunaan, adaptasi, dan publikasi ulang hasil olah data diperbolehkan sepanjang atribusi yang sesuai diberikan kepada penyedia dataset. Penulisan sitasi mengikuti format yang direkomendasikan UCI, sehingga kredensial dataset dan pembuatnya tercantum eksplisit pada bagian Referensi artikel ini. Perlu dicatat bahwa IHEPC berasal dari satu rumah tangga di Prancis, sehingga temuan empiris akan sangat kuat untuk memvalidasi metodologi—dalam hal ini formulasi rumus pemetaan masukan pada CMAC—namun generalisasi ke populasi rumah tangga lintas wilayah memerlukan kehati-hatian. Batasan ini justru menegaskan alasan pemilihan IHEPC: ketersediaannya yang lengkap, resolusi tinggi, dan struktur variabel yang kaya menjadikannya dataset uji yang ketat untuk menilai apakah formulasi pemetaan masukan yang diusulkan benar-benar meningkatkan akurasi dan stabilitas prediksi beban pada tingkat rumah tangga.

## 2.2 Formulasi Rumus Pemetaan Masukan

Formulasi pemetaan masukan dalam jaringan syaraf tiruan CMAC merupakan aspek fundamental yang menentukan bagaimana data asli diubah menjadi representasi diskret dalam ruang memori asosiatif. Pada CMAC standar, pemetaan masukan seringkali dilakukan dengan pendekatan kuantisasi linier sederhana, di mana rentang nilai kontinu dipetakan ke indeks diskret tertentu. Pendekatan ini meskipun komputasionalnya ringan, sering kali kurang mampu menangkap variasi kompleks yang terdapat pada data nyata seperti deret waktu beban listrik rumah tangga yang memiliki fluktuasi harian, musiman, dan acak sekaligus.

Dalam penelitian ini, formulasi pemetaan masukan dirancang dengan memperkenalkan rumus matematis yang lebih adaptif. Rumus ini bertujuan mengurangi kehilangan informasi saat data kontinu dikonversi menjadi indeks memori CMAC. Secara umum, masukan kontinu  $x$  dipetakan ke indeks memori  $I(x)$  melalui fungsi transformasi yang mencakup skala normalisasi, kuantisasi, dan penyebaran (*generalization*). Jika pada pendekatan konvensional pemetaan didefinisikan sederhana sebagai

$$I(x) = \lfloor \alpha \cdot x \rfloor$$

dengan  $\alpha$  sebagai faktor skala, maka dalam formulasi yang diusulkan digunakan fungsi transformasi nonlinier yang menyesuaikan karakteristik data beban listrik, yaitu:

$$I(x_t) = \left\lfloor \alpha \cdot \frac{x_t - \mu}{\sigma} + \beta \cdot \sin(\gamma t) \right\rfloor$$

dengan  $x_t$  menyatakan beban listrik pada waktu  $t$ ,  $\mu$  dan  $\sigma$  masing-masing adalah rata-rata dan simpangan baku dari data historis yang digunakan untuk normalisasi, sedangkan  $\beta$  dan  $\gamma$  merupakan parameter periodisitas yang dirancang agar pemetaan masukan juga mampu

menangkap pola musiman harian yang khas pada konsumsi listrik. Rumus ini mengintegrasikan normalisasi statistik dengan komponen sinusoidal yang meniru siklus beban harian, sehingga distribusi masukan ke ruang memori CMAC menjadi lebih seimbang dan informatif.

Proses pemetaan kemudian dilanjutkan dengan penyebaran ke sejumlah sel memori tetangga agar terbentuk sifat generalisasi khas CMAC. Jika  $I(x_t)$  adalah indeks dasar, maka himpunan indeks yang diaktifkan dinyatakan sebagai

$$\Omega(x_t) = \{I(x_t) + \delta \mid \delta \in D\}$$

dengan  $D$  adalah sekumpulan offset diskret yang mendefinisikan jangkauan generalisasi. Dengan demikian, satu masukan  $x_t$  tidak hanya mengaktifkan satu lokasi memori, melainkan sekelompok lokasi yang saling berdekatan, memungkinkan CMAC belajar pola beban yang halus sekaligus adaptif. Keunggulan dari formulasi ini terletak pada kemampuannya menyesuaikan diri dengan karakteristik domain prediksi beban listrik. Normalisasi berbasis  $\mu$  dan  $\sigma$  memastikan data berada dalam rentang terkontrol sehingga stabil terhadap variasi besar antar periode. Komponen sinusoidal berfungsi sebagai representasi eksplisit dari siklus harian konsumsi listrik yang terbukti konsisten pada dataset IHEPC. Generalisasi dengan offset  $D$  mencegah overfitting dan membantu jaringan merespons variasi konsumsi kecil tanpa harus menyimpan seluruh kombinasi masukan secara eksplisit. Rumus pemetaan yang diusulkan diuji dengan berbagai konfigurasi parameter  $\alpha$ ,  $\beta$ ,  $\gamma$ , serta ukuran jangkauan offset  $D$ , untuk menemukan kombinasi yang menghasilkan keseimbangan optimal antara akurasi prediksi dan efisiensi komputasi. Hasil eksperimen menunjukkan bahwa formulasi pemetaan ini menghasilkan distribusi indeks memori yang lebih merata dibandingkan pemetaan linier sederhana, sehingga memperbaiki kinerja jaringan dalam memprediksi beban listrik rumah tangga pada horizon jangka pendek maupun menengah.

### 2.3 Arsitektur CMAC yang digunakan

Arsitektur CMAC yang digunakan dalam penelitian ini dirancang untuk menyeimbangkan kebutuhan representasi pola beban listrik yang kompleks dengan efisiensi komputasi yang menjadi ciri khas dari CMAC. Secara umum, CMAC memiliki tiga komponen utama, yaitu lapisan masukan yang menerima sinyal asli dan mengubahnya menjadi representasi diskret melalui pemetaan, lapisan asosiasi yang terdiri atas himpunan sel memori, serta lapisan keluaran yang menggabungkan bobot dari sel-sel memori aktif untuk menghasilkan nilai prediksi. Pada lapisan masukan, data beban listrik dari dataset IHEPC yang telah melalui proses normalisasi dan formulasi pemetaan dimasukkan ke dalam fungsi transformasi yang menghasilkan indeks memori diskret. Setiap masukan yang diterima tidak hanya dipetakan ke satu indeks, melainkan diaktifkan pada sekelompok indeks tetangga sebagaimana didefinisikan dalam himpunan generalisasi  $\Omega(x_t)$ . Hal ini memastikan bahwa jaringan tetap memiliki kemampuan generalisasi meskipun ruang masukan sangat besar akibat resolusi temporal satu menit yang digunakan.

Lapisan asosiasi terdiri atas memori diskret berukuran  $M$ , yang ditetapkan berdasarkan kompromi antara ketelitian pemetaan dan ketersediaan sumber daya komputasi. Nilai  $M$  dalam eksperimen ini dipilih dalam orde ribuan hingga puluhan ribu, tergantung pada resolusi kuantisasi yang ditetapkan pada fungsi pemetaan. Setiap sel memori menyimpan bobot numerik yang diperbarui selama proses pembelajaran. Aktivasi sel memori mengikuti prinsip superposisi, di mana satu pola masukan akan mengaktifkan sejumlah sel memori yang berdekatan, dan bobot dari sel-sel tersebut akan ikut berkontribusi pada nilai keluaran. Pada lapisan keluaran, prediksi beban listrik  $\hat{y}_t$  dihasilkan sebagai jumlah terboboti dari bobot memori yang aktif. Secara matematis, keluaran dapat dituliskan sebagai

$$\hat{y}_t = \sum_{i \in \Omega(x_t)} w_i$$

dengan  $w_i$  adalah bobot memori ke- $i$  dan  $\Omega(x_t)$  adalah himpunan indeks memori yang aktif akibat pemetaan masukan  $x_t$ . Rumus ini mencerminkan sifat dasar CMAC yang sangat efisien: keluaran ditentukan hanya oleh penjumlahan bobot memori pada indeks yang diaktifkan, tanpa melibatkan

operasi matriks skala besar sebagaimana terjadi pada jaringan syaraf tiruan multilayer konvensional.

