

Métodos de otimização em sistemas de gestão de energia: uma revisão

Dárvyn C. Posselt¹³, Matheus N. Amorim², André R. Rafael², Iwens G. S. Júnior²³,
Carlos E. Pereira¹⁴

¹ Universidade Federal do Rio Grande do Sul (UFRGS) – Porto Alegre – RS – Brasil

² Universidade Federal de Goiás (UFG) - Goiânia - GO - Brasil

³ Centro de Competência EMBRAPII em Tecnologias Imersivas (AKCIT) - Goiânia - GO - Brasil

⁴ Centro de Competência EMBRAPII em Agricultura Digital (CEDRA) – Porto Alegre – RS – Brasil

{darvincassiano@gmail.com, matheus_amorim@discente.ufg.br,
andre.ribeiro@discente.ufg.br, iwens@ufg.br, cpereira@ufrgs.br}

Abstract. *The optimization of energy consumption and decentralized generation in remote environments is one of the main challenges of energy transition. In this context, Energy Management Systems (EMS) play a significant role by enabling demand monitoring, forecasting, and control. Various optimization methods have been applied to these systems, ranging from classical techniques to metaheuristics and artificial intelligence, each with specific performance and applicability features. This article reviews the main optimization methods employed in EMS, discussing their advantages, limitations, and application areas.*

Resumo. *A otimização do consumo e da geração descentralizada de energia em ambientes remotos é um dos principais desafios da transição energética. Nesse contexto, os Sistemas de Gestão de Energia (Energy Management Systems – EMS) desempenham papel central ao permitirem o monitoramento, a previsão e o controle da demanda. Diversos métodos de otimização têm sido aplicados a esses sistemas, abrangendo desde técnicas clássicas até metaheurísticas e inteligência artificial, cada uma com características próprias de desempenho e aplicabilidade. Este artigo revisa os principais métodos de otimização empregados em EMS, discutindo suas vantagens, limitações e áreas de aplicação.*

1. Introdução

A crescente integração de fontes renováveis de energia e a digitalização das redes elétricas têm impulsionado a demanda por sistemas de gestão energética mais eficientes e inteligentes. Nesse contexto, os Sistemas de Gestão de Energia (Energy Management Systems – EMS) desempenham papel central, uma vez que possibilitam o monitoramento, a previsão e o controle do consumo e da geração de energia em ambientes descentralizados (WANG; MAO; KHODAEI, 2021). O uso de técnicas de otimização tem se consolidado como estratégia fundamental para aumentar a eficiência, reduzir custos e mitigar impactos ambientais, tornando-se um campo de pesquisa cada vez mais relevante (SHARDA; SHARMA; SINGH, 2021).

Os métodos de otimização aplicados a EMS abrangem desde abordagens clássicas, como programação linear, inteira e dinâmica, até técnicas baseadas em metaheurísticas e inteligência artificial como em algoritmos de *machine learning (ML)*. Cada método apresenta características específicas quanto à complexidade computacional, capacidade de convergência e aplicabilidade em cenários com múltiplas variáveis, incertezas ou restrições não lineares. A escolha adequada do algoritmo impacta diretamente no desempenho do sistema, sendo crucial compreender seus princípios e limitações.

Nos últimos anos, o avanço da Internet das Coisas (IoT), aliado à crescente participação de fontes renováveis e à necessidade de maior eficiência, tem ampliado as possibilidades de aplicação dos métodos de otimização em diferentes cenários energéticos (SHREENIDHI; RAMAIAH, 2022). A literatura aponta que tais técnicas têm sido exploradas em contextos diversos, como redes inteligentes, *microgrids*, ambientes residenciais e comerciais, permitindo maior integração entre a geração, o armazenamento e o consumo (HUANG; JIN, 2024). A variedade de abordagens encontradas reforça a relevância da análise comparativa entre métodos, de modo a compreender quais algoritmos apresentam melhor desempenho frente às diferentes restrições e objetivos de cada aplicação.

