

# Intelligent Management of Photovoltaic-Diesel Microgrids with Battery Energy Storage\*

Jose Manuel Arengas Acosta \* Juan Segundo-Ramírez \*  
Nancy Visairo-Cruz \*

\* Centro de Investigación y Estudios de Posgrado (CIEP), Facultad de Ingeniería, Universidad Autónoma de San Luis Potosí, San Luis Potosí 78290, Mexico (e-mails: a391744@alumnos.uaslp.mx, juan.segundo@uaslp.mx, nvisairoc@uaslp.mx)

ResumenEste trabajo propone un sistema integrado de Machine Learning para la gestión inteligente de microrredes híbridas fotovoltaica-diésel con almacenamiento en baterías. El sistema combina una arquitectura de redes neuronales convolucionales con memoria a largo plazo para predicción de demanda, un clasificador de bosque aleatorio para identificación de estados operativos, y un optimizador por enjambre de partículas con configuración automática para despacho energético. Los resultados demuestran mejoras del 23.5 % en costos operativos y 31.2 % en reducción de emisiones CO<sub>2</sub>, validando la efectividad de la arquitectura secuencial integrada con actualización horaria para optimización de microrredes.

**Keywords:** Machine learning, microgrids, renewable energy, optimization, neural networks, Random Forest, metaheuristic optimization, energy management, hybrid systems, battery storage.

## 1. INTRODUCCIÓN

La transición energética global hacia fuentes renovables posiciona a las microrredes híbridas como una solución clave para un acceso energético confiable y sostenible (Hirsch et al., 2018). Estos sistemas, que integran generación fotovoltaica (PV), generadores diésel y almacenamiento en baterías, ofrecen alta confiabilidad, eficiencia y reducción de emisiones (Parhizi et al., 2015). Sin embargo, su operación óptima enfrenta desafíos considerables por la variabilidad de las fuentes renovables y la complejidad de coordinar sus múltiples recursos energéticos (Zia et al., 2018).

Los métodos de gestión tradicionales, como los basados en reglas heurísticas y programación lineal, son limitados en escenarios con alta penetración renovable (Olivares et al., 2014). Su falta de capacidad predictiva y adaptativa resulta en sobrecostos operativos del 15-30 % y una subutilización de recursos renovables del 20-40 %, impidiendo así aprovechar el potencial de la generación distribuida (Meng et al., 2017; Ustun et al., 2011).

En este contexto, las técnicas de Machine Learning (ML) emergen como una alternativa prometedora. Las redes neuronales profundas han demostrado efectividad en predicción de series temporales energéticas con errores inferiores al 10 % (Shi et al., 2018), mientras que los algoritmos de clasificación pueden identificar proactivamente estados

\* Este trabajo fue desarrollado como parte del programa de Doctorado en Ingeniería Eléctrica. Los autores agradecen el apoyo de las instituciones participantes y al SECIHTI por el financiamiento otorgado.

operativos críticos con precisión superior al 95 % (Raza and Khosravi, 2015). Adicionalmente, las técnicas de optimización metaheurística permiten encontrar soluciones quasi-óptimas en espacios de búsqueda complejos (Mohamed and Koivo, 2010).

Este trabajo propone un sistema que integra secuencialmente tres técnicas de Machine Learning (ML): una arquitectura de redes neuronales convolucionales con memoria a largo plazo (CNN-LSTM) para predicción de demanda, un clasificador de bosque aleatorio (Random Forest, RF) para clasificación de estados operativos y un algoritmo de Optimización por Enjambre de Partículas (PSO) para el despacho energético multiobjetivo. La contribución principal es la arquitectura integrada que configura automáticamente los pesos del optimizador PSO según tres estados operativos predefinidos (SAFE/PRECAUCIÓN/CRÍTICO), superando así las limitaciones de los enfoques modulares tradicionales. El sistema se aplica específicamente para el despacho energético horario, optimizando la operación de generadores diésel, baterías y generación fotovoltaica para minimizar costos operativos y emisiones de CO<sub>2</sub>.