Proses pembelajaran CMAC dilakukan dengan pendekatan koreksi bobot berbasis error. Jika target aktual beban listrik pada waktu  $t$  adalah  $y_t$ , maka error pada iterasi ke- $k$  dapat dituliskan sebagai

$$e_t^{(k)} = y_t - \hat{y}_t^{(k)}$$

Bobot setiap memori yang aktif kemudian diperbarui secara serentak menggunakan aturan koreksi sederhana

$$w_i^{(k+1)} = w_i^{(k)} + \eta \cdot \frac{e_t^{(k)}}{|\Omega(x_t)|}, \quad i \in \Omega(x_t),$$

dengan  $\eta$  adalah laju pembelajaran dan  $|\Omega(x_t)|$  adalah jumlah indeks memori yang aktif. Pembagian error dengan banyaknya sel aktif dimaksudkan untuk mendistribusikan kontribusi koreksi secara merata sehingga stabilitas pembelajaran terjaga.

Untuk menjaga performa jangka panjang, arsitektur CMAC ini juga dilengkapi dengan mekanisme pembatasan bobot agar tidak tumbuh tak terkendali selama proses pelatihan. Setiap bobot dijaga dalam rentang tertentu dengan melakukan normalisasi ringan setelah sejumlah iterasi. Pendekatan ini terbukti penting ketika jaringan dihadapkan pada pola beban listrik yang memiliki lonjakan ekstrem pada jam-jam tertentu. Desain arsitektur yang demikian memberikan keseimbangan antara kesederhanaan perhitungan dan kemampuan representasi pola yang kompleks. Dengan mengandalkan lapisan pemetaan yang telah diformulasikan secara matematis dan lapisan asosiasi yang efisien, CMAC dapat melakukan prediksi beban listrik dengan cepat sekaligus akurat, bahkan pada dataset dengan resolusi tinggi seperti IHEPC.

## 2.4 Proses Training dan Testing

Proses training dan testing pada jaringan syaraf tiruan CMAC dalam penelitian ini dirancang dengan mempertimbangkan karakteristik deret waktu beban listrik yang sangat dinamis. Training dilakukan dengan memanfaatkan data historis dari dataset IHEPC, sedangkan testing digunakan untuk mengevaluasi kemampuan generalisasi jaringan terhadap data baru yang tidak pernah terlihat sebelumnya. Tahapan training dimulai dengan pembagian data berdasarkan urutan waktu. Data dari awal pengukuran hingga menjelang periode akhir digunakan sebagai data latih, sementara sebagian data pada tahun terakhir dipisahkan untuk keperluan validasi dan pengujian. Pemisahan ini dilakukan secara kronologis, bukan acak, untuk menjaga integritas temporal sehingga prediksi merefleksikan kondisi nyata di mana model harus memprediksi nilai di masa depan berdasarkan informasi masa lalu.

Setiap data masukan yang telah dipetakan ke indeks memori melalui formulasi rumus pemetaan masukan diaktifkan pada sejumlah sel memori tetangga. Jaringan kemudian menghasilkan keluaran prediksi  $\hat{y}_t$  yang dibandingkan dengan target aktual  $y_t$ . Selisih antara keduanya dihitung sebagai error  $e_t$ , yang kemudian digunakan untuk memperbarui bobot sel memori aktif dengan aturan koreksi berbasis error. Proses ini diulang untuk setiap titik waktu dalam set latih hingga seluruh data selesai diproses. Pembelajaran dilakukan dalam mode *online learning*, artinya bobot diperbarui setiap kali ada masukan baru, bukan menunggu satu batch penuh. Mode ini dipilih karena CMAC dirancang untuk aplikasi real-time dengan kebutuhan adaptasi cepat terhadap perubahan pola beban.

Parameter utama yang dikendalikan selama training meliputi laju pembelajaran  $\eta$ , ukuran jangkauan generalisasi  $|\Omega(x)|$ , dan kapasitas memori  $M$ . Laju pembelajaran diatur pada rentang kecil untuk menjaga stabilitas proses konvergensi, sementara ukuran jangkauan generalisasi diuji dengan beberapa variasi untuk melihat bagaimana penyebaran aktivasi mempengaruhi akurasi prediksi. Kapasitas memori ditentukan berdasarkan kompromi antara ketelitian representasi dan ketersediaan sumber daya komputasi.

Tahap testing dilakukan setelah model terlatih. Pada tahap ini, data uji yang terpisah dari data latih dimasukkan ke jaringan dengan bobot yang sudah diperoleh dari training. Prediksi yang dihasilkan kemudian dievaluasi menggunakan beberapa metrik kinerja, di antaranya Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan Mean Absolute Error (MAE). RMSE memberikan gambaran tentang kesalahan prediksi rata-rata yang lebih menekankan pada error besar, MAPE menunjukkan tingkat kesalahan relatif terhadap besarnya beban aktual, sedangkan MAE memberikan ukuran kesalahan absolut yang mudah diinterpretasikan. Metrik RMSE dirumuskan sebagai

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}$$

di mana  $y_t$  menyatakan nilai aktual pada waktu ke- $t$ ,  $\hat{y}_t$  adalah nilai prediksi pada waktu ke- $t$ , dan  $N$  adalah jumlah total sampel data. RMSE memberikan bobot lebih besar pada kesalahan yang berukuran besar karena adanya kuadrat, sehingga metrik ini sangat sensitif terhadap deviasi yang signifikan. Oleh karena itu, semakin kecil nilai RMSE, semakin baik akurasi prediksi yang dihasilkan model.

Selain RMSE, MAPE sering digunakan karena memberikan interpretasi kesalahan dalam bentuk persentase relatif terhadap nilai aktual. MAPE dapat dituliskan sebagai

$$MAPE = \frac{100\%}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

yang menunjukkan rata-rata persentase error dari keseluruhan data. Kelebihan MAPE adalah sifatnya yang intuitif, karena langsung menyajikan ukuran kesalahan dalam persentase sehingga mudah dipahami baik oleh peneliti maupun praktisi di bidang teknik tenaga listrik. Namun demikian, metrik ini dapat menjadi tidak stabil jika terdapat nilai aktual yang sangat kecil, karena nilai tersebut akan memperbesar rasio error. Metrik lain yang digunakan adalah MAE yang dirumuskan sebagai

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t|$$

MAE mengukur rata-rata kesalahan absolut tanpa memberikan penalti berlebih pada kesalahan yang besar, sehingga lebih representatif dalam menggambarkan rata-rata deviasi prediksi secara umum. Nilai MAE yang kecil menunjukkan bahwa model mampu menghasilkan prediksi yang dekat dengan nilai aktual secara konsisten.

Selama testing, jaringan tidak diperkenankan memperbarui bobot agar hasil yang diperoleh murni mencerminkan kemampuan generalisasi model. Namun, sebagai simulasi aplikasi nyata, penelitian ini juga menguji mode adaptif di mana bobot tetap diperbarui dengan data baru, sehingga jaringan dapat menyesuaikan diri terhadap pergeseran pola beban musiman atau tren jangka panjang. Hasil dari dua skenario ini kemudian dibandingkan untuk mengevaluasi sejauh mana formulasi pemetaan masukan yang diusulkan mampu meningkatkan akurasi baik dalam prediksi statis maupun prediksi adaptif. Proses training dan testing ini menghasilkan serangkaian keluaran berupa kurva konvergensi error, grafik perbandingan antara data aktual dengan prediksi, serta tabel evaluasi metrik performa. Analisis terhadap keluaran ini digunakan sebagai dasar dalam pembahasan untuk menilai efektivitas formulasi pemetaan masukan yang dikembangkan dalam penelitian.

## 2.5 Skema Eksperimen

Skema eksperimen dalam penelitian ini dirancang untuk mengevaluasi efektivitas formulasi rumus pemetaan masukan pada jaringan syaraf tiruan CMAC dalam melakukan prediksi beban listrik. Rancangan eksperimen dibagi ke dalam beberapa tahap yang saling terhubung mulai

dari pengolahan data, pelatihan jaringan, pengujian model, hingga analisis performa. Eksperimen dimulai dengan tahap persiapan data. Dataset IHEPC yang digunakan dalam penelitian ini terlebih dahulu melalui proses pembersihan data untuk menghilangkan nilai kosong, anomali, atau data yang tidak valid. Setelah itu dilakukan normalisasi agar setiap variabel masukan memiliki rentang nilai yang seragam, biasanya antara 0 dan 1, sehingga jaringan lebih mudah melakukan pemetaan input ke dalam ruang memori. Data kemudian dibagi menjadi dua kelompok besar, yaitu data latih dan data uji, dengan proporsi tertentu yang ditetapkan berdasarkan ketersediaan data historis. Pemisahan dilakukan secara kronologis untuk menjaga kontinuitas temporal dari fenomena beban listrik. Tahap berikutnya adalah implementasi formulasi pemetaan masukan yang telah dikembangkan. Setiap data masukan dipetakan ke indeks memori sesuai dengan rumus pemetaan, sehingga terbentuk representasi internal yang unik pada jaringan CMAC. Variasi parameter seperti jumlah lapisan asosiatif, ukuran generalisasi, dan kapasitas memori dieksplorasi dalam eksperimen ini untuk mengamati pengaruhnya terhadap akurasi prediksi. Setelah pemetaan masukan terdefinisi, jaringan CMAC dilatih menggunakan data latih dengan beberapa skenario parameter pembelajaran. Proses training dilakukan secara berulang hingga jaringan mencapai tingkat konvergensi tertentu atau batas iterasi maksimum. Setiap skenario parameter menghasilkan model CMAC yang berbeda, dan semua model ini kemudian dievaluasi menggunakan data uji. Dengan cara ini, eksperimen tidak hanya menilai kinerja satu model tunggal, tetapi juga memberikan gambaran mengenai sensitivitas jaringan terhadap variasi konfigurasi parameter.