O presente artigo tem como objetivo revisar os principais métodos de otimização utilizados em sistemas de gestão de energia, com ênfase nos EMS, e discutir suas áreas de aplicação, vantagens e limitações. Busca-se, ainda, identificar lacunas não exploradas na área, possibilitando a proposição de perspectivas futuras de pesquisa. A contribuição deste trabalho reside em fornecer uma visão abrangente do estado da arte, servindo como base para novos estudos e para o desenvolvimento de soluções inovadoras voltadas à eficiência energética, identificando e endereçando oportunidades na área.

2. Metodologia

A revisão da literatura foi conduzida com o objetivo de identificar e analisar os principais métodos de otimização aplicados a sistemas de gestão de energia, com ênfase em Energy Management Systems (EMS). Para tanto, foram consultadas três bases de dados de referência na área: Scopus, IEEE Xplore e ACM Digital Library.

As buscas foram realizadas utilizando combinações de palavras-chave relacionadas a “Energy Management Systems”, “Optimization”, “Algorithms” e “Energy Management”, considerando publicações no período de 2020 a data da consulta, 15 de setembro de 2025. Foram incluídos artigos publicados em periódicos, escritos em inglês ou português, que apresentassem métodos de otimização aplicados especificamente ao contexto de EMS ou à gestão de energia em ambientes descentralizados.

Os critérios de exclusão abrangeram artigos de caráter estritamente conceitual, sem aplicação prática ou experimental, artigos que não descrevessem de forma clara o algoritmo utilizado, bem como artigos que não empregassem sensores para análise do sistema. Além disso, foram descartados artigos duplicados entre as bases.

Ao final do processo de triagem, foram identificados 93 artigos, dos quais 73 provenientes da base Scopus, 19 da base IEEE Xplore e 1 da base ACM Digital Library. Após a aplicação dos critérios de elegibilidade, 30 estudos foram selecionados para compor a análise desta revisão. Dos trabalhos lidos, apenas 2 não são exclusivamente voltados para o residencial e abordam redes Microgrids como ponto chave. A separação advém da própria literatura, que tem focado apenas neste setor. Este fato demonstra que a gestão de energia

ainda tem diversos campos para expandir como o industrial, rural e até mesmo a gestão energética dos novos datacenters.

3.Fundamentação teórica

Os Sistemas de Gestão de Energia (EMS) são desenvolvidos no contexto de uma rede elétrica com um crescente número de cargas conectadas, bem como pontos de geração. Esse cenário traz grande complexidade, mas oferece oportunidade para organizar a gestão destes elementos, de acordo com os requisitos das aplicações e demandas dos usuários. O desafio central está em garantir eficiência, confiabilidade e redução de custos, para diferentes perfis de usuários com diferentes condições de redes disponíveis (LIÑAN-REYES; GARRIDO-ZAFRA; GIL-DE-CASTRO et al., 2021).

Sua arquitetura característica é composta por 3 camadas de informação principais representadas na Figura 1: (i) Monitoramento: sendo responsável por obter informações de todos os componentes do sistema, tanto de geração, quanto consumo e sensores auxiliares (ELKHOLY et al., 2022). (ii) Log e previsão: sistema responsável por armazenar os dados de monitoramento e gerar previsões de acordo com o estado atual do sistema (NAKIP et al., 2023), (KARUNA et al., 2024). (iii) Otimização e Controle: visto geralmente como o cérebro do EMS, onde as informações de previsão e o estado completo do sistema são recebidas e decisões são tomadas de acordo com a prioridade definida no algoritmo de otimização (CONSTANTINO et al., 2025), (BAHMANYAR; RAZMJOOY; MIRJALILI, 2022).

Dentro das arquiteturas propostas nos últimos anos nota-se um grande foco no método de otimização aplicado, por ser o responsável pelo resultado do sistema. Métodos clássicos, heurísticos e de inteligência artificial têm sido aplicados para atender a essas demandas, cada qual apresentando vantagens e limitações em termos de tempo de processamento, capacidade de lidar com incertezas e complexidade computacional e de implantação (POLAMURI et al., 2024).

