Evaluación del Desempeño de una Estrategia de Control de Tensión Basada en *Deep Reinforcement Learning* en una Red de Distribución de Media Tensión con Recursos Energéticos Distribuidos

Apéndices

Alan Ferney Lizarazo Maldonado

Trabajo de Grado para Optar el Título de Magíster en Ingeniería Eléctrica

Director
German Alfonso Osma Pinto
Doctor en Ingeniería Eléctrica

Codirector
César Antonio Duarte Gualdrón
Doctor en Ingeniería Eléctrica

Universidad Industrial de Santander
Facultad de Ingenierías Fisicomecánicas
Escuela de Ingenierías Eléctrica, Electrónica y de Telecomunicaciones
Maestría en Ingeniería Eléctrica
Bucaramanga
2026

Tabla de Contenido

Pág.

Apéndice A. Corpus Bibliográfico Retenido en la Revisión 3

Listado del Corpus 3

Apéndice B. Repositorio Técnico Entregado: Guía de Uso y Trazabilidad Computacional 19

B.1. Propósito del Apéndice 19

B.2. Ruta Rápida de Lectura 20

B.3. Mapa General del Flujo Computacional 20

B.4. Estructura del Repositorio 21

B.5. Componentes Principales 22

B.6. Entorno Computacional e Instalación 22

B.7. Datos, Pares de Evaluación y Configuraciones 23

B.8. Flujo de Trabajo Recomendado 25
B.8.1. Preparar Entorno 26
B.8.2. Verificar Datos y Configuraciones 26
B.8.3. Generar Pares Carga–Irradiancia 26
B.8.4. Entrenar MASAC 27
B.8.5. Evaluar MASAC 28
B.8.6. Evaluar OPF-QS y DROOP 28
B.8.7. Generar Comparaciones y Figuras 29

B.9. Control de Atención, Pronóstico y Regularización 29

B.10. Evaluaciones BASE y Contingencias N-1 30

B.11. Evaluaciones por Nivel de Penetración Fotovoltaica 33

B.12. Visualización y Análisis de Salidas 34

B.13. Escenarios del Libro y Ruta Computacional Asociada 35

B.14. Generación de Salidas y Análisis 36

B.15. Verificación Mínima del Repositorio 37

B.16. Trazabilidad y Buenas Prácticas de Uso 38

Apéndice A

Corpus Bibliográfico Retenido en la Revisión

Este apéndice reproduce el listado de los 118 documentos retenidos en la búsqueda estructurada descrita en el Capítulo 3 del documento principal. Estos documentos constituyen el *corpus* base de la revisión del estado del arte. La inclusión de un documento en este listado no implica que haya sido citado explícitamente en el cuerpo del manuscrito: de este conjunto, 38 trabajos fueron usados de forma directa en la redacción. Las normas, los estándares y las referencias metodológicas o incorporadas posteriormente como apoyo complementario se administran por separado y no modifican el conteo del *corpus* base.

El listado presenta los metadatos bibliográficos completos de cada publicación: autores, año, título, revista científica o actas de congreso, volumen, número de fascículo, paginación o identificador de artículo, y enlace DOI activo cuando está disponible. Todos los documentos están indexados en Scopus. Las entradas se presentan según las normas APA (séptima edición), en orden alfabético por el apellido del primer autor y con sangría francesa de 1.27 cm.

Tabla A1
Resumen del corpus bibliográfico retenido en la revisión.

Indicador	Valor
Documentos retenidos (*corpus* base)	118
Trabajos usados de forma directa en la redacción	38
Base de indexación	Scopus

Nota. El *corpus* base comprende 118 documentos; 38 se utilizaron directamente en la redacción del manuscrito.