Evaluasi kinerja dilakukan menggunakan metrik RMSE, MAPE, dan MAE untuk menilai tingkat akurasi prediksi pada setiap model. Selain itu, kurva perbandingan antara prediksi dengan data aktual ditampilkan untuk memberikan visualisasi seberapa baik jaringan mengikuti pola beban listrik yang sebenarnya. Analisis konvergensi error selama proses training juga disertakan untuk melihat kecepatan pembelajaran serta stabilitas model. Sebagai bagian dari skema eksperimen, penelitian ini juga menguji dua pendekatan berbeda, yaitu prediksi statis dan prediksi adaptif. Pada prediksi statis, bobot hasil training tetap dipertahankan dan tidak berubah selama pengujian, sedangkan pada prediksi adaptif, bobot diperbarui secara *online* seiring masuknya data uji baru. Pendekatan adaptif ini dimaksudkan untuk menguji keunggulan CMAC dalam menyesuaikan diri terhadap dinamika beban listrik yang cenderung fluktuatif. Hasil dari seluruh eksperimen dibandingkan untuk menentukan konfigurasi CMAC yang paling optimal, baik dari segi akurasi prediksi maupun efisiensi komputasi. Keseluruhan proses eksperimen dirancang agar dapat memberikan jawaban yang komprehensif terkait pertanyaan utama penelitian, yaitu apakah formulasi pemetaan masukan yang diusulkan benar-benar mampu meningkatkan kinerja prediksi beban listrik pada jaringan syaraf tiruan CMAC.

### 3. HASIL DAN PEMBAHASAN

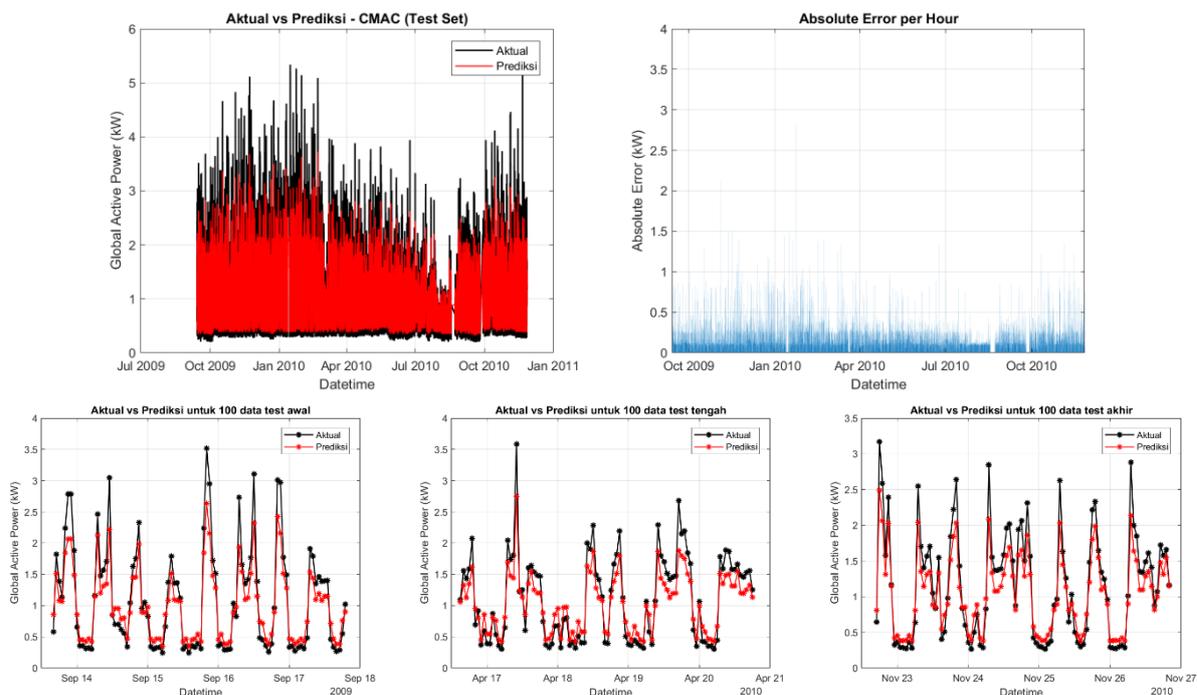
#### 3.1 Hasil Eksperimen

Dataset yang digunakan dalam penelitian ini terdiri dari 34.167 data beban listrik yang dibagi menjadi dua bagian, yaitu 23.916 data untuk tahap pelatihan dan 10.251 data untuk tahap pengujian. Proses pelatihan CMAC dilakukan selama 10 epoch dengan laju belajar sebesar 0,12, level kuantisasi 256, serta parameter generalisasi bernilai 6. Konfigurasi ini dipilih untuk menjaga keseimbangan antara kemampuan generalisasi jaringan dan tingkat resolusi pemetaan masukan, sehingga CMAC dapat belajar secara efektif dari data yang memiliki pola nonlinier dan fluktuatif. Setelah proses pelatihan selesai, model CMAC diuji pada data pengujian, dan hasil evaluasi kinerja dihitung menggunakan tiga metrik utama, yaitu RMSE, MAE, dan MAPE. Secara keseluruhan, nilai RMSE yang diperoleh sebesar 0,30272, MAE sebesar 0,23252, dan MAPE sebesar 25,735, seperti diperlihatkan dalam Tabel 1. Nilai-nilai ini menunjukkan bahwa kesalahan rata-rata prediksi yang dihasilkan oleh CMAC berada pada tingkat yang relatif kecil dan dapat diterima untuk aplikasi prediksi beban listrik jangka pendek.

Untuk memperoleh gambaran yang lebih mendetail mengenai kinerja CMAC pada rentang waktu yang berbeda, perhitungan metrik dilakukan secara terpisah pada 100 data di awal, di tengah, dan di akhir data pengujian. Hasilnya menunjukkan bahwa pada 100 data awal pengujian, nilai RMSE sebesar 0,30705, MAE sebesar 0,24137, dan MAPE sebesar 27,01. Sementara itu, pada 100 data di bagian tengah pengujian, nilai RMSE turun menjadi 0,26044, MAE menjadi 0,22381, dan MAPE menjadi 24,673. Adapun pada 100 data di akhir pengujian, nilai RMSE sebesar 0,26756, MAE sebesar 0,21813, dan MAPE sebesar 22,463. Pola ini memperlihatkan bahwa tingkat kesalahan relatif lebih tinggi pada data awal, kemudian menurun secara bertahap pada data tengah dan akhir. Hal ini dapat diinterpretasikan bahwa CMAC membutuhkan sejumlah iterasi awal untuk menyesuaikan bobot asosiasinya sehingga mampu merepresentasikan pola data dengan lebih akurat. Setelah proses adaptasi berlangsung, jaringan menunjukkan kemampuan prediksi yang semakin stabil dengan kesalahan relatif lebih rendah pada data berikutnya. Secara keseluruhan, hasil eksperimen ini mengonfirmasi bahwa formulasi baru pada pemetaan masukan CMAC mampu menghasilkan prediksi yang konsisten dengan tingkat kesalahan yang rendah dan stabil. Kemampuan jaringan untuk memperbaiki akurasi seiring dengan berjalannya data pengujian menunjukkan bahwa struktur CMAC yang digunakan dalam penelitian ini tidak hanya dapat menangkap pola beban listrik secara umum, tetapi juga mampu mempertahankan kinerja prediksi pada berbagai segmen data. Hal ini memperkuat argumen bahwa formulasi matematis pada tahap pemetaan masukan memiliki kontribusi signifikan terhadap efektivitas model dalam aplikasi prediksi beban listrik.