Métodos clássicos são baseados em otimização matemática clássica e possuem fórmulas bem definidas para chegar no resultado ótimo do sistema. Demandam, porém, modelagem precisa para chegar a um bom resultado e tendem a apresentar pouca flexibilidade para alterações no sistema (BAHMANYAR et al 2022). Já os métodos heurísticos e metaheurísticos abordam um problema de ajuste de variáveis, testando combinações até encontrar um caminho melhor sem, contudo, garantir a otimalidade. Sua complexidade reduz, por não ter o rigor de fórmulas matemáticas exatas, mas ainda se beneficia de boas formulações (ROCHD et al., 2021). Métodos envolvendo IA, ainda podem ter múltiplas subclassificações, mas em geral, podem ser desenvolvidas sem a necessidade de uma modelagem completa do ambiente físico por obter bons resultados apenas com reconhecimento de padrões (CORREA-DEVAL et al., 2022).

Dentre os objetivos de otimização, o mais comum é a redução do custo de energia elétrica, porém outros focos têm se tornado frequentemente abordados, como conforto do usuário, estabilidade de redes críticas, bem como sistemas de otimização multiobjetivo, ou híbridos, capazes de contemplar múltiplos focos e permitem que o usuário defina a ordem de prioridade (ELKHOLY et al., 2022).

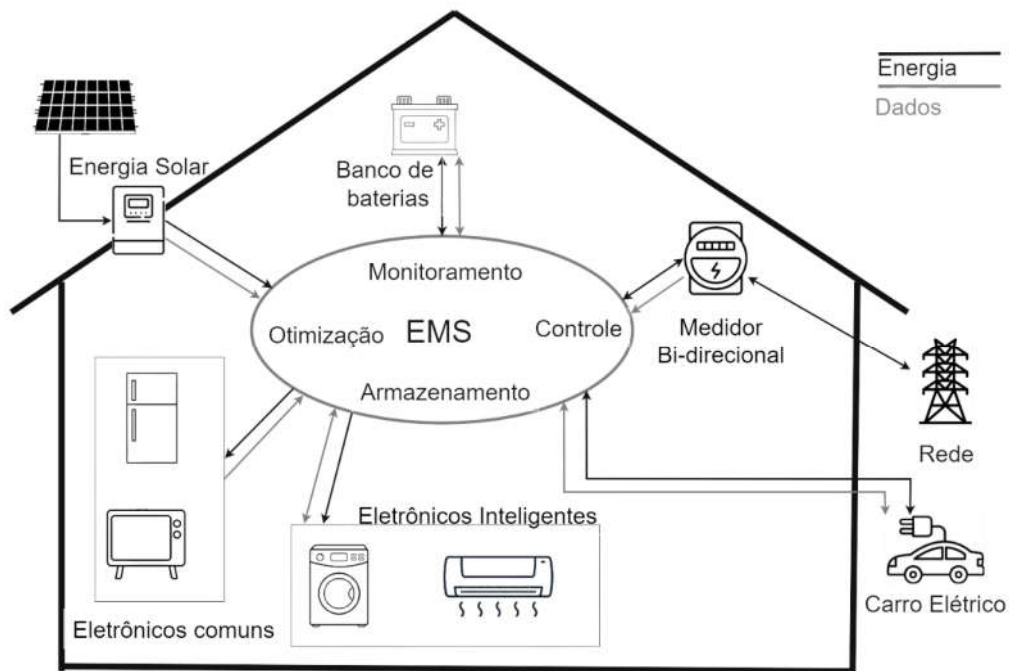


Figura 1. Exemplo de arquitetura EMS. Fonte: autor

4.Principais métodos de otimização utilizados

Na análise de 30 artigos selecionados, exemplificada pela Figura 2 e detalhada na Tabela 1, percebe-se que os métodos de otimização aplicados em EMS nos últimos anos podem ser divididos em três grandes grupos: i) métodos matemáticos clássicos, ii) algoritmos heurísticos/metaheurísticos e iii) técnicas baseadas em inteligência artificial (IA). Observou-se uma predominância das metaheurísticas, em 43% dos artigos analisados, o que a consolida como a metodologia mais explorada nos estudos recentes. Outros métodos explorados foram encontrados, mas em geral podem ser classificados como heurísticos, por proporem uma metodologia para ordenação.