Listado del Corpus

Abdelhadi, H., Mahmoud, A. M., Saied, E. M. M., y Mohamed, M. A. E. (2024). Innovative hierarchical control of multiple microgrids: Cheetah meets PSO. *Energy Reports*, *11*, 4967–4981.

https://doi.org/10.1016/j.egyr.2024.04.055

Abdelkader, S. M., Kinga, S., Ebinyu, E., Amissah, J., Mugerwa, G., Taha, I. B. M., y Mansour, D.-E. A. (2024). Advancements in data-driven voltage control in active distribution networks: A comprehensive review. *Results in Engineering*, *23*, Artículo 102741. https://doi.org/10.1016/j.rineng.2024.102741

Ajitha Priyadarsini, S., y Rajeev, D. (2024). Optimizing distribution systems with renewable energy integration: Hybrid mud ring algorithm–quantum neural network approach. *Energy Technology*, *12*(9), Artículo 2301694. https://doi.org/10.1002/ente.202301694

Al-Ja'afreh, M. A. A., Amjad, B., Rowe, K., Mokryani, G., y Marquez, J. L. A. (2023). Optimal planning and forecasting of active distribution networks using a multi-stage deep learning based technique. *Energy Reports*, *10*, 686–705. https://doi.org/10.1016/j.egyr.2023.07.014

Allahmoradi, S., Afrasiabi, S., Liang, X., Zhao, J., y Shahidehpour, M. (2024). Data-driven Volt/VAr optimization for modern distribution networks: A review. *IEEE Access*, *12*, 71184–71204. https://doi.org/10.1109/ACCESS.2024.3403035

AlQattan, A. J., Albasri, F., y Al-Mosawi, S. A. (2024). Advanced controller design for D-FACTS device in grid-connected photovoltaic system controller. *International Journal of Advances in Applied Sciences*, *13*(3), 467–477. https://doi.org/10.11591/ijaas.v13.i3.pp467-477

Alrashidi, M. (2022). Community battery storage systems planning for voltage regulation in low voltage distribution systems. *Applied Sciences*, *12*(18), Artículo 9083. https://doi.org/10.3390/app12189083

Alyasiri, A. M. M., y Kurnaz, S. (2023). Passive islanding detection in microgrids using artificial neural networks. *Applied Nanoscience*, *13*(4), 2885–2900. https://doi.org/10.1007/s13204-021-02197-5

Anum, H., Hashmi, M. A., Shahid, M. U., Munir, H. M., Irfan, M., Veerendra, A. S., Kanan, M., y Flah, A. (2024). Backward neural network (BNN) based multilevel control for enhancing the quality of an islanded RES DC microgrid under variable communication network. *Heliyon*, *10*(12), Artículo e32646. https://doi.org/10.1016/j.heliyon.2024.e32646

Ayyagari, K. S., Gonzalez, R., Jin, Y., Alamaniotis, M., Ahmed, S., y Gatsis, N. (2023). Learning reactive power control polices in distribution networks using conditional value-at-risk and artificial neural networks. *Journal of Modern Power Systems and Clean Energy*, *11*(1), 201–211. https://doi.org/10.35833/MPCE.2022.000477

Azimi, R., y Esmaeili, S. (2013). Multiobjective daily Volt/VAr control in distribution systems with distributed generation using binary ant colony optimization. *Turkish Journal of Electrical Engineering and Computer Sciences*, *21*(3), 613–629. https://doi.org/10.3906/elk-1110-16

Baniyounis, M., Salah, S. Z., y Ghaeb, J. A. (2023). Machine learning for prediction models to mitigate the voltage deviation in photovoltaic-rich distributed network. *International Journal of Electrical and Computer Engineering (IJECE)*, *13*(1), 55–68. https://doi.org/10.11591/ijece.v13i1.pp55-68

Beyer, K., Beckmann, R., Geißendörfer, S., von Maydell, K., y Agert, C. (2021). Adaptive online-learning Volt-VAr control for smart inverters using deep reinforcement learning. *Energies*, *14*(7), Artículo 1991. https://doi.org/10.3390/en14071991

Bilal, M., Rizwan, M., Alsaidan, I., y Almasoudi, F. M. (2021). AI-based approach for optimal placement of EVCS and DG with reliability analysis. *IEEE Access*, *9*, 154204–154224. https://doi.org/10.1109/ACCESS.2021.3125135

Boghdady, T. A., y Mohamed, Y. A. (2023). Reactive power compensation using STATCOM in a PV grid connected system with a modified MPPT method. *Ain Shams Engineering Journal*, *14*(8), Artículo 102060. https://doi.org/10.1016/j.asej.2022.102060