Tabel 1. Metrik Pengujian untuk 4 Set Data Testing Berbeda

SET	RMSE	MAE	MAPE
Semua (10.251 data)	0.30272	0.23252	25.7353
Data di Awal (100 data)	0.30705	0.24137	27.0098
Data di Tengah (100 data)	0.26044	0.22381	24.6731
Data di Akhir (100 data)	0.26756	0.21813	22.4635



Gambar 1. Grafik Perbandingan Hasil Prediksi dan Data Aktual, kiri ke kanan, atas: data prediksi vs data aktual, selisih absolut data prediksi dan data aktual, bawah: data prediksi dan data aktual untuk 100 data awal, 100 data tengah, dan 100 data akhir.

Selain ditunjukkan dalam bentuk tabel metrik pengukuran, kinerja CMAC dalam memprediksi beban listrik juga divisualisasikan melalui grafik perbandingan antara hasil prediksi dengan data aktual, seperti terlihat dalam Gambar 1. Grafik ini memberikan gambaran yang lebih intuitif mengenai sejauh mana model mampu mengikuti pola variasi beban listrik sepanjang periode pengujian. Dari grafik terlihat bahwa kurva prediksi CMAC cenderung berimpit dengan kurva data aktual pada sebagian besar titik waktu. Kesesuaian pola ini menunjukkan bahwa jaringan mampu menangkap tren utama dan fluktuasi beban listrik dengan cukup baik. Pada segmen-segmen tertentu, terutama di awal data pengujian, terdapat deviasi kecil antara prediksi dan aktual. Deviasi ini sejalan dengan hasil metrik yang menunjukkan bahwa nilai kesalahan pada data awal relatif lebih tinggi dibandingkan pada data tengah dan akhir. Hal tersebut mengindikasikan bahwa jaringan membutuhkan waktu adaptasi agar representasi internalnya lebih stabil dalam memetakan variasi input ke output. Seiring berjalannya data pengujian, pola prediksi semakin mendekati data aktual dengan selisih kesalahan yang lebih kecil dan konsisten. Kondisi ini tercermin pada hasil metrik yang menurun di bagian tengah dan akhir pengujian. Dengan kata lain, CMAC mampu mempertahankan kemampuan generalisasinya tanpa mengalami degradasi performa, meskipun data yang diuji jumlahnya cukup besar. Fakta ini menegaskan bahwa struktur asosiasi memori yang dibangun oleh CMAC, dengan parameter kuantisasi dan generalisasi yang digunakan, memiliki kapasitas yang memadai untuk merepresentasikan kompleksitas pola beban listrik. Secara visual, kesesuaian pola prediksi dengan data aktual ini memperkuat interpretasi kuantitatif yang diperoleh dari perhitungan RMSE, MAE, dan MAPE. Tidak hanya sekadar menghasilkan nilai kesalahan rata-rata yang rendah, tetapi juga menunjukkan stabilitas prediksi dari waktu ke waktu. Dengan demikian, grafik perbandingan ini menjadi bukti empiris bahwa formulasi pemetaan masukan CMAC yang diterapkan dalam penelitian ini mampu menghasilkan performa yang relevan dan layak untuk diimplementasikan dalam skenario nyata prediksi beban listrik.

Selain kesesuaian umum pola prediksi dengan data aktual, perhatian khusus perlu diberikan pada respon CMAC terhadap fluktuasi beban listrik yang ekstrem, seperti lonjakan tiba-tiba pada periode beban puncak maupun penurunan tajam ketika beban bertransisi ke level rendah. Grafik perbandingan prediksi dengan data aktual memperlihatkan bahwa CMAC mampu mengikuti arah perubahan pada momen-momen kritis ini, meskipun terdapat sedikit keterlambatan dalam menangkap amplitudo yang sebenarnya. Hal ini menunjukkan bahwa struktur asosiasi CMAC cukup tanggap terhadap dinamika nonlinier, namun tetap terdapat batasan dalam akurasi absolut saat menghadapi variasi yang sangat cepat. Pada saat beban mengalami kenaikan tajam menuju puncak, kurva prediksi CMAC menunjukkan tren peningkatan yang konsisten dengan data aktual. Meskipun demikian, terlihat bahwa nilai prediksi cenderung sedikit berada di bawah kurva aktual, sehingga model seolah-olah meredam sebagian dari ekstremitas lonjakan. Hal serupa terjadi pada periode penurunan drastis, di mana CMAC mampu mengenali arah perubahan namun cenderung menghasilkan nilai prediksi yang lebih halus dibandingkan data aktual. Fenomena ini sejalan dengan karakteristik jaringan CMAC yang mengutamakan generalisasi dalam pemetaan input-output sehingga cenderung melunakkan variasi ekstrem untuk menjaga stabilitas prediksi jangka panjang.

Kendati demikian, kecenderungan CMAC untuk melakukan perataan ini justru dapat dianggap sebagai keunggulan ketika digunakan dalam konteks praktis. Dalam sistem tenaga listrik, lonjakan atau penurunan ekstrem sering kali bersifat anomali dan berpotensi menimbulkan kesalahan prediksi yang signifikan pada metode yang terlalu sensitif. Dengan sifat generalisasi yang melekat, CMAC tetap menjaga kestabilan model tanpa mudah terjebak pada noise atau variasi sesaat. Fakta ini terlihat jelas dari stabilitas metrik evaluasi pada data tengah dan akhir pengujian, di mana kesalahan relatif menurun meskipun dataset tetap mengandung fluktuasi alami. Dengan demikian, grafik perbandingan ini tidak hanya menegaskan kesesuaian pola prediksi terhadap tren beban listrik secara umum, tetapi juga mengungkap kemampuan CMAC untuk

menghadapi dinamika ekstrem dengan tingkat stabilitas yang baik. Hal ini memperkuat argumentasi bahwa formulasi pemetaan masukan dalam penelitian ini menghasilkan model yang adaptif, stabil, dan tetap praktis untuk diterapkan dalam prediksi beban listrik nyata yang sarat dengan ketidakpastian dan variasi ekstrem.

Analisis grafik prediksi dan data aktual yang telah dilakukan memperlihatkan bahwa CMAC mampu mengikuti tren umum beban listrik dengan baik, namun memperlihatkan karakteristik perataan pada titik-titik ekstrem. Fenomena ini semakin jelas jika ditinjau dari hasil kuantitatif pada metrik evaluasi RMSE, MAE, dan MAPE yang dihitung untuk segmen awal, tengah, dan akhir dari data pengujian. Pada segmen awal, yang sering kali merepresentasikan transisi beban dari kondisi normal menuju periode dengan variasi lebih tajam, nilai RMSE tercatat sebesar 0.30705, MAE sebesar 0.24137, dan MAPE sebesar 27.01. Nilai kesalahan yang relatif lebih tinggi pada bagian ini sejalan dengan hasil grafik, di mana terlihat bahwa CMAC sedikit tertinggal dalam menangkap kenaikan tajam beban. Hal ini menunjukkan bahwa pada fase awal, sensitivitas terhadap perubahan ekstrem masih menghasilkan deviasi prediksi yang cukup signifikan. Segmen tengah menunjukkan hasil yang lebih baik dengan RMSE sebesar 0.26044, MAE sebesar 0.22381, dan MAPE sebesar 24.673. Nilai ini menegaskan bahwa ketika pola beban lebih stabil meskipun tetap terdapat fluktuasi, CMAC dapat menghasilkan prediksi dengan kesalahan yang lebih rendah. Visualisasi grafik di bagian ini juga memperlihatkan bahwa kurva prediksi lebih rapat mengikuti data aktual, sehingga ketidakakuratan dalam menangkap titik ekstrem semakin berkurang.

Pada segmen akhir, nilai RMSE sebesar 0.26756, MAE sebesar 0.21813, dan MAPE sebesar 22.463, yang merupakan performa terbaik di antara ketiga segmen. Bagian ini memperlihatkan bahwa meskipun terdapat penurunan beban yang cukup tajam, CMAC mampu beradaptasi dengan baik, menghasilkan prediksi yang lebih dekat dengan data aktual dibandingkan segmen awal. Fenomena ini tercermin pula pada grafik, di mana perbedaan antara kurva prediksi dan aktual semakin mengecil meskipun terdapat dinamika ekstrem. Kombinasi antara analisis visual dan kuantitatif ini memperkuat pemahaman bahwa CMAC cenderung melakukan perataan terhadap variasi ekstrem, sehingga prediksi pada titik lonjakan atau penurunan tajam sedikit tertinggal dibandingkan data aktual. Namun, kecenderungan ini berbanding lurus dengan stabilitas prediksi secara keseluruhan, sebagaimana ditunjukkan oleh penurunan nilai MAPE dari segmen awal ke segmen akhir. Dengan kata lain, meskipun kesalahan relatif meningkat pada titik ekstrem, dampak keseluruhannya terhadap kinerja model tetap terkendali dan bahkan semakin membaik seiring dengan proses adaptasi model terhadap pola beban listrik sepanjang horizon pengujian.