Figura 2. Análise de dispersão dos trabalhos

Alguns trabalhos, como Garrido-Zafra et al., 2021 e Shakir et al., 2025 focam em métodos matemáticos, abordando sistemas de Linear Programming (LP), Mixed-Integer

Linear Programming (MILP) e Dynamic Programming (DP). Estes modelos são frequentemente aplicados em problemas de alocação de recursos e tomada de decisão, sendo bons candidatos para o EMS. A LP estrutura o problema a partir de funções objetivo e restrições lineares, admitindo variáveis contínuas e permitindo soluções em espaços convexos. A MILP, por sua vez, estende esse arcabouço ao incorporar variáveis inteiras ou binárias, viabilizando a modelagem de situações em que as decisões são discretas ou indivisíveis. A DP, por sua vez, distingue-se por decompor o problema original em uma sequência de subproblemas interdependentes, resolvidos de forma recursiva com base no princípio da otimalidade. Como apresentado anteriormente, estes métodos matemáticos dependem de uma modelagem precisa do sistema para boa operação.

A adoção de métodos que utilizam conceitos de IA é crescente, como observado em Rehman, 2025 e Nakip et al., 2023. Estes trabalhos apresentam técnicas de previsão ou tomada de decisão em tempo real. Para a previsão são utilizados métodos como Gradient Boosting (GB), Support Vector Machine (SVM) ou ML. Já para a decisão em tempo real o método mais utilizado é o Deep Reinforcement Learning (DRL). Este grupo de métodos beneficia-se de um grande volume de dados, Big Data (BD), que alimentam o sistema e possibilitam o treinamento contínuo do modelo. A desvantagem deste método fica por conta de seu alto custo computacional, principalmente na fase de treinamento dos algoritmos, sendo um desafio executar modelos complexos em tempo real para atuação no sistema.

Algoritmos heurísticos e metaheurísticos também se destacaram na busca realizada. A grande maioria dos trabalhos utilizou apenas estes métodos ou uma combinação destes com modelos matemáticos ou de IA. Dentro desta área o maior foco foi em algoritmos populacionais, como Genetic Algorithm (GA) (FAYEZ; AMER; EL TANTAWY, 2021), Bald Eagle Search Optimization (BESOA) (ALHASNAWI; JASIM; SIANO, 2022), Butterfly Optimization Algorithm (BOA) (WANG; MAO; KHODAEI, 2021) e Particle Swarm Optimization (PSO) (ROCHD et al., 2021). Este tipo de proposta geralmente é inspirado em algum comportamento observável em populações, e busca replicar tal comportamento, criando uma população de respostas que coopere para chegar em um resultado ótimo. A escolha de métodos populacionais decorre de sua boa resposta a sistemas com múltiplas variáveis independentes, pois o algoritmo consegue ser agnóstico ao significado da variável e buscar apenas a otimização. Este grupo se caracteriza por um equilíbrio entre custo e complexidade de modelagem matemática. Sua abordagem de análise exploratória guiada permite a obtenção de resultados significativos, mesmo na ausência de um conhecimento completo do sistema.