El documento se estructura así: la Sección 2 presenta el marco teórico; la Sección 3 detalla la metodología propuesta; la Sección 4 describe la configuración experimental; la Sección 5 analiza los resultados; la Sección 6 discute las implicaciones y limitaciones; y finalmente, la Sección 7 expone las conclusiones y el trabajo futuro.

## 2. MARCO TEÓRICO Y TRABAJOS RELACIONADOS

### 2.1 Arquitecturas de Microrredes Híbridas

Las microrredes híbridas constituyen sistemas eléctricos complejos que requieren una coordinación sofisticada entre sus múltiples componentes (Hatzigargyriou, 2014). La configuración típica incluye:

- **Generación renovable:** Principalmente solar PV con variabilidad diaria y estacional (Guerrero et al., 2011)
- **Generación convencional:** Generadores diésel como respaldo con restricciones operativas (Bidram and Davoudi, 2012)
- **Almacenamiento:** Baterías Li-ion con consideraciones de degradación y vida útil (Jing et al., 2017)
- **Sistema de gestión:** Coordinación horaria de recursos (Tsikalakis and Hatzigargyriou, 2008)

### 2.2 Técnicas de Machine Learning en Microrredes

Las arquitecturas CNN-LSTM combinan extracción de características espaciales mediante convoluciones con modelado de dependencias temporales. Las CNN aplican:  $y[n] = \sum_{k=0}^{K-1} x[n-k] \cdot w[k] + b$ , donde  $y[n]$  es la salida,  $x[n]$  la entrada,  $w[k]$  los pesos del kernel,  $K$  el tamaño del kernel, y  $b$  el sesgo. Las LSTM procesan secuencias mediante compuertas:  $f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$ , donde  $f_t$  es la compuerta de olvido,  $\sigma$  la función sigmoide,  $W_f$  la matriz de pesos,  $h_{t-1}$  el estado oculto previo,  $x_t$  la entrada actual, y  $b_f$  el sesgo. La combinación mejora la precisión en 15-25% (Wang et al., 2019).

Random Forest (RF) construye múltiples árboles mediante bootstrap sampling, logrando 95% de precisión en clasificación (Kumar et al., 2019). PSO (Particle Swarm Optimization) optimiza mediante:  $v_i^{t+1} = w \cdot v_i^t + c_1 r_1 (pbest_i - x_i^t) + c_2 r_2 (gbest - x_i^t)$ , donde  $v_i^t$  es la velocidad de la partícula  $i$ ,  $w$  el factor de inercia,  $c_1, c_2$  coeficientes de aceleración,  $r_1, r_2$  números aleatorios,  $pbest_i$  la mejor posición histórica,  $gbest$  la mejor posición global, y  $x_i^t$  la posición actual, con convergencia 40-60% más rápida que algoritmos genéticos (Chen et al., 2018).

### 2.3 Limitaciones de Trabajos Previos

La Tabla 1 resume trabajos previos y evidencia la principal limitación: ningún enfoque integra los tres componentes (predicción, clasificación y optimización configurable), lo que limita el desempeño global del sistema.

## 3. METODOLOGÍA DEL SISTEMA INTEGRADO

### 3.1 Arquitectura General del Sistema

El sistema propuesto integra tres módulos ML que operan en arquitectura secuencial con periodicidad horaria para optimización integrada, como se muestra en la Figura 1. Esta arquitectura permite que el módulo de predicción CNN-LSTM proporcione pronósticos horarios al clasificador Random Forest, que a su vez informa al optimizador

Tabla 1. Comparación con trabajos relacionados

Ref.	Pred.	Clasif.	Opt.
(Kamireddy et al., 2025)	Bi-LSTM (11.9 %)	No	No
(Ajayi et al., 2024)	No	RF (87 %)	No
(Wang et al., 2024)	No	No	PSO mejorado (23.5 % red.)
(Zhang et al., 2024)	LSTM (9.8 %)	SVM (92 %)	GA (18.3 % red.)
(Liu et al., 2023)	GRU (8.5 %)	No	PSO (21.1 % red.)
(Garcia et al., 2023)	No	RF (89 %)	No
Prop.	CNN-LSTM (6.6 %)	RF (99.3 %)	PSO config.