Bokker, O., Schlachter, H., Beutel, V., Geißendörfer, S., y von Maydell, K. (2023). Reactive power control of a converter in a hardware-based environment using deep reinforcement learning. *Energies*, *16*(1), Artículo 78. https://doi.org/10.3390/en16010078

Calderaro, V., Conio, G., Galdi, V., Massa, G., y Piccolo, A. (2014). Active management of renewable energy sources for maximizing power production. *International Journal of Electrical Power & Energy Systems*, *57*, 64–72. https://doi.org/10.1016/j.ijepes.2013.11.040

Calero, F., Canizares, C. A., y Bhattacharya, K. (2021). Aggregated BESS dynamic models for

active distribution network studies. *IEEE Transactions on Smart Grid*, *12*(3), 2077–2088. https://doi.org/10.1109/TSG.2020.3048648

Cao, D., Hu, J., Liu, Y., y Hu, W. (2024). Decentralized graphical-representation-enabled multi-agent deep reinforcement learning for robust control of cyber-physical systems. *IEEE Transactions on Reliability*, *73*(4), 1710–1720. https://doi.org/10.1109/TR.2024.3354938

Cao, D., Zhao, J., Hu, W., Ding, F., Yu, N., Huang, Q., y Chen, Z. (2022). Model-free voltage control of active distribution system with PVs using surrogate model-based deep reinforcement learning. *Applied Energy*, *306*, Artículo 117982. https://doi.org/10.1016/j.apenergy.2021.117982

Cao, D., Zhao, J., Hu, W., Yu, N., Ding, F., Huang, Q., y Chen, Z. (2022). Deep reinforcement learning enabled physical-model-free two-timescale voltage control method for active distribution systems. *IEEE Transactions on Smart Grid*, *13*(1), 149–165. https://doi.org/10.1109/TSG.2021.3113085

Chandrashekhar Reddy, S., Prasad, P. V. N., y Jaya Laxmi, A. (2013). Reliability improvement of distribution system by optimal placement of distributed generator using genetic algorithm and neural network. *Journal of Electrical Engineering*, *13*(1), 273–279.

Chen, P., Liu, S., Wang, X., y Kamwa, I. (2024). Physics-guided multi-agent adversarial reinforcement learning for robust active voltage control with peer-to-peer (P2P) energy trading. *IEEE Transactions on Power Systems*, *39*(6), 7089–7101. https://doi.org/10.1109/TPWRS.2024.3369591

Chung, S., y Zhang, Y. (2023). Artificial intelligence applications in electric distribution systems: Post-pandemic progress and prospect. *Applied Sciences*, *13*(12), Artículo 6937. https://doi.org/10.3390/app13126937

Ghaeb, J., Salah, S., y Obeidat, F. (2023). Intelligent control for voltage regulation in the distribution network equipped with PV farm. *Energies*, *16*(1), Artículo 360. https://doi.org/10.3390/en16010360

Glover, D., y Dubey, A. (2025). Learning Volt-VAr droop curves to optimally coordinate photo-

voltaic (PV) smart inverters. *IEEE Transactions on Industry Applications*, *61*(1), 859–871. https://doi.org/10.1109/TIA.2024.3472655

Gush, T., y Kim, C.-H. (2024). Robust local coordination control of PV smart inverters with SVC and OLTC in active distribution networks. *IEEE Transactions on Power Delivery*, *39*(3), 1610–1621. https://doi.org/10.1109/TPWRD.2024.3374059

Hamadouche, Z., Khiat, M., y Iqbal, M. A. (2021). Intelligent voltage regulator for distributed generation-based network. *Indonesian Journal of Electrical Engineering and Computer Science*, *23*(1), 98–109. https://doi.org/10.11591/ijeecs.v23.i1.pp98-109

Hu, D., Ye, Z., Gao, Y., Ye, Z., Peng, Y., y Yu, N. (2022). Multi-agent deep reinforcement learning for voltage control with coordinated active and reactive power optimization. *IEEE Transactions on Smart Grid*, *13*(6), 4873–4886. https://doi.org/10.1109/TSG.2022.3185975