Outros estilos de algoritmo explorados em artigos foram os métodos híbridos ou meméticos, que juntam duas abordagens, a fim de reduzir o *trade-off* de cada método, buscando manter a otimalidade da solução. A exemplo de Alhasnawi et al., 2022 em que se propôs uma divisão de estágios em que, no primeiro estágio, foi aplicado um algoritmo Backtracking Search Algorithm, ajustado em um segundo estágio por um Multi-Agent System (MAS). Outras propostas inovadoras unem técnicas de previsão baseadas em IA com metaheurística, como em Constantinou et al., 2023, onde foi proposto o uso de PSO para agendamento de cargas enquanto uma SVM realiza a previsão de geração renovável e de variáveis climáticas. Essa abordagem mostra-se bastante promissora para cenários complexos, uma vez que esses métodos híbridos combinam um planejamento abrangente

com ajustes locais em tempo real. Isso permite lidar com imprevistos, como mudanças climáticas ou a ativação de dispositivos fora do horário programado.

Tabela 1: Aplicação e Métodos de Otimização dos Artigos

Referência	Local de Aplicação	Método de Otimização
FAYEZ et all 2021	Residencial	GA, PSO, WOA, SCA
GARRIDO-ZAFRA et al., 2021	Residencial	ML + BD + heurísticas
ALHASNAWI; JASIM; SIANO, 2022	Residencial	BESOA multiobjetivo
CORREA-DEVAL et al., 2022	Residencial	Rede Neural SE-IF BiLSTM
ELKHOLY et al., 2022	Residencial	LP
ROCHD et al., 2021	Residencial	PSO
WANG; MAO; KHODAEI, 2021	Residencial	BOA
ALHASNAW et al., 2022	Residencial	BSA e PSO binário
SHARDA; SHARMA; SINGH, 2021	Residencial	Least Slack Time (LST)
CONSTANTINOU et al., 2025	Residencial	GreenCap+ e GA
SHREENIDHI; RAMAIAH, 2022	Residencial	Deep Convolutional Network e metaheurística
CONSTANTINOU et al., 2023	Residencial	GA + heurísticas locais
GUAN et al., 2020	Residencial	PSO e SVM
GHOSH et al., 2024	Residencial	DSM
POLAMURI et al., 2024	Residencial	Reconhecimento de padrões + data mining
SHAKIR et al., 2025	Residencial	MPC e MILP
KORMPAKIS et al., 2025	Residencial	ML
RAMACHANDRA; RAJASEKAR, 2025	Residencial	Multi-Objective OptimizationPUMA
SENTHILKUMAR et al., 2024	DC Microgrids	Simulated Annealing Optimization
ABISHU et al., 2024	Residencial	Deep Reinforcement Learning
BAHMANYAR; RAZMJOOY; MIRJALILI, 2022	Residencial	Multi-Objective Arithmetic Optimization Algorithm
HUANG; JIN, 2024	Residencial/Microgrid	Grey Wolf Crow Search Optimization
KIM; KIM, 2024	Residencial	Tarifa bidirecional em tempo real (CBi-RTP)
HAMOUDA; DWEDAR, 2020	Residencial	Power Limit Management

VINJAMURI; BURTHI, 2022	Residencial	Metaheurístico com ML
REHMAN, 2025	Residencial	Proximal Policy Optimization com DRL
NAKIP et al., 2023	Residencial	Neural Network
KARUNA et al., 2024	Residencial	Gradient Boosting
RAMACHANDRA; RAJASEKAR, 2024	Residencial	Multi-objective Mountain Gazelle Optimization
LIN, 2021	Residencial	GA multiobjetivo

5. Análise comparativa dos métodos

A análise dos artigos mais relevantes evidencia uma diferenciação entre abordagens tradicionais e propostas recentes. Embora GA e PSO permaneçam como referências em otimização e comparação, os estudos destacados avançam com soluções inovadoras, híbridas e/ou validadas em cenários próximos da realidade. Nesse conjunto, os métodos clássicos (LP, MILP e DP) praticamente não aparecem, o que reforça sua limitação em ambientes complexos e dinâmicos: são eficazes em problemas bem definidos, mas mostram restrições diante da volatilidade típica de EMS complexos.