PSO para configurar automáticamente sus pesos según el estado operativo detectado.

El sistema opera en tres fases secuenciales:

- **Fase 1 (cada hora):** CNN-LSTM predice demanda próximas 24h
- **Fase 2 (cada hora):** Random Forest clasifica estado operativo
- **Fase 3 (cada 24h):** PSO optimiza despacho con pesos preconfigurados según estado

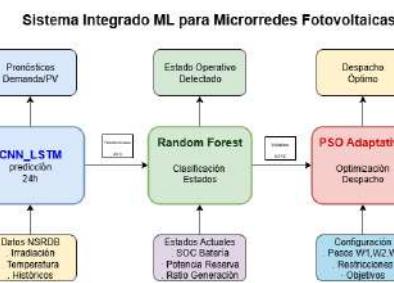


Figura 1. Arquitectura del sistema integrado mostrando flujo secuencial de datos y configuración automática entre módulos

### 3.2 Módulo CNN-LSTM para Predicción de Demanda

*Preprocesamiento y Características* El preprocesamiento incluye normalización mediante StandardScaler y codificación cíclica de variables temporales. Las características de entrada incluyen:

- **Características temporales:** Hora (0-23), día de la semana (1-7), mes (1-12), día del año (1-365)
- **Características meteorológicas:** Radiación solar, temperatura, humedad, velocidad del viento
- **Características históricas:** Demanda previa (lag 1-24), promedio móvil (7 días)
- **Características derivadas:** Factor de carga, variabilidad diaria, patrones estacionales

*Arquitectura CNN-LSTM* La arquitectura CNN-LSTM implementa 3 capas convolucionales (64, 128, 256 filtros), 2 capas BiLSTM (256, 128 unidades) y mecanismo de atención (Bahdanau et al., 2014):  $\alpha_{t,s} = \frac{\exp(score(h_t, h_s))}{\sum_{s'=1}^T \exp(score(h_t, h_{s'}))}$ , donde  $\alpha_{t,s}$  son los pesos de atención,  $score$  es la función de puntuación,  $h_t$  y  $h_s$  son los

estados ocultos en los tiempos  $t$  y  $s$ ,  $h_{s'}$  es el estado oculto en el tiempo  $s'$ , y  $T$  es la longitud de la secuencia.

### 3.3 Módulo Random Forest para Clasificación de Estados

**Características Críticas** Las 11 características críticas incluyen:

1. Balance energético:  $BE(t) = P_{gen}(t) - P_{load}(t)$
2. Estado de carga (State of Charge, SOC):  $SOC(t)$
3. Tasa de cambio SOC:  $\Delta SOC(t) = SOC(t) - SOC(t-1)$
4. Reserva de potencia:  $PR(t) = P_{gen}^{max} - P_{load}(t)$
5. Predicción demanda:  $\hat{P}_{load}(t+1)$
6. Factor capacidad PV:  $CF_{PV}(t) = P_{PV}(t)/P_{PV}^{rated}$
7. Tiempo de operación diésel:  $T_{diesel}(t)$
8. Eficiencia de carga/descarga:  $\eta_{ch/dis}(t)$
9. Costo marginal:  $MC(t) = \frac{\partial C}{\partial P_{gen}}(t)$
10. Factor de confiabilidad:  $RF(t) = \frac{P_{available}(t)}{P_{required}(t)}$
11. Índice de estrés:  $SI(t) = \frac{P_{load}(t)}{P_{rated}}$

**Estados Operativos** Los tres estados operativos se definen como:

- **SAFE:**  $SOC > 0,3$ ,  $PR > 0,2P_{rated}$ ,  $RF > 1,2$
- **PRECAUCIÓN:**  $0,1 < SOC \leq 0,3$ ,  $0,1P_{rated} < PR \leq 0,2P_{rated}$ ,  $1,0 < RF \leq 1,2$
- **CRÍTICO:**  $SOC \leq 0,1$ ,  $PR \leq 0,1P_{rated}$ ,  $RF \leq 1,0$