Huang, B., y Wang, J. (2024). Adaptive static equivalences for active distribution networks with massive renewable energy integration: A distributed deep reinforcement learning approach. *IEEE Transactions on Network Science and Engineering*, *11*(6), 5463–5476. https://doi.org/10.1109/TNSE.2023.3272794

Huang, Q., Hu, W., Zhang, G., Cao, D., Liu, Z., Huang, Q., y Chen, Z. (2021). A novel deep reinforcement learning enabled agent for pumped storage hydro-wind-solar systems voltage control. *IET Renewable Power Generation*, *15*(16), 3941–3956. https://doi.org/10.1049/rpg2.12311

Huang, W., y Zhao, C. (2024). Deep-learning-aided voltage-stability-enhancing stochastic distribution network reconfiguration. *IEEE Transactions on Power Systems*, *39*(2), 2827–2836. https://doi.org/10.1109/TPWRS.2023.3286406

Hussain, I., Agarwal, R. K., y Singh, B. (2018). MLP control algorithm for adaptable dual-mode single-stage solar PV system tied to three-phase voltage-weak distribution grid. *IEEE Transactions on Industrial Informatics*, *14*(6), 2530–2538. https://doi.org/10.1109/TII.2018.2811485

Ibrahim, S., y Alwash, S. (2022). Optimal DG integration in power distribution systems using

coronavirus herd immunity optimizer. *International Journal of Intelligent Engineering and Systems*, *15*(6), 119–131. https://doi.org/10.22266/ijies2022.1231.13

Kabir, F., Yu, N., Gao, Y., y Wang, W. (2023). Deep reinforcement learning-based two-timescale Volt-VAr control with degradation-aware smart inverters in power distribution systems. *Applied Energy*, *335*, Artículo 120629. https://doi.org/10.1016/j.apenergy.2022.120629

Kalaiselvan, K., Saravanan, R., Adhavan, B., y Manikandan, G. S. (2024). Hybrid methodology-based energy management of microgrid with grid-isolated electric vehicle charging system in smart distribution network. *Electrical Engineering*, *106*(3), 2705–2720. https://doi.org/10.1007/s00202-023-02095-9

Kamali, R., Sharifi, R., Radmanesh, H., y Fathi, S. H. (2016). Online voltage estimation for distribution networks in presence of distributed generation. *Indian Journal of Science and Technology*, *9*(18), 1–5. https://doi.org/10.17485/ijst/2016/v9i18/71484

Kamarudin, M. N., y Tengku Hashim, T. J. (2019). Coordinated and optimal voltage control for voltage regulation using firefly algorithm. *Indonesian Journal of Electrical Engineering and Computer Science*, *16*(2), 568–576. https://doi.org/10.11591/ijeecs.v16.i2.pp568-576

Kandasamy, N., Badrinarayanan, R., Kanamarlapudi, V., Tseng, K., y Soong, B.-H. (2017). Performance analysis of machine-learning approaches for modeling the charging/discharging profiles of stationary battery systems with non-uniform cell aging. *Batteries*, *3*(2), Artículo 18. https://doi.org/10.3390/batteries3020018

Karimi, A., Aminifar, F., Fereidunian, A., y Lesani, H. (2019). Energy storage allocation in wind integrated distribution networks: An MILP-based approach. *Renewable Energy*, *134*, 1042–1055. https://doi.org/10.1016/j.renene.2018.11.034

Kayal, P., y Chanda, C. K. (2013). A simple and fast approach for allocation and size evaluation of distributed generation. *International Journal of Energy and Environmental Engineering*, *4*(1), Artículo 7. https://doi.org/10.1186/2251-6832-4-7

Kefayat, M., Lashkar Ara, A., y Nabavi Niaki, S. A. (2015). A hybrid of ant colony optimization and artificial bee colony algorithm for probabilistic optimal placement and sizing of distributed

energy resources. *Energy Conversion and Management*, *92*, 149–161. https://doi.org/10.1016/j.enconman.2014.12.037

Khan, B., Shafiq, S., y Al-Awami, A. T. (2023). Artificial-neural-network-based autonomous demand response controller for thermostatically controlled loads. *IEEE Systems Journal*, *17*(3), 5014–5022. https://doi.org/10.1109/JSYST.2023.3280927