Do ponto de vista arquitetural, duas contribuições aproximam-se ao enfatizar coordenação distribuída e autonomia local. O trabalho Alhasnawi et al., 2022 propõe uma divisão explícita entre planejamento e execução: uma metaheurística agenda cargas (planejamento) e um MAS executa dinamicamente essas decisões (execução). Em consonância com a tomada de decisão distribuída, Abishu et al., 2024 combina DRL com um MAS no qual cada agente, segmentado por tipo de carga (fixas, deslocáveis, ajustáveis em potência), decide localmente. Assim, estes convergem ao dissociar papéis (planejar/executar) e ao deslocar a inteligência para a borda do sistema, favorecendo descentralização e aprendizado contínuo.

Ainda no eixo de adaptação *online*, Abishu et al., 2024 e Rehman, 2025 aproximam-se ao empregar DRL para lidar com dinâmicas do ambiente. Em Abishu et al., 2024, o arranjo multiagente permite aprendizado contínuo e objetivo múltiplo; em Rehman, 2025, o uso do algoritmo Proximal Policy Optimization (PPO) visa viabilizar ajustes contínuos das ações conforme novas informações chegam, otimizando a política de consumo ao longo do tempo. Em conjunto, esses estudos enfatizam a capacidade dos métodos de Reinforcement Learning (RL) de ajustar-se iterativamente a estados variáveis do EMS.

Três trabalhos se conectam ao incorporar previsão para orientar decisões de otimização. Guan et al., 2020 utiliza PSO em regime *rolling*, integrando previsões de geração renovável e variáveis ambientais por SVM, de modo a antecipar cenários e alinhar decisões à variabilidade das fontes. Já Vinjamuri; Burthi, 2022 aplica GB para prever padrões de consumo e geração em *smart homes*, alcançando alta precisão preditiva, evidenciando que ganhos expressivos podem advir de reduzir incertezas na previsão, mesmo quando a etapa de otimização é simples. Em conjunto estes trabalhos demonstram que, com atenção ao passado, pode-se gerar bons resultados no futuro de EMS.

Outro eixo de convergência está na escalabilidade e validação prática. Ramachandra; Rajasekar, 2025 apresenta uma arquitetura escalável para múltiplas residências, com Kubernetes para orquestração de serviços e containers, interface web em ReactJS e uso do

método metaheurísticos Multi-Objective PUMA Optimization (MPO), priorizando capacidade de expansão e usabilidade. (Constantinou et al., 2025) avança do ambiente de simulação para um protótipo físico em residência, no qual o GreenCap+ — algoritmo memético que combina GA e heurísticas locais — resolve um problema multiobjetivo de redução de consumo e manutenção do conforto do usuário, dentro de uma interface de gestão energética. As decisões do algoritmo impactam cargas e recursos reais. Por fim Ramachandra; Rajasekar, 2024 valida um algoritmo metaheurísticos Multi-objective Mountain Gazelle Optimization (MMGO) em um cluster de 50 residências, coordenando em tempo real diferentes perfis de consumo e cargas. Dessa forma enfatizam que a evolução de EMS exige tanto escalabilidade, quanto comprovação em cenários de operação real.

A qualidade da energia surge como um objetivo de otimização relevante, conforme ilustrado por Vinjamuri; Burthi, 2022, que propõe um algoritmo híbrido metaheurístico com auxílio de ML. Este algoritmo visa mitigar distorções harmônicas e manter o fator de potência, evidenciando que o EMS pode incorporar metas além de custo/consumo. Os ganhos relatados demonstram que a integridade da forma de onda e a aderência a critérios de qualidade podem ser buscadas, promovendo uma maior durabilidade dos equipamentos da rede.

Assim, os trabalhos avaliados diferenciam-se não apenas pelo método de otimização empregado, mas pela forma como combinam previsão, escalabilidade, descentralização, novos objetivos ou validação prática. Esse conjunto reforça que a evolução dos EMS não está apenas em criar algoritmos, mas em aplicar métodos de forma inovadora e orientada a problemas reais.