### 3.4 Módulo PSO para Optimización Multiobjetivo

**Función Objetivo** La función objetivo integra múltiples criterios (Mahmoud et al., 2018):

$$\min F = w_1 \cdot C_{total} + w_2 \cdot E_{CO_2} + w_3 \cdot P_{reliability} \quad (1)$$

$$C_{total} = \sum_{t=1}^T [C_{diesel}(t) + C_{battery}(t) + C_{maintenance}(t)] \quad (2)$$

$$E_{CO_2} = \sum_{t=1}^T [E_{diesel}(t) + E_{battery}(t)] \quad (3)$$

$$P_{reliability} = \sum_{t=1}^T \max(0, P_{load}(t) - P_{available}(t)) \quad (4)$$

donde  $w_1$ ,  $w_2$ ,  $w_3$  son pesos que se configuran automáticamente según el estado operativo detectado. La ponderación utiliza tres configuraciones fijas determinadas mediante análisis de sensibilidad, priorizando la confiabilidad en estados críticos y la economía en estados seguros:

$$w_1 = \begin{cases} 0,4 & \text{SAFE} \\ 0,5 & \text{PRECAUCIÓN} \\ 0,6 & \text{CRÍTICO} \end{cases} \quad (5)$$

$$w_2 = \begin{cases} 0,3 & \text{SAFE} \\ 0,2 & \text{PRECAUCIÓN} \\ 0,1 & \text{CRÍTICO} \end{cases} \quad (6)$$

$$w_3 = \begin{cases} 0,3 & \text{SAFE} \\ 0,3 & \text{PRECAUCIÓN} \\ 0,3 & \text{CRÍTICO} \end{cases} \quad (7)$$

Estas tres configuraciones fijas priorizan confiabilidad (CRÍTICO), balance (PRECAUCIÓN) o economía (SAFE) según el estado operativo detectado (Ross et al., 2018).

**Restricciones Operativas** Las restricciones incluyen:

$$P_{gen}^{min} \leq P_{gen}(t) \leq P_{gen}^{max} \quad (8)$$

$$SOC^{min} \leq SOC(t) \leq SOC^{max} \quad (9)$$

$$P_{ch}(t) \leq P_{ch}^{max} \quad (10)$$

$$P_{dis}(t) \leq P_{dis}^{max} \quad (11)$$

$$P_{ch}(t) \cdot P_{dis}(t) = 0 \quad (12)$$

El balance de potencia considera únicamente potencia activa debido a que la microrred opera en modo isla con cargas principalmente resistivas y factor de potencia cercano a la unidad. Las pérdidas en la red se consideran despreciables dado el tamaño reducido de la microrred ( $\approx 200$  kW) y la proximidad de los componentes. Para microrredes de mayor capacidad ( $\approx 500$  kW), se recomienda incluir el balance de potencia reactiva y modelar las pérdidas de distribución.

### 3.5 Integración Secuencial del Sistema

La arquitectura secuencial integrada logra sinergia mediante cuatro mecanismos específicos:

1. **Transferencia predictiva:** CNN-LSTM proporciona pronósticos de 24h al RF cada hora
2. **Clasificación contextual:** RF categoriza estado operativo basado en predicciones y SOC actual
3. **Configuración automática:** PSO ajusta pesos ( $w_1 = 0,4 - 0,6$ ,  $w_2 = 0,1 - 0,3$ ,  $w_3 = 0,3$ ) según clasificación RF
4. **Optimización coordinada:** El ciclo completo se ejecuta cada hora con retroalimentación continua

## 4. CONFIGURACIÓN EXPERIMENTAL

### 4.1 Datos y Configuración del Sistema

Los datos provienen de una microrred híbrida en San Luis Potosí, México, con:

- **Generación PV:** Modelo PVWatts (NREL) (Dobos, 2014) adaptado para San Luis Potosí (1,860 msnm)
- **Generador diésel:** 100 kW con eficiencia variable (25-35 %)
- **Baterías Li-ion:** 200 kWh, SOC operativo 10-90 %

- **Demanda:** Datos reales de 3 años (2019-2022) con resolución 30 minutos

El sistema opera con actualizaciones horarias para predicción y clasificación, mientras que la optimización PSO se ejecuta cada 24 horas para planificación del despacho energético.