Kim, B.-G., y Rho, D.-S. (2013). Optimal voltage regulation method for distribution systems with distributed generation systems using the artificial neural networks. *Journal of Electrical Engineering and Technology*, *8*(4), 712–718. https://doi.org/10.5370/JEET.2013.8.4.712

Kim, D., Yoon, K., Lee, S. H., y Park, J.-W. (2021). Optimal placement and sizing of an energy storage system using a power sensitivity analysis in a practical stand-alone microgrid. *Electronics*, *10*(13), Artículo 1598. https://doi.org/10.3390/electronics10131598

Kumar, A., y Choudhary, J. (2023). Power quality improvement of hybrid renewable energy systems-based microgrid for STATCOM: Hybrid-deep-learning model and mexican axoltl dingo optimizer (mado). *Engineering Research Express*, *5*(4), Artículo 045031. https://doi.org/10.1088/2631-8695/ad0287

Lee, S., y Choi, D.-H. (2023). Two-stage scheduling of smart electric vehicle charging stations and inverter-based Volt-VAr control using a prediction error-integrated deep reinforcement learning method. *Energy Reports*, *10*, 1135–1150. https://doi.org/10.1016/j.egyr.2023.07.054

Li, J., Zhang, R., Wang, H., Liu, Z., Lai, H., y Zhang, Y. (2024). Deep reinforcement learning for voltage control and renewable accommodation using spatial-temporal graph information. *IEEE Transactions on Sustainable Energy*, *15*(1), 249–262. https://doi.org/10.1109/TSTE.2023.3282187

Li, P., Wei, M., Ji, H., Xi, W., Yu, H., Wu, J., Yao, H., y Chen, J. (2022). Deep reinforcement learning-based adaptive voltage control of active distribution networks with multi-terminal soft open point. *International Journal of Electrical Power & Energy Systems*, *141*, Artículo 108138. https://doi.org/10.1016/j.ijepes.2022.108138

Li, S., Sun, Y., Ramezani, M., y Xiao, Y. (2018). Artificial neural networks for Volt/VAr control of DER inverters at the grid edge. *IEEE Transactions on Smart Grid*, *10*(5), 5564–5573. https://doi.org/10.1109/TSG.2018.2887080

Li, Y., Hao, G., Liu, Y., Yu, Y., Ni, Z., y Zhao, Y. (2022). Many-objective distribution network reconfiguration via deep reinforcement learning assisted optimization algorithm. *IEEE Transactions on Power Delivery*, *37*(3), 2230–2244. https://doi.org/10.1109/TPWRD.2021.3107534

Liu, D., Zeng, P., Cui, S., y Song, C. (2023). Deep reinforcement learning for charging scheduling of electric vehicles considering distribution network voltage stability. *Sensors*, *23*(3), Artículo 1618. https://doi.org/10.3390/s23031618

Loureiro, P. C., Variz, A. M., de Oliveira, L. W., Oliveira, Â. R., y Pereira, J. L. R. (2017). ANN-based SVC tuning for voltage and harmonics control in microgrids. *Journal of Control, Automation and Electrical Systems*, *28*(1), 114–122. https://doi.org/10.1007/s40313-016-0281-z

Madureira, A. G., y Peças Lopes, J. A. (2009). Coordinated voltage support in distribution networks with distributed generation and microgrids. *IET Renewable Power Generation*, *3*(4), 439–454. https://doi.org/10.1049/iet-rpg.2008.0064

Maharjan, S., Cheng, R., y Wang, Z. (2024). Generalized analytical estimation of sensitivity matrices in unbalanced distribution networks. *IEEE Transactions on Power Systems*, *39*(6), 6807–6818. https://doi.org/10.1109/TPWRS.2024.3369615

Mahmud, N., Zahedi, A., y Mahmud, A. (2017). A cooperative operation of novel PV inverter control scheme and storage energy management system based on ANFIS for voltage regulation of grid-tied PV system. *IEEE Transactions on Industrial Informatics*, *13*(5), 2657–2668. https://doi.org/10.1109/TII.2017.2651111

Manoj, V., Sai Murali Krishna, K., y Kiran, M. S. (2018). Photovoltaic system based grid interfacing inverter functioning as a conventional inverter and active power filter. *Journal of Advanced Research in Dynamical and Control Systems*, *10*(5), 1109–1117.