6. Conclusão

A revisão realizada proporcionou uma visão abrangente dos métodos de EMS desenvolvidos, focando em suas otimizações e áreas de aplicação, predominantemente residenciais. Esta análise revelou lacunas significativas para futuras investigações. A limitação atual a sistemas residenciais sugere a exploração em edificações maiores e até mesmo em contextos rurais. Concomitantemente, a expansão para sistemas mais complexos exige um foco em escalabilidade, com a arquitetura descentralizada emergindo como uma solução promissora para a interação de múltiplos equipamentos. Adicionalmente, a qualidade da energia representa um campo pouco explorado que pode, contudo, oferecer maior estabilidade à rede. Finalmente, com este olhar sobre a técnica percebe-se que sistemas EMS ainda possuem campo de desenvolvimento para atingir seu potencial de aplicação.

Referências

- Fayez, H.M., Amer, G.M., El tantawy, E.S.F. (2021) "Load Management in Smart Home Using Intelligent Algorithms", *22nd International Middle East Power Systems Conference (MEPCON)*, IEEE, 521–527.
- Liñan-reyes, M., Garrido-zafra, J., Gil-de-castro, A.G.D. et al. (2021) "Energy management expert assistant, a new concept", *Sensors (MDPI)*, 21.
- Alhasnawi, B.N., Jasim, B.H., Siano, P. et al. (2022) "A Novel Solution for Day-Ahead Scheduling Problems Using the IoT-Based Bald Eagle Search Optimization Algorithm", *Inventions (MDPI)*, 7.

- Correa-delval, M., Sun, H., Matthews, P.C. et al. (2022) "Appliance Scheduling Optimisation Method Using Historical Data in Households with RES Generation and Battery Storage Systems", *5th International Conference on Renewable Energy and Power Engineering (REPE)*, 442–447.
- Elkholy, M.H., Senjyu, T., Elsayed lotfy, M.E. et al. (2022) "Design and Implementation of a Real-Time Smart Home Management System Considering Energy Saving", *Sustainability (MDPI)*, 14.
- Rochd, A., Benazzouz, A., Ait abdelmoula, I. et al. (2021) "Design and implementation of an AI-based & IoT-enabled Home Energy Management System: A case study in Benguerir — Morocco", *Energy Reports (Elsevier)*, 7, 699–719.
- Wang, X., Mao, X., Khodaei, H. (2021) "A multi-objective home energy management system based on internet of things and optimization algorithms", *Journal of Building Engineering*, 33.
- Alhasnawi, B.N., Jasim, B.H., Mansoor, R.D. et al. (2022) "A new Internet of Things based optimization scheme of residential demand side management system", *IET Renewable Power Generation*, 16, 1992–2006.
- Sharda, S., Sharma, K., Singh, M. (2021) "A real-time automated scheduling algorithm with PV integration for smart home prosumers", *Journal of Building Engineering*, 44.
- Constantinou, S., Costa, C., Konstantinidis, A. et al. (2025) "A Sustainable Energy Management Framework for Smart Homes", *IEEE Transactions on Sustainable Computing*, 10, 70–81.
- Shreenidhi, H.S., Ramaiah, N.S. (2022) "A two-stage deep convolutional model for demand response energy management system in IoT-enabled smart grid", *Sustainable Energy, Grids and Networks (Elsevier)*, 30.
- Constantinou, S., Polycarpou, N., Costa, C. et al. (2023) "An IoT Data System for Solar Self-Consumption", *24th IEEE International Conference on Mobile Data Management (MDM)*, 65–72.
- Guan, Y., Feng, W., Wu, Y. et al. (2020) "An IoT Platform-based Multi-objective Energy Management System for Residential Microgrids", *IEEE 9th International Power Electronics and Motion Control Conference*, 3107–3112.
- Ghosh, A., Goswami, A.K., Basu, A. et al. (2024) "An IoT-based Smart Building Energy Management using DSM Strategies", *3rd International Conference on Power Electronics and IoT Applications in Renewable Energy and its Control (PARC)*, 123–128.
- Polamuri, S.R., Nalla, L.V., Madhuri, A.D. et al. (2024) "Analyse The Energy Consumption by Integrating the IOT and Pattern Recognition Technique", *2nd International Conference on Disruptive Technologies (ICDT)*, 607–610.
- Shakir, A., Zhang, J., He, Y. et al. (2025) "Coordinated Optimization of Household Air Conditioning and Battery Energy Storage Systems: Implementation and Performance Evaluation", *Processes (MDPI)*, 13.
- Kormpakis, G., Lekidis, A., Papias, I. et al. (2025) "Holistic framework for household energy management services", *IEEE*.