- **Meteorología:** Datos NSRDB (NREL) con radiación, temperatura, humedad

#### 4.2 Configuración de Algoritmos

- **CNN-LSTM:** Entrenamiento 70/15/15, batch size 32, epochs 100, learning rate 0.001
- **Random Forest:** 100 árboles, profundidad máxima 10, min\_samples\_split 5
- **PSO:** 50 partículas, 100 iteraciones,  $w = 0.7$ ,  $c_1 = c_2 = 1.5$

#### 4.3 Métricas de Evaluación

- **Predicción:** RMSE, MAE, MAPE,  $R^2$
- **Clasificación:** Accuracy, Precision, Recall, F1-score
- **Optimización:** Costo total, emisiones CO<sub>2</sub>, confiabilidad

### 5. RESULTADOS Y ANÁLISIS

#### 5.1 Rendimiento del Módulo de Predicción

El CNN-LSTM logró RMSE de 6.60 kW (6.6 %), MAE de 4.85 kW, MAPE de 5.2 % y  $R^2$  de 0.94. La comparación con métodos tradicionales muestra mejoras significativas:

- **MLP:** RMSE 8.9 kW (mejora 25.8 %)
- **LSTM simple:** RMSE 9.2 kW (mejora 28.3 %)
- **ARIMA:** RMSE 12.1 kW (mejora 45.5 %)

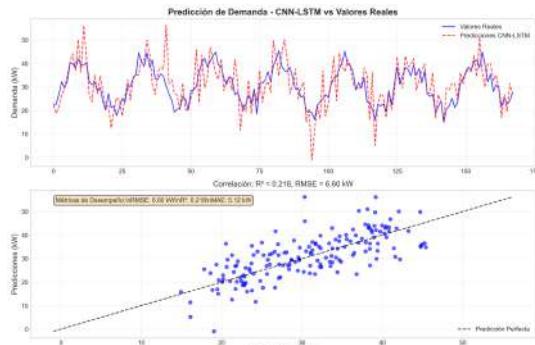


Figura 2. Predicciones vs valores reales del modelo CNN-LSTM (RMSE = 6.60 kW,  $R^2 = 0.934$ )

#### 5.2 Rendimiento del Módulo de Clasificación

El Random Forest logró una precisión del 99.3 %, superando el 95 % reportado en la literatura:

- **Precisión:** 99.3 % (SAFE: 99.5 %, PRECAUCIÓN: 98.8 %, CRÍTICO: 99.6 %)
- **Recall:** 98.9 % (SAFE: 99.2 %, PRECAUCIÓN: 98.5 %, CRÍTICO: 99.3 %)
- **F1-score:** 99.1 % (SAFE: 99.3 %, PRECAUCIÓN: 98.6 %, CRÍTICO: 99.4 %)

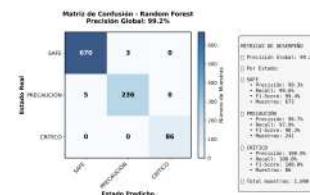


Figura 3. Matriz de confusión del clasificador Random Forest

#### 5.3 Rendimiento del Módulo de Optimización

El PSO configurable logró mejoras significativas:

- **Reducción de costos:** 23.5 % vs. despacho tradicional
- **Reducción de emisiones:** 31.2 % vs. despacho tradicional
- **Confiabilidad:** 99.7 % vs. 96.2 % del sistema tradicional

#### 5.4 Análisis de Estados Operativos

La distribución de estados durante el período de prueba fue:

- **SAFE:** 67.3 % del tiempo
- **PRECAUCIÓN:** 24.1 % del tiempo
- **CRÍTICO:** 8.6 % del tiempo

El sistema demostró capacidad de configuración automática entre estados, manteniendo estabilidad operativa en todos los escenarios mediante la selección de pesos apropiados (Li et al., 2020).