Mohamed Imran, A., Kowsalya, M., y Kothari, D. P. (2014). A novel integration technique for optimal network reconfiguration and distributed generation placement in power distribution networks. *International Journal of Electrical Power & Energy Systems*, *63*, 461–472. https://doi.org/10.1016/j.ijepes.2014.06.011

Musiqi, D., Kastrati, V., Bosisio, A., y Berizzi, A. (2023). Deep neural network-based autonomous voltage control for power distribution networks with DGs and EVs. *Applied Sciences*, *13*(23), Artículo 12690. https://doi.org/10.3390/app132312690

Nagaballi, S., y Kale, V. S. (2021). A metaphor-less based AI technique for optimal deployment of DG and DSTATCOM considering reconfiguration in the rds for techno-economic benefits. *Journal of Intelligent & Fuzzy Systems*, *41*(5), 5719–5729. https://doi.org/10.3233/JIFS-189891

Nguyen, H. M., Torres, J. L. R., Leki, A., y Pham, H. V. (2021). Mpc based centralized voltage and reactive power control for active distribution networks. *IEEE Transactions on Energy Conversion*, *36*(2), 1537–1547. https://doi.org/10.1109/TEC.2021.3054844

Nguyen, T. P., Nguyen, T. A., Phan, T. V.-H., y Vo, D. N. (2021). A comprehensive analysis for multi-objective distributed generations and capacitor banks placement in radial distribution networks using hybrid neural network algorithm. *Knowledge-Based Systems*, *231*, Artículo 107387. https://doi.org/10.1016/j.knosys.2021.107387

Niknam, T., y Firouzi, B. B. (2009). A practical algorithm for distribution state estimation including renewable energy sources. *Renewable Energy*, *34*(11), 2309–2316. https://doi.org/10.1016/j.renene.2009.03.005

Obert, J., Trevizan, R. D., y Chavez, A. (2023). Efficient distributed energy resource voltage control using ensemble deep reinforcement learning. *International Journal of Semantic Computing*, *17*(02), 293–308. https://doi.org/10.1142/S1793351X23610020

Okuno, T., Kaneko, A., Fujimoto, Y., Hayashi, Y., Ishimaru, M., y Doi, M. (2025). Dynamic determination method of line drop compensator parameters for voltage regulators based on mixture of experts using real-time information. *IEEJ Transactions on Electrical and Elec-*

tronic Engineering, *20*(3), 358–372. https://doi.org/10.1002/tee.24193

Pradeepa, A. S., y Vaithilingam, C. (2019). Load indices based voltage profile assessment of real time distribution system using generalized regression neural network. *International Review on Modelling and Simulations (IREMOS)*, *12*(4), 222–229. https://doi.org/10.15866/iremos.v12i4.16889

Ramli, S. P., Pashaei, M., Karimi, M., Kauhaniemi, K., Pourdaryaei, A., Daryaei, M., y Zarei, M. (2022). The recent development of optimal docr protection strategies for sustainable power systems via computational intelligence techniques. *IEEE Access*, *10*, 134277–134291. https://doi.org/10.1109/ACCESS.2022.3231603

Rao, G. S., y Obulesh, Y. P. (2013). Optimal location of DG for maintaining distribution system stability: A hybrid technique. *International Journal of Power and Energy Conversion*, *4*(4), 387–403. https://doi.org/10.1504/IJPEC.2013.057036

Raviprabhakaran, V. (2022). Performance enrichment in optimal location and sizing of wind and solar PV centered distributed generation by communal spider optimization algorithm. *COMPEL – The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, *41*(5), 1971–1990. https://doi.org/10.1108/COMPEL-12-2021-0495

Reddy, K. R., Basha, C. H. H., Prashanth, V., Dhanamjayulu, C., Shivashimpiger, S., y Likhitha, R. (2023). A novel on energy management strategy with maximum exploitation of renewables and EV storage in distribution networks. *International Transactions on Electrical Energy Systems*, *2023*, 1–18. https://doi.org/10.1155/2023/1365608