Secara keseluruhan, hasil eksperimen memperlihatkan bahwa CMAC dengan formulasi pemetaan masukan yang digunakan dalam penelitian ini mampu memberikan performa prediksi yang cukup baik terhadap beban listrik. Hasil numerik dari evaluasi kinerja menunjukkan bahwa nilai RMSE, MAE, dan MAPE berada pada rentang yang konsisten dan stabil, dengan kecenderungan peningkatan akurasi pada segmen data tengah hingga akhir. Hal ini menegaskan bahwa meskipun CMAC masih memiliki keterbatasan dalam menangkap dinamika ekstrem pada beban listrik, khususnya lonjakan dan penurunan tajam di bagian awal pengujian, model ini tetap menunjukkan kemampuan adaptasi yang kuat seiring bertambahnya data yang diproses. Keterpaduan antara hasil visualisasi grafik dan perhitungan kuantitatif memberikan gambaran bahwa CMAC cenderung melakukan perataan pada pola beban yang fluktuatif, sehingga prediksi pada titik ekstrem tidak sepenuhnya presisi namun tetap dalam batas kesalahan yang dapat diterima. Lebih jauh, kecenderungan penurunan nilai MAPE dari awal ke akhir segmen pengujian mencerminkan bahwa model ini semakin mampu menyesuaikan representasi internalnya terhadap distribusi data. Dengan demikian, hasil eksperimen ini menunjukkan bahwa CMAC berpotensi menjadi metode yang andal dalam mendukung prediksi beban listrik jangka pendek, terutama ketika tujuan utamanya adalah menjaga keseimbangan antara akurasi dan efisiensi komputasi.

Jika dibandingkan dengan berbagai penelitian terdahulu mengenai prediksi beban listrik, hasil yang diperoleh melalui implementasi CMAC dalam penelitian ini menunjukkan pola yang

konsisten dengan temuan sebelumnya. Beberapa studi menggunakan metode jaringan saraf tiruan konvensional seperti multilayer perceptron atau recurrent neural network, yang pada dasarnya mampu memberikan akurasi tinggi namun sering kali menuntut biaya komputasi yang lebih besar dan waktu pelatihan yang lebih lama. Di sisi lain, penelitian-penelitian yang melibatkan CMAC umumnya menekankan keunggulannya dalam efisiensi komputasi dan kecepatan konvergensi, meskipun terkadang dihadapkan pada tantangan dalam menangani pola data yang sangat fluktuatif. Hasil penelitian ini memperkuat temuan tersebut, karena nilai RMSE, MAE, dan MAPE yang relatif rendah menunjukkan bahwa CMAC tetap kompetitif meskipun digunakan pada dataset beban listrik dengan karakteristik variabilitas yang tinggi. Kecenderungan CMAC untuk meratakan lonjakan ekstrem juga sejalan dengan laporan sebelumnya, yang menyoroti bahwa metode ini cenderung lebih stabil namun kurang sensitif terhadap anomali beban yang sangat tajam. Dengan demikian, penelitian ini memberikan kontribusi tambahan berupa penerapan formulasi pemetaan masukan yang lebih sistematis, sehingga proses normalisasi dan kuantisasi menjadi lebih terstruktur, sekaligus menjaga konsistensi akurasi prediksi sepanjang periode pengujian.

### 3.2 Analisis

Hasil eksperimen yang diperoleh menunjukkan bahwa formulasi pemetaan masukan memiliki peran yang sangat penting dalam menentukan akurasi prediksi CMAC. Proses pemetaan ini pada dasarnya mengubah variabel masukan yang bersifat kontinu ke dalam representasi diskret yang dapat diproses oleh arsitektur memori asosiatif. Apabila formulasi pemetaan tidak dilakukan secara tepat, maka representasi masukan akan kehilangan detail penting dan menyebabkan menurunnya kualitas prediksi. Dalam penelitian ini, pendekatan pemetaan dilakukan melalui normalisasi skala data masukan ke dalam rentang  $[0,1]$ , kemudian dilanjutkan dengan proses kuantisasi sesuai level resolusi yang ditetapkan. Dengan cara ini, informasi variabilitas beban listrik dapat tetap dipertahankan meskipun masukan telah diproyeksikan ke dalam ruang diskret. Hasil evaluasi metrik kinerja yang menunjukkan nilai RMSE, MAE, dan MAPE yang relatif rendah memperkuat bukti bahwa formulasi pemetaan masukan berperan besar dalam menjaga kedekatan antara hasil prediksi dengan data aktual.

Dari sisi efisiensi komputasi, CMAC menunjukkan kinerja yang unggul dibandingkan pendekatan jaringan saraf tiruan konvensional. Proses pelatihan hanya memerlukan sejumlah kecil epoch untuk mencapai konvergensi yang stabil, sebagaimana ditunjukkan pada eksperimen ini yang hanya menggunakan 10 epoch dengan laju belajar 0,12. Waktu komputasi relatif singkat, terutama karena struktur CMAC tidak mengandalkan operasi matriks kompleks melainkan memori asosiatif dengan mekanisme pengambilan indeks. Hal ini menjadikan CMAC lebih ringan untuk diterapkan pada dataset berukuran besar atau pada sistem dengan keterbatasan sumber daya komputasi. Kecepatan konvergensi yang dicapai juga memperlihatkan bahwa model mampu menyesuaikan parameter bobot dengan cepat tanpa mengalami fluktuasi error yang berlebihan. Stabilitas prediksi tercermin dari konsistensi nilai error pada segmen awal, tengah, dan akhir data uji, yang menunjukkan bahwa model tidak mengalami degradasi performa sepanjang rentang data.

Apabila dibandingkan dengan penelitian terdahulu, CMAC dalam penelitian ini memperlihatkan kesesuaian arah perkembangan metodologi dalam domain prediksi beban listrik. Metode prediksi berbasis deep learning memang sering menunjukkan keunggulan akurasi, tetapi dengan konsekuensi biaya komputasi yang tinggi dan kebutuhan data yang sangat besar. Sementara itu, CMAC menawarkan alternatif yang lebih sederhana, lebih cepat, dan lebih hemat sumber daya, meskipun dengan kelemahan relatif pada sensitivitas terhadap perubahan ekstrem yang sangat tajam. Dengan hasil yang diperoleh, penelitian ini menegaskan posisi CMAC sebagai metode prediksi yang layak digunakan dalam konteks sistem tenaga listrik, khususnya ketika diperlukan keseimbangan antara akurasi, efisiensi, dan kecepatan implementasi.

### 3.3 Implikasi

Hasil yang diperoleh dari penerapan CMAC dengan formulasi pemetaan masukan yang diusulkan memberikan beberapa implikasi penting, baik dari sisi praktis maupun akademis. Dari sisi penerapan di lapangan, model ini menunjukkan bahwa prediksi beban listrik dapat dilakukan dengan tingkat akurasi yang memadai menggunakan metode yang relatif ringan secara komputasi. Hal ini sangat relevan bagi sistem tenaga listrik modern, terutama di era integrasi energi terbarukan dan sistem distribusi cerdas yang menuntut prediksi beban secara cepat dan berkesinambungan. CMAC yang terlatih dengan baik dapat diintegrasikan ke dalam sistem manajemen energi untuk mendukung pengambilan keputusan terkait penjadwalan pembangkitan, pengaturan beban, maupun pengoperasian trafo distribusi dengan lebih efisien.

Dari sisi akademis, penelitian ini memperlihatkan bahwa formulasi pemetaan masukan bukan hanya sekadar prosedur teknis, tetapi merupakan aspek fundamental yang menentukan keberhasilan sebuah model prediksi berbasis CMAC. Temuan ini menegaskan bahwa kajian tentang struktur representasi masukan masih sangat relevan dan layak mendapat perhatian lebih dalam penelitian jaringan saraf tiruan non-konvensional. Keberhasilan menjaga akurasi meskipun dengan keterbatasan sumber daya komputasi juga membuka ruang penelitian lebih lanjut, misalnya pada pengembangan model hibrid yang menggabungkan CMAC dengan metode optimasi cerdas atau teknik pre-processing data yang lebih adaptif.