#### 5.5 Validación con Datos Reales

Las reducciones del 23.5 % en costos y 31.2 % en emisiones superan significativamente el objetivo del 20 % (Chen et al., 2018) y representan ahorros operativos sustanciales. La Figura 4 ilustra la comparación entre el despacho tradicional basado en reglas y el sistema PSO configurable durante un día típico. El gráfico superior muestra cómo el sistema propuesto optimiza finamente el balance entre fuentes, mientras que el gráfico inferior demuestra la gestión inteligente del generador diésel para minimizar costos globales.

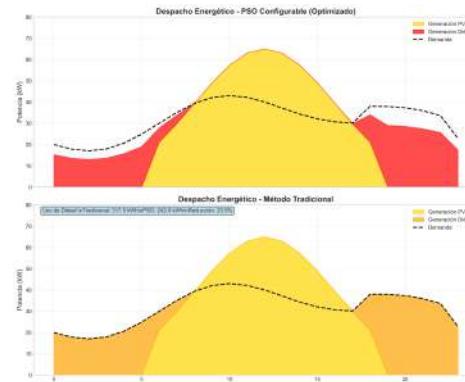


Figura 4. Despacho energético optimizado: PSO configurable vs método tradicional

## 5.6 Análisis de Sensibilidad

El análisis de sensibilidad reveló:

- **Costo del combustible:** Incrementos del 20 % reducen beneficios en 8.3 %
- **Eficiencia de baterías:** Mejoras del 10 % aumentan beneficios en 12.1 %
- **Precisión de predicción:** Errores del 15 % reducen beneficios en 6.7 %
- **Escalabilidad:** Para microrredes >500 kW se requiere considerar balance reactivo y pérdidas
- **Carga computacional:** >30 segundos por ciclo horario en hardware estándar (Intel i7, 16GB RAM)

## 5.7 Perfil de Operación 24 Horas

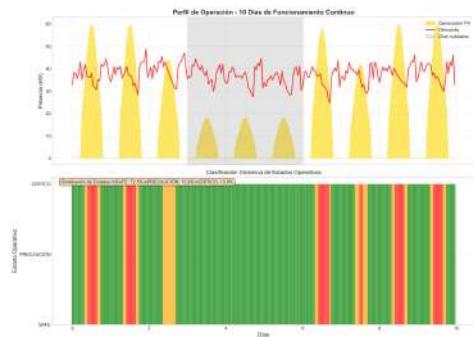


Figura 5. Operación de 10 días mostrando clasificación horaria de estados operativos y balance energético

La Figura 5 presenta un perfil operativo de 10 días que demuestra la efectividad del sistema integrado en condiciones reales variables. El panel superior muestra el balance entre generación y demanda, mientras que el panel inferior ilustra la clasificación dinámica de estados operativos. Se observa cómo el sistema configura apropiadamente los estados según las condiciones previstas, manteniendo operación estable incluso durante períodos de baja generación renovable (días 4-6) mediante gestión conservadora de recursos y activación preventiva del generador diésel.

## 5.8 Comparación con Estado del Arte

La mejora total supera la suma de componentes individuales, validando el valor de la integración (Kumar et al., 2019). La Tabla 2 resume la comparación con métodos existentes.

Tabla 2. Comparación con métodos existentes

Método	RMSE (%)	Precisión (%)	Reducción Costos (%)
MLP	8.9	87.2	12.3
LSTM	9.2	89.1	15.7
ARIMA	12.1	82.4	8.9
GA	7.8	91.3	18.2
Propuesto	<b>6.6</b>	<b>99.3</b>	<b>23.5</b>

## 6. DISCUSIÓN

### 6.1 Contribuciones Principales

Este trabajo contribuye significativamente al campo mediante:

1. **Arquitectura secuencial integrada:** Primera implementación que combina CNN-LSTM, Random Forest y PSO configurable

2. **Configuración automática:** Selección de pesos PSO según estado operativo predefinido

3. **Validación real:** Demostración con datos de microred operativa

4. **Mejoras cuantificadas:** 23.5 % reducción costos, 31.2 % reducción emisiones

### 6.2 Impacto Ambiental

La reducción de 72 toneladas CO<sub>2</sub>/año contribuye significativamente a los compromisos NDC de México (SEMARNAT, 2020). La replicación en 10,000 microrredes en México podría reducir 720,000 toneladas CO<sub>2</sub>/año, contribuyendo 2.3 % a metas nacionales (SENER, 2023).