- Ramachandra, N., Rajasekar, N. (2025) "Kubernetes and IoT-based next-generation scalable energy management framework for residential clusters", *Journal of Building Engineering*, 104.
- Senthilkumar, G., Mallala, B., Sivarajan, S. et al. (2024) "Maximizing Power Utilization through Machine Learning and IoT based Power Flow Strategies in DC Micro Grids with Renewable Energy Resources", *Proceedings of the 7th International Conference on Inventive Computation Technologies*, 1166–1171.
- Abishu, H.N., Mohammed, A.M., Márquez, S. et al. (2024) "Multi-Agent DRL-based Multi-Objective Demand Response Optimization for Real-Time Energy Management in Smart Homes", *20th International Wireless Communications & Mobile Computing Conference*, 1210–1217.
- Bahmanyar, D., Razmjoo, N., Mirjalili, S.J. (2022) "Multi-objective scheduling of IoT-enabled smart homes for energy management based on Arithmetic Optimization Algorithm: A Node-RED and NodeMCU module-based technique", *Knowledge-Based Systems*, 247.
- Huang, Z., Jin, G. (2024) "Navigating urban day-ahead energy management considering climate change toward using IoT enabled machine learning technique: Toward future sustainable urban", *Sustainable Cities and Society*, 101.
- Kim, H.J., Kim, M.K. (2024) "New Customized Bidirectional Real-Time Pricing Mechanism for Demand Response in Predictive Home Energy Management System", *IEEE Internet of Things Journal*, 11, 24497–24510.
- Hamouda, Y.E.M., Dwedar, S.J.I. (2020) "Optimally Automated Home Management for Smart Grid System Using Sensor Networks: Gaza Strip as a Case Study", *Technology and Economics of Smart Grids and Sustainable Energy (Springer)*, 5.
- Vinjamuri, U.R., Burthi, L.R. (2022) "Power Quality Enhancement of Smart Home Energy Management System in Smart Grid Using MAORDF-CapSA Technique", *Ecological Engineering & Environmental Technology*, 23, 1–19.
- Rehman, U.U. (2025) "Proximal Policy Optimization–Driven Real-Time Home Energy Management System with Storage and Renewables", *Process Integration and Optimization for Sustainability*, 9, 507–536.
- Nakıp, M., Çopur, O., Biyik, E. et al. (2023) "Renewable energy management in smart home environment via forecast embedded scheduling based on Recurrent Trend Predictive Neural Network", *Applied Energy (Elsevier)*, 340.
- Karuna, G., Poornima, E., S, A. et al. (2024) "Smart energy management: real-time prediction and optimization for IoT-enabled smart homes", *Cogent Engineering*, 11.
- Ramachandra, N., Rajasekar, N. (2024) "State-of-the-art and real-time implementation of an IoT-based home energy management system for a cluster of dwellings", *Heliyon (Elsevier)*, 10.
- Lin, Y. (2021) "Trainingless multi-objective evolutionary computing-based nonintrusive load monitoring: Part of smart-home energy management for demand-side management", *Journal of Building Engineering*, 33.