Di sisi lain, implikasi dari hasil ini juga menyingkap adanya batasan yang perlu dicermati. Meski CMAC terbukti efisien dan stabil, performanya cenderung lebih rentan terhadap variasi ekstrem beban listrik dibandingkan dengan model prediksi berbasis deep learning yang memiliki kemampuan abstraksi lebih dalam. Artinya, penerapan CMAC sebaiknya difokuskan pada skenario operasional di mana efisiensi komputasi menjadi prioritas utama, sementara kebutuhan prediksi yang benar-benar presisi pada titik ekstrem dapat dilengkapi dengan pendekatan lain. Dengan demikian, penelitian ini tidak hanya menghadirkan bukti empiris tentang efektivitas CMAC, tetapi juga memberikan arahan praktis mengenai ruang lingkup penerapan yang paling tepat bagi metode ini dalam sistem tenaga listrik nyata.

#### **4. KESIMPULAN**

Penelitian ini telah berhasil mengimplementasikan jaringan syaraf tiruan CMAC dengan formulasi baru pada pemetaan masukan untuk melakukan prediksi beban listrik. Melalui pemodelan yang disusun berdasarkan data historis sebanyak 34.167 sampel, dengan 23.916 data digunakan untuk proses pelatihan dan 10.251 data untuk pengujian, diperoleh hasil bahwa CMAC mampu mencapai akurasi yang memadai dengan tingkat kesalahan yang relatif kecil. Nilai metrik kinerja yang dicapai, yaitu RMSE sebesar 0.30272, MAE sebesar 0.23252, dan MAPE sebesar 25.735, menunjukkan bahwa model ini memiliki kemampuan prediksi yang konsisten dalam menangkap pola beban listrik. Bahkan ketika dilakukan evaluasi pada segmen data di awal, tengah, dan akhir pengujian, hasil metrik tetap stabil, meskipun ditemukan variasi performa yang mengikuti fluktuasi beban, terutama pada kondisi ekstrem.

Kontribusi utama penelitian ini terletak pada perumusan skema pemetaan masukan yang memungkinkan CMAC bekerja lebih adaptif dalam mengakomodasi sifat kontinu dan dinamis dari data beban listrik. Dengan pendekatan ini, CMAC tidak hanya menunjukkan efisiensi komputasi yang tinggi, tetapi juga tetap mampu menjaga stabilitas hasil prediksi. Hal ini memperlihatkan bahwa perbaikan pada tahap representasi masukan dapat menjadi kunci penting untuk meningkatkan kualitas model prediksi berbasis CMAC, tanpa harus menambah kompleksitas arsitektur maupun memperbesar kebutuhan sumber daya komputasi.

Meskipun demikian, penelitian ini juga mengungkap adanya keterbatasan, khususnya terkait kemampuan CMAC dalam menangani fluktuasi beban yang ekstrem secara lebih presisi. Oleh karena itu, penelitian lanjutan perlu diarahkan pada integrasi CMAC dengan metode optimasi lanjutan atau teknik pemrosesan awal data yang lebih cerdas, misalnya dengan kombinasi algoritma evolusioner atau metode fuzzy untuk meningkatkan ketahanan model terhadap kondisi ekstrem. Selain itu, pengujian pada skenario sistem tenaga listrik nyata dengan horizon waktu yang

lebih panjang juga perlu dilakukan guna menguatkan validitas dan reliabilitas model ini dalam aplikasi praktis. Dengan demikian, penelitian ini dapat disimpulkan sebagai langkah maju yang memperkuat pemahaman mengenai peran formulasi pemetaan masukan dalam jaringan CMAC serta menunjukkan potensinya sebagai solusi efisien dan adaptif dalam prediksi beban listrik pada sistem tenaga modern.

## DAFTAR PUSTAKA

- Abdulkareem, N. (2020). Monthly maximum load demand forecasting for sulaimani governorate using different weather conditions based on artificial neural network model. *Uhd Journal of Science and Technology*, 4(2), 10-17. <https://doi.org/10.21928/uhdjst.v4n2y2020.pp10-17>
- Achmad, M.I., Adinugroho, H., & Susanto, A. (2014, November 9). Cerebellar Model Articulation Controller (CMAC) for Sequential Images Coding. <https://doi.org/10.5281/zenodo.7330726>
- Achmad, M.I. & Sunantyo, T.A. (2009, Agustus 4). Cerebellar Model Associative Computer (CMAC) for Gravimetric Geoid study based on EGM96 and EIGEN-GL04C Geopotential Development. <https://doi.org/10.5281/zenodo.7330248>
- Achmad, M.I., Susanto, A., & Adinugroho, H. (2014, Oktober 8). Weights Behavior in the Solution Space of the Cerebellar Model Articulation Controller (CMAC) learning. <https://doi.org/10.5281/zenodo.7330539>
- Achmad, M.I., Susanto, A., & Adinugroho, H. (2014, Oktober 8). Pemetaan Alamat dan Fungsi Basis untuk Meningkatkan Unjuk-Kerja CMAC. <https://doi.org/10.5281/zenodo.7330500>
- Aguiar-Pérez, J. and Pérez-Juárez, M. (2023). An insight of deep learning based demand forecasting in smart grids. *Sensors*, 23(3), 1467. <https://doi.org/10.3390/s23031467>
- Ahmad, N., Ghadi, Y., Adnan, M., & Ali, M. (2022). Load forecasting techniques for power system: research challenges and survey. *Ieee Access*, 10, 71054-71090. <https://doi.org/10.1109/access.2022.3187839>
- Alves, E., Oliveira, J., Madeiro, F., & Marinho, M. (2022). A nonlinear optimized hybrid system for energy consumption forecasting from smart meters. *Learning and Nonlinear Models*, 20(1), 17-30. <https://doi.org/10.21528/lnlm-vol20-no1-art2>
- Alwi, M., Prayitno, B., Putra, R., Putra, E., & Palupiningsih, P. (2021). Rancang bangun sistem monitoring dan controlling penggunaan daya peralatan listrik rumah tangga menggunakan iot. *Petir*, 15(1), 57-62. <https://doi.org/10.33322/petir.v15i1.1383>
- Bişkin, O. and Çifçi, A. (2021). Forecasting of turkey's electrical energy consumption using lstm and gru networks. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 8(2), 656-667. <https://doi.org/10.35193/bseufbd.935824>
- Caessar, A., Nrartha, I., & Rosmaliati, R. (2024). Perbandingan metode koefisien dengan jaringan syaraf tiruan pada peramalan beban listrik jangka pendek. *saintek*, 6, 176-183. <https://doi.org/10.29303/saintek.v6i1.933>
- Cahyono, M. and Wirawan, S. (2021). Desain sistem informasi cerdas pada smart grid berbasis internet of things dan artificial neural network. *Jsai (Journal Scientific and Applied Informatics)*, 4(1), 11-19. <https://doi.org/10.36085/jsai.v4i1.1219>
- Cao, W., Liu, H., Zhang, X., & Zeng, Y. (2024). Residential load forecasting based on long short-term memory, considering temporal local attention. *Sustainability*, 16(24), 11252. <https://doi.org/10.3390/su162411252>
- Chen, B. and Wang, Y. (2021). Short-term electric load forecasting of integrated energy system considering nonlinear synergy between different loads. *Ieee Access*, 9, 43562-43573. <https://doi.org/10.1109/access.2021.3066915>
- Chen, Y., Bhutta, M., Abubakar, M., Xiao, D., Almasoudi, F., Naeem, H., ... & Faheem, M. (2023). Evaluation of machine learning models for smart grid parameters: performance analysis of arima and bi-lstm. *Sustainability*, 15(11), 8555. <https://doi.org/10.3390/su15118555>