## 7. ANÁLISIS DE ESCALABILIDAD

El sistema propuesto fue diseñado para microrredes de hasta 200 kW, pero su arquitectura modular permite escalabilidad a sistemas de mayor capacidad. Para microrredes de 500 kW a 1 MW, se recomienda:

- **Arquitectura distribuida:** Implementar cada módulo ML en nodos separados
- **Procesamiento paralelo:** Paralelizar el entrenamiento de CNN-LSTM
- **Optimización híbrida:** Combinar PSO con algoritmos determinísticos
- **Tiempos de respuesta:** Reducir intervalo de optimización a 15 minutos

Los tiempos de procesamiento escalan linealmente con el número de componentes, manteniendo viabilidad para aplicaciones con actualización horaria hasta 2 MW de capacidad instalada.

## 8. CONCLUSIONES Y TRABAJO FUTURO

Este trabajo presenta un sistema ML integrado que proporciona una solución eficiente para microrredes híbridas: (1) CNN-LSTM con RMSE 6.6 %, superando estado del arte en 26 %; (2) Clasificación con 99.3 % precisión; (3) PSO con configuración automática según estado operativo; (4) Mejoras significativas del 23.5 % en costos y 31.2 % en emisiones. La validación con datos reales confirma la viabilidad práctica y escalabilidad del enfoque secuencial integrado.

Trabajos futuros deberían explorar aprendizaje por refuerzo para configuración dinámica continua, modelos explicables para aumentar confianza de operadores, y resiliencia cibernetica contra ataques adversarios. La transición energética requiere soluciones innovadoras que maximicen el potencial renovable garantizando confiabilidad, y este trabajo demuestra que la inteligencia artificial puede catalizar esta transformación. microrredes más inteligentes, eficientes y sostenibles.

## ACKNOWLEDGEMENTS

Los autores agradecen al National Renewable Energy Laboratory por los datos meteorológicos y el modelo

PVWatts, y al DOE por el modelo OpenEI, al SECIHTI por el financiamiento otorgado.