Rehman, A. U., Ali, M., Iqbal, S., Shafiq, A., Ullah, N., y Otaibi, S. A. (2022). Artificial intelligence-based control and coordination of multiple PV inverters for reactive power/voltage control of power distribution networks. *Energies*, *15*(17), Artículo 6297. https://doi.org/10.3390/en15176297

Rehman, A. U., Ullah, Z., Qazi, H. S., Hasanien, H. M., y Khalid, H. M. (2024). Reinforcement learning-driven proximal policy optimization-based voltage control for PV and WT integrated power system. *Renewable Energy*, *227*, Artículo 120590. https://doi.org/10.1016/j.rene

ne.2024.120590

Ruiz-Rodriguez, F. J., Gomez-Gonzalez, M., y Jurado, F. (2013). Optimization of radial systems with biomass fueled gas engine from a metaheuristic and probabilistic point of view. *Energy Conversion and Management*, *65*, 343–350. https://doi.org/10.1016/j.enconman.2012.09.002

Sabat, J., y Mangaraj, M. (2023). Field programmable gate array-based execution on a distributed energy resource supported electrical distribution system for enhanced power quality with optimal active power flow control. *ECTI Transactions on Electrical Engineering, Electronics, and Communications*, *21*(1), Artículo 248571. https://doi.org/10.37936/ecti-eec.2023211.248571

Sayadi, F., Esmaeili, S., y Keynia, F. (2017). Two-layer volt/VAr/total harmonic distortion control in distribution network based on PVs output and load forecast errors. *IET Generation, Transmission & Distribution*, *11*(8), 2130–2137. https://doi.org/10.1049/iet-gtd.2016.1440

Schlachter, H., Geißendörfer, S., von Maydell, K., y Agert, C. (2022). Voltage-based load recognition in low voltage distribution grids with deep learning. *Energies*, *15*(1), Artículo 104. https://doi.org/10.3390/en15010104

Schlachter, H., Geißendörfer, S., von Maydell, K., y Agert, C. (2024). Load recognition in hardware-based low voltage distribution grids using convolutional neural networks. *IEEE Transactions on Smart Grid*, *15*(1), 1042–1051. https://doi.org/10.1109/TSG.2023.3280326

Selim, A., Zhao, J., Ding, F., Miao, F., y Park, S.-Y. (2024). Adaptive deep reinforcement learning algorithm for distribution system cyber attack defense with high penetration of DERs. *IEEE Transactions on Smart Grid*, *15*(4), 4077–4089. https://doi.org/10.1109/TSG.2023.3345314

Shahid, S., Shafiq, S., Khan, B., Al-Awami, A. T., y Butt, M. O. (2021). A machine learning-based communication-free PV controller for voltage regulation. *Sustainability*, *13*(21), Artículo 12208. https://doi.org/10.3390/su132112208

Shi, N., Cheng, R., Liu, L., Wang, Z., Zhang, Q., y Reno, M. J. (2024). Data-driven affinely

adjustable robust Volt/VAr control. *IEEE Transactions on Smart Grid*, *15*(1), 247–259. https://doi.org/10.1109/TSG.2023.3270112

Song, H., Liu, C., Amani, A. M., Gu, M., Jalili, M., Meegahapola, L., Yu, X., y Dickeson, G. (2024). Smart optimization in battery energy storage systems: An overview. *Energy and AI*, *17*, Artículo 100378. https://doi.org/10.1016/j.egyai.2024.100378

Stanelyte, D., y Radziukynas, V. (2020). Review of voltage and reactive power control algorithms in electrical distribution networks. *Energies*, *13*(1), Artículo 58. https://doi.org/10.3390/en13010058

Sun, X., y Qiu, J. (2021). Two-stage Volt/VAr control in active distribution networks with multi-agent deep reinforcement learning method. *IEEE Transactions on Smart Grid*, *12*(4), 2903–2912. https://doi.org/10.1109/TSG.2021.3052998

Sun, Y., Zhang, S., Liu, M., Zheng, R., y Dong, S. (2024). Energy management based on safe multi-agent reinforcement learning for smart buildings in distribution networks. *Energy and Buildings*, *318*, Artículo 114410. https://doi.org/10.1016/j.enbuild.2024.114410