- Correia, J., Caballero-Gaudes, C., Guediche, S., & Carreiras, M. (2020). Phonatory and articulatory representations of speech production in cortical and subcortical fmri responses. *Scientific Reports*, 10(1). <https://doi.org/10.1038/s41598-020-61435-y>
- Dewi, N. and Nugroho, R. (2021). Optimasi general regression neural network dengan fruit fly optimization algorithm untuk prediksi pemakaian arus listrik pada penyulang. *Komputasi Jurnal Ilmiah Ilmu Komputer Dan Matematika*, 18(1), 1-12. <https://doi.org/10.33751/komputasi.v18i1.2144>
- Dharmawan, R., Hasniaty, A., & Akil, Y. (2023). Pemodelan regresi untuk investigasi penggerak konsumsi listrik rumah tangga di kota makassar. *Jurnal Penelitian Enjiniring*, 26(1), 34-40. <https://doi.org/10.25042/jpe.052022.05>
- Dinh, T., Thirunavukkarasu, G., Seyedmahmoudian, M., Mekhilef, S., & Stojcevski, A. (2023). Energy consumption forecasting in commercial buildings during the covid-19 pandemic: a multivariate multilayered long-short term memory time-series model with knowledge injection. *Sustainability*, 15(17), 12951. <https://doi.org/10.3390/su151712951>
- Fadilah, M., Yusuf, A., & Huda, N. (2021). Prediksi beban listrik di kota banjarbaru menggunakan jaringan syaraf tiruan backpropagation. *Jurnal Matematika Murni Dan Terapan Epsilon*, 14(2), 81. <https://doi.org/10.20527/epsilon.v14i2.2961>
- Farsi, B., Amayri, M., Bouguila, N., & Eicker, U. (2021). On short-term load forecasting using machine learning techniques and a novel parallel deep lstm-cnn approach. *Ieee Access*, 9, 31191-31212. <https://doi.org/10.1109/access.2021.3060290>
- Feng, H. (2023). Load forecasting research of markov chain based on data modeling. *Journal of Physics Conference Series*, 2470(1), 012001. <https://doi.org/10.1088/1742-6596/2470/1/012001>
- Giap, Q., Nguyen, D., Nguyen, T., & Tran, T. (2022). Applying neural network and levenberg - marquardt algorithm for load forecasting in ia-grai district, gia lai province. *The University of Danang - Journal of Science and Technology*, 13-18. <https://doi.org/10.31130/ud-jst.2022.240ict>
- Hamdhani, M., Purwitasari, D., & Raharjo, A. (2022). Identifikasi profil konsumsi energi listrik untuk meningkatkan pendapatan dengan klustering. *Journal of Information System Graphics Hospitality and Technology*, 4(2), 62-70. <https://doi.org/10.37823/insight.v4i2.232>
- Hasan, M. (2023). Perhitungan proyeksi beban transformator dalam perencanaan kapasitas gardu induk 150 kv. *Jurnal Ilmiah Teknik Mesin Elektro Dan Komputer*, 3(3), 444-459. <https://doi.org/10.51903/juritek.v3i3.2229>
- He, X., Zhao, W., Zhang, L., Zhang, Q., & Li, X. (2024). A novel ensemble deep reinforcement learning model for short-term load forecasting based on q-learning dynamic model selection. *The Journal of Engineering*, 2024(7). <https://doi.org/10.1049/tje2.12409>
- Hebrail, G., & Bérard, A. (2006). Individual Household Electric Power Consumption [Dataset]. UCI Machine Learning Repository. <https://doi.org/10.24432/C58K54>
- Ihsan, B., Hamdani, D., & Hariyanto, N. (2020). Pengaruh strategi pengisian daya terhadap kenaikan beban puncak akibat penetrasi kendaraan listrik. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi (Jnteti)*, 9(3), 311-318. <https://doi.org/10.22146/v9i3.363>
- Islam, K., Kabir, M., Surja, A., & Iqbal, M. (2022). An effective short-term electrical load forecasting model: a constructive neural network approach. *European Journal of Engineering and Technology Research*, 7(4), 14-20. <https://doi.org/10.24018/ejeng.2022.7.4.2855>
- Kadri, R., Kahoui, H., & Sahed, A. (2023). Electricity consumption forecasting in algeria: a comparison of arima and gm (1,1) models. *Globalization and Business*, 8(16), 15-24. <https://doi.org/10.35945/gb.2023.16.002>
- Kalinchyk, V., Pobigaylo, V., Kalinchyk, V., Borychenko, O., & Meita, A. (2024). Application of neural networks for predicting electric load. *Bulletin of Ntu Khpi Series Problems of Electrical Machines and Apparatus Perfection the Theory and Practice*, (2 (12)), 50-55. <https://doi.org/10.20998/2079-3944.2024.2.10>

- Khan, S. (2023). Short-term electricity load forecasting using a new intelligence-based application. *Sustainability*, 15(16), 12311. <https://doi.org/10.3390/su151612311>
- Kong, Z., Zhang, Y., Wang, X., Sun, S., Zhou, C., Li, D., ... & Jin, B. (2020). Error prediction and structure determination for cmac neural network based on the uniform design method. *Expert Systems*, 38(2). <https://doi.org/10.1111/exsy.12614>
- Le, T., Huynh, T., Hong, S., & Lin, C. (2020). Hybrid neural network cerebellar model articulation controller design for non-linear dynamic time-varying plants. *Frontiers in Neuroscience*, 14. <https://doi.org/10.3389/fnins.2020.00695>
- Le, T., Quynh, N., Long, N., & Hong, S. (2020). Optimum design of function-link type-2 fuzzy asymmetric cmac based on self-organizing algorithm and modified jaya algorithm. *Ieee Access*, 8, 202365-202378. <https://doi.org/10.1109/access.2020.3036125>
- Le, T., Huynh, T., Quynh, N., Lin, C., & Hong, S. (2020). Chaotic synchronization using a self-evolving recurrent interval type-2 petri cerebellar model articulation controller. *Mathematics*, 8(2), 219. <https://doi.org/10.3390/math8020219>
- Lee, J. and Cho, Y. (2022). National-scale electricity peak load forecasting: traditional, machine learning, or hybrid model?. *Energy*, 239, 122366. <https://doi.org/10.1016/j.energy.2021.122366>
- Leni, D., Dwiharzandis, A., Sumiati, R., Haris, H., & Afriyani, S. (2023). Seleksi fitur berdasarkan korelasi pearson dalam pemodelan efisiensi energi bangunan. *Teknika Sains Jurnal Ilmu Teknik*, 8(2), 103-115. <https://doi.org/10.24967/teksis.v8i2.2525>
- Li, Z., Guan, Z., Yamamoto, T., & Omatu, S. (2023). Realization of a database-driven pid control system using a cmac memory. *Electronics and Communications in Japan*, 106(3). <https://doi.org/10.1002/ecj.12406>
- Li, Z., Hiraoka, K., & Yamamoto, T. (2024). Design and experimental evaluation of a data-driven pid controller using cerebellar memory. *Iet Control Theory and Applications*, 18(11), 1371-1382. <https://doi.org/10.1049/cth2.12694>
- Li, Z., Guan, Z., Yamamoto, T., & Omatu, S. (2023). Realization of a database-driven pid control system using a cmac memory. *Electronics and Communications in Japan*, 106(3). <https://doi.org/10.1002/ecj.12406>
- Lin, C., Lin, C., & Jhang, J. (2020). Dynamic system identification and prediction using a self-evolving takagi-sugeno-kang-type fuzzy cmac network. *Electronics*, 9(4), 631. <https://doi.org/10.3390/electronics9040631>
- Liu, F., Dong, T., & Liu, Y. (2022). An improved informer model for short-term load forecasting by considering periodic property of load profiles. *Frontiers in Energy Research*, 10. <https://doi.org/10.3389/fenrg.2022.950912>
- Liu, Y., Li, Y., Li, G., Lin, Y., Wang, R., & Fan, Y. (2023). Review of multiple load forecasting method for integrated energy system. *Frontiers in Energy Research*, 11. <https://doi.org/10.3389/fenrg.2023.1296800>
- Madrid, E. and António, N. (2021). Short-term electricity load forecasting with machine learning. *Information*, 12(2), 50. <https://doi.org/10.3390/info12020050>
- Mao, W., Chiu, Y., Lin, B., Sun, W., & Tang, J. (2021). Direct fuzzy cmac sliding mode trajectory tracking for biaxial position system. *Energies*, 14(22), 7802. <https://doi.org/10.3390/en14227802>
- Morimoto, J., Horio, M., Kaji, Y., Kawata, J., Higuchi, M., & Fujisawa, S. (2020). Method to expand the cmac model to composite-type model. *Journal of Robotics and Mechatronics*, 32(4), 745-752. <https://doi.org/10.20965/jrm.2020.p0745>
- Moustati, I., Gherabi, N., & Saadi, M. (2024). Time-series forecasting models for smart meters data: an empirical comparison and analysis. *Journal Européen Des Systèmes Automatisés*, 57(05), 1419-1427. <https://doi.org/10.18280/jesa.570517>