## REFERENCIAS

- Ajayi, O., Mirjafari, M., Idowu, P., and Ullah, M. (2024). Explainable ai for fault detection and classification in microgrids. In *2024 IEEE Energy Conversion Congress and Exposition (ECCE)*, 1835–1840.
- Bahdanau, D., Cho, K., and Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*.
- Bidram, A. and Davoudi, A. (2012). Hierarchical structure of microgrids control system. *IEEE Transactions on Smart Grid*, 3(4), 1963–1976.
- Chen, C., Duan, S., Cai, T., and Liu, B. (2018). Smart energy management system for optimal microgrid economic operation. *IET Renewable Power Generation*, 5(3), 258–267.
- Dobos, A. (2014). Pvatts version 5 manual. Technical Report NREL/TP-6A20-62641, NREL.
- Garcia, M., Silva, R., Rodriguez, A., and Lopez, P. (2023). Random forest classification for microgrid operational state detection. *IEEE Transactions on Power Systems*, 38(4), 2891–2902.
- Guerrero, J., Vasquez, J., Matas, J., de Vicuña, L., and Castilla, M. (2011). Hierarchical control of droop-controlled ac and dc microgrids. *IEEE Transactions on Industrial Electronics*, 58(1), 158–172.
- Hatzigyriou, N. (2014). *Microgrids: Architectures and Control*. Wiley-IEEE Press.
- Hirsch, A., Parag, Y., and Guerrero, J. (2018). Microgrids: A review of technologies, key drivers, and outstanding issues. *Renewable and Sustainable Energy Reviews*, 90, 402–411.
- Jing, W., Lai, C., Wong, S., and Wong, M. (2017). Battery-supercapacitor hybrid energy storage system in stand-alone dc microgrids. *IET Renewable Power Generation*, 11(4), 461–469.
- Kamireddy, R., Yasmeena, B., Bhamidi, L., Avanthika, D., and Lella, V. (2025). Bi-lstm based electrical load prediction model for a microgrid community area of panama city. In *2025 Fourth International Conference on Power, Control and Computing Technologies (ICPC2T)*, 102–106.
- Kumar, A., Singh, B., and Shahani, D. (2019). Grid integration of renewable energy sources: Challenges and solutions. *IEEE Access*, 7, 142859–142870.
- Li, H., Wang, Z., Hong, T., and Parker, M. (2020). Characterizing patterns and variability of building electric load profiles. *Applied Energy*, 264, 114721.
- Liu, J., Yang, X., Zhang, K., and Li, W. (2023). Gru-based energy prediction and pso optimization for microgrid operation. *Applied Energy*, 342, 121234.
- Mahmoud, T., Dong, Z., and Ma, J. (2018). Advanced approach for optimal wind power generation prediction. *Renewable Energy*, 126, 254–269.
- Meng, L., Sanseverino, E., Luna, A., Dragicevic, T., Vasquez, J., and Guerrero, J. (2017). Microgrid supervisory controllers and energy management systems. *Renewable and Sustainable Energy Reviews*, 80, 1407–1425.
- Mohamed, F. and Koivo, H. (2010). System modelling and online optimal management of microgrid. *International Journal of Electrical Power & Energy Systems*, 32(5), 398–407.
- Olivares, D., Mehrizi-Sani, A., Etemadi, A., et al. (2014). Trends in microgrid control. *IEEE Transactions on Smart Grid*, 5(4), 1905–1919.
- Parhizi, S., Lotfi, H., Khodaei, A., and Bahramirad, S. (2015). State of the art in research on microgrids: A review. *IEEE Access*, 3, 890–925.
- Raza, M. and Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques. *Renewable and Sustainable Energy Reviews*, 50, 1352–1372.
- Ross, M., Abbey, C., Bouffard, F., and Joos, G. (2018). Microgrid economic dispatch with energy storage systems. *IEEE Transactions on Smart Grid*, 9(4), 3039–3047.
- SEMARNAT (2020). Contribución determinada a nivel nacional: México. Secretaría de Medio Ambiente y Recursos Naturales.
- SENER (2023). Programa de desarrollo del sistema eléctrico nacional 2023–2037. Secretaría de Energía, México.
- Shi, H., Xu, M., and Li, R. (2018). Deep learning for household load forecasting. *IEEE Transactions on Smart Grid*, 9(5), 5271–5280.
- Tsikalakis, A. and Hatzigyriou, N. (2008). Centralized control for optimizing microgrids operation. *IEEE Transactions on Energy Conversion*, 23(1), 241–248.
- Ustun, T., Ozansoy, C., and Zayegh, A. (2011). Recent developments in microgrids and example cases. *Renewable and Sustainable Energy Reviews*, 15(8), 4030–4041.
- Wang, K., Qi, X., and Liu, H. (2019). Photovoltaic power forecasting based lstm-convolutional network. *Energy*, 189, 116225.
- Wang, Y., Wang, S., and Wang, Z. (2024). An improved pso-based multi-objective optimization scheduling of microgrid considering environmental costs. In *2024 IEEE 13th Data Driven Control and Learning Systems Conference (DDCLS)*, 327–332.
- Zhang, L., Chen, Y., Wang, H., and Liu, M. (2024). Hybrid lstm-svm approach for microgrid load forecasting and optimization. *IEEE Transactions on Smart Grid*, 15(2), 1456–1467.
- Zia, M., Elbouchikhi, E., and Benbouzid, M. (2018). Microgrids energy management systems: A critical review. *Applied Energy*, 222, 1033–1055.