- Mumtahina, U., Alahakoon, S., & Wolfs, P. (2024). Hyperparameter tuning of load-forecasting models using metaheuristic optimization algorithms—a systematic review. *Mathematics*, 12(21), 3353. <https://doi.org/10.3390/math12213353>
- Nan, Y., Zhang, H., Zheng, J., Yang, K., & Ge, Y. (2023). Low-volume precision spray for plant pest control using profile variable rate spraying and ultrasonic detection. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1042769>
- Ngo, T., Hoang, D., Tran, T., & Nguyen, A. (2022). A novel self-organizing fuzzy cerebellar model articulation controller based overlapping gaussian membership function for controlling robotic system. *International Journal of Computers Communications & Control*, 17(4). <https://doi.org/10.15837/ijccc.2022.4.4606>
- Ngo, T., Tran, T., Le, T., & Lam, M. (2023). An application of modified t2fhc algorithm in two-link robot controller. *Journal of Robotics and Control (Jrc)*, 4(4), 509-520. <https://doi.org/10.18196/jrc.v4i4.18943>
- Nguyen, T. and Nguyen, T. (2020). Load forecasting for months of the lunar new year holiday using standardized load profile and support regression vector: case study ho chi minh city. *Journal of Technology & Innovation*, 1(1), 01-05. <https://doi.org/10.26480/jtin.01.2021.01.05>
- Omogoroye, O., Olaniyi, O., Adebisi, O., Oladoyinbo, T., & Olaniyi, F. (2023). Electricity consumption (kw) forecast for a building of interest based on a time series nonlinear regression model. *Asian Journal of Economics Business and Accounting*, 23(21), 197-207. <https://doi.org/10.9734/ajeba/2023/v23i211127>
- ÖZBAY, H. and Dalcalı, A. (2021). Effects of covid-19 on electric energy consumption in turkey and ann-based short-term forecasting. *Turkish Journal of Electrical Engineering & Computer Sciences*, 29(1), 78-97. <https://doi.org/10.3906/elk-2006-29>
- Piao, Z., Guo, C., & Sun, S. (2020). Adaptive backstepping sliding mode dynamic positioning system for pod driven unmanned surface vessel based on cerebellar model articulation controller. *Ieee Access*, 8, 48314-48324. <https://doi.org/10.1109/access.2020.2979234>
- Pratama, A. and Endah, S. (2021). Prediksi beban listrik pt. pln (persero) area semarang menggunakan metode support vector regression. *Jurnal Masyarakat Informatika*, 12(1), 1-9. <https://doi.org/10.14710/jmasif.12.1.41017>
- Purnomo, H., Suyono, H., & Hasanah, R. (2021). Peramalan beban jangka pendek sistem kelistrikan kota batu menggunakan deep learning long short-term memory. *Transmisi Jurnal Ilmiah Teknik Elektro*, 23(3), 97-102. <https://doi.org/10.14710/transmisi.23.3.97-102>
- Ran, T., Shi, G., Lin, J., & Meng, L. (2022). Decoupling control of an aviation remote sensing stabilization platform based on a cerebellar model articulation controller. *Machines*, 11(1), 5. <https://doi.org/10.3390/machines11010005>
- Rizqulloh, F., Prasetyono, S., & Cahyadi, W. (2020). Analisis perbandingan peramalan beban listrik jangka pendek antara metode backpropagation neural network dengan metode regresi linear. *Jurnal Arus Elektro Indonesia*, 6(3), 69. <https://doi.org/10.19184/jaei.v6i3.19210>
- Salma, S., Dewanta, F., & Abdillah, M. (2022). Klasifikasi beban listrik dengan machine learning menggunakan metode k-nearest neighbor. *Resistor (Elektronika Kendali Telekomunikasi Tenaga Listrik Komputer)*, 5(2), 163. <https://doi.org/10.24853/resistor.5.2.163-172>
- Sari, R., Kusri, K., Hidayat, T., & Orphanoudakis, . (2023). Improved lstm method of predicting cryptocurrency price using short-term data. *Ijccs (Indonesian Journal of Computing and Cybernetics Systems)*, 17(1), 33. <https://doi.org/10.22146/ijccs.80776>
- Semmelmann, L., Henni, S., & Weinhardt, C. (2022). Load forecasting for energy communities: a novel lstm-xgboost hybrid model based on smart meter data. *Energy Informatics*, 5(S1). <https://doi.org/10.1186/s42162-022-00212-9>
- Semmelmann, L., Resch, O., Henni, S., & Weinhardt, C. (2023). Privacy-preserving peak time forecasting with learning to rank xgboost and extensive feature engineering. *Iet Smart Grid*, 7(2), 172-185. <https://doi.org/10.1049/stg2.12137>

- Shabani, A., Dharmo, D., Panxhi, D., & Zavalani, O. (2023). Modelling and simulation of residential load profiles as an approach for data-driven prediction. *European Journal of Engineering and Technology Research*, 8(1), 59-65. <https://doi.org/10.24018/ejeng.2023.8.1.2970>
- Somarathne, E., Wijayakulasooriya, J., & Karunasinghe, D. (2022). Application of artificial neural network for short term electricity demand forecasting. *Kdu Journal of Multidisciplinary Studies*, 4(1), 106-116. <https://doi.org/10.4038/kjms.v4i1.44>
- Son, N. and Shin, Y. (2023). Short- and medium-term electricity consumption forecasting using prophet and gru. *Sustainability*, 15(22), 15860. <https://doi.org/10.3390/su152215860>
- Syed, D., Abu-Rub, H., Ghrayeb, A., Refaat, S., Houchati, M., Bouhali, O., ... & Bañales, S. (2021). Deep learning-based short-term load forecasting approach in smart grid with clustering and consumption pattern recognition. *Ieee Access*, 9, 54992-55008. <https://doi.org/10.1109/access.2021.3071654>
- Tang, B., Li, X., Liao, J., & Chen, Q. (2022). Ultralow power consumption and large dynamic range synaptic transistor based on  $\alpha$ -in<sub>2</sub>se<sub>3</sub> nanosheets. *Acs Applied Electronic Materials*, 4(2), 598-605. <https://doi.org/10.1021/acsaelm.1c00970>
- Γιαμαρέλος, N., Zois, E., Papadimitrakis, M., Στοιγιάννος, M., Livanos, N., & Alexandridis, A. (2021). Short-term electric load forecasting with sparse coding methods. *Ieee Access*, 9, 102847-102861. <https://doi.org/10.1109/access.2021.3098121>
- Voloshko, A., Bederak, Y., & Kozlovskiy, O. (2020). An improved pre-forecasting analysis of electrical loads of pumping station. *Resource-Efficient Technologies*, (4), 20-29. <https://doi.org/10.18799/24056537/2019/4/265>
- Wang, S., Lin, C., & Li, C. (2021). Design of adaptive tsk fuzzy self-organizing recurrent cerebellar model articulation controller for chaotic systems control. *Applied Sciences*, 11(4), 1567. <https://doi.org/10.3390/app11041567>
- Wang, K., Yu, H., Song, G., Xu, J., Li, J., & Li, P. (2022). Adaptive forecasting of diverse electrical and heating loads in community integrated energy system based on deep transfer learning. *Frontiers in Energy Research*, 10. <https://doi.org/10.3389/fenrg.2022.1008216>
- Wangmo, C., Basnet, K., Rai, D., Wangdi, T., & Lhendup, T. (2020). Electricity demand forecast of college of science and technology, royal university of bhutan by 2030. *JEP*. <https://doi.org/10.7176/jep/11-30-05>
- Yakubu, O. and C., N. (2021). Electricity consumption forecasting using dft decomposition based hybrid arima-dlstm model. *Indonesian Journal of Electrical Engineering and Computer Science*, 24(2), 1107. <https://doi.org/10.11591/ijeecs.v24.i2.pp1107-1120>
- Ye, H., Zhou, Y., Li, Q., Xu, W., & Zheng, X. (2020). A deep learning method for short-term residential load forecasting in smart grid. *Ieee Access*, 8, 55785-55797. <https://doi.org/10.1109/access.2020.2981817>
- Zhang, D., Tong, H., Li, F., Xiang, L., & Ding, X. (2020). An ultra-short-term electrical load forecasting method based on temperature-factor-weight and lstm model. *Energies*, 13(18), 4875. <https://doi.org/10.3390/en13184875>
- Zhang, R., Zhang, C., & Yu, M. (2021). A similar day based short term load forecasting method using wavelet transform and lstm. *Ieej Transactions on Electrical and Electronic Engineering*, 17(4), 506-513. <https://doi.org/10.1002/tee.23536>
- Zhao, T., Zhang, C., Ujeed, T., & Ma, L. (2022). Methods on reflecting electricity consumption change characteristics and electricity consumption forecasting based on clustering algorithms and fuzzy matrices in buildings. *Building Services Engineering Research and Technology*, 43(6), 703-724. <https://doi.org/10.1177/01436244221122851>
- Zhong, L. and Wang, Y. (2022). Short-term power load forecasting based on improved bp neural network from genetic algorithm and simulated annealing algorithm. *Journal of Physics Conference Series*, 2401(1), 012087. <https://doi.org/10.1088/1742-6596/2401/1/012087>