Sundarajoo, S., y Soomro, D. M. (2023). Artificial neural network-based voltage stability online monitoring approach for distributed generation integrated distribution system. *Distributed Generation & Alternative Energy Journal*, *38*(6), 1839–1862. https://doi.org/10.13052/dgaej2156-3306.3866

Suraya, S., Irshad, S. M., Ramesh, G. P., y Sujatha, P. (2022). Biogeography based optimization algorithm and neural network to optimize place and size of distributed generating system in electrical distribution. *Journal of Electrical Engineering & Technology*, *17*(3), 1593–1603. https://doi.org/10.1007/s42835-022-01056-9

Suzuki, O., Wu, G., y Minakawa, T. (2007). A local demand forecast by NN method for distributed autonomous voltage and reactive power control system. *Electrical Engineering in Japan*, *159*(4), 27–37. https://doi.org/10.1002/eej.20450

Tao, Y., Qiu, J., y Lai, S. (2022). A learning and operation planning method for uber energy storage system: Order dispatch. *IEEE Transactions on Intelligent Transportation Systems*, *23*(12),

23070–23083. https://doi.org/10.1109/TITS.2022.3199510

Tarraq, A., El Mariami, F., y Belfqih, A. (2023). Multi-objective distributed generation integration in radial distribution system using modified neural network algorithm. *International Journal of Electrical and Computer Engineering (IJECE)*, *13*(5), 4810–4823. https://doi.org/10.11591/ijece.v13i5.pp4810-4823

Tolabi, H. B., Ara, A. L., y Hosseini, R. (2020). A new thief and police algorithm and its application in simultaneous reconfiguration with optimal allocation of capacitor and distributed generation units. *Energy*, *203*, Artículo 117911. https://doi.org/10.1016/j.energy.2020.117911

Tran, T. V., Truong, B.-H., Nguyen, T. P., Nguyen, T. A., Duong, T. L., y Vo, D. N. (2021). Reconfiguration of distribution networks with distributed generations using an improved neural network algorithm. *IEEE Access*, *9*, 165618–165647. https://doi.org/10.1109/ACCESS.2021.3134872

Tu, J., Xu, Y., y Yin, Z. (2019). Data-driven kernel extreme learning machine method for the location and capacity planning of distributed generation. *Energies*, *12*(1), Artículo 109. https://doi.org/10.3390/en12010109

Türk, J., Schuster, M., Köppe, H., y Engel, B. (2023). Development approach of a Volt-VAr control for inverter-coupled renewable energy plants using deep reinforcement learning. *IET Conference Proceedings*, *2023*(20), 521–528. https://doi.org/10.1049/icp.2023.2782

ur Rehman, A., Ali, M., Iqbal, S., Habib, S., Shafiq, A., Elbarbary, Z. M. S., y Barnawi, A. B. (2023). Transition towards a sustainable power system: MA-DA&DC framework based voltage control in high PV penetration networks. *Energy Reports*, *9*, 5922–5936. https://doi.org/10.1016/j.egyr.2023.05.035

Uzum, B., Onen, A., Hasanien, H. M., y Muyeen, S. M. (2021). Rooftop solar PV penetration impacts on distribution network and further growth factors—A comprehensive review. *Electronics*, *10*(1), Artículo 55. https://doi.org/10.3390/electronics10010055

Vennila, C., Papana, V. P., Reddy, C. V. K., y Kumar, U. A. (2026). ALSO-DCGNN: Enhancing power quality and voltage regulation of energy storage systems in DC micro grid. *Environ-*

ment, Development and Sustainability, *28*(3), 7059–7083. https://doi.org/10.1007/s10668-024-05226-9

Wang, B., Tao, W., Zhang, Z., Chen, P., y Cui, M. (2023). Reactive power and voltage optimization method of distribution network based on reinforcement learning MADDPG algorithm. *IET Conference Proceedings*, *2023*(15), 1150–1153. https://doi.org/10.1049/icp.2023.2443

Wang, H., Luo, R., Yu, Q., y Li, Z. (2023). Topology-independent end-to-end learning model for improving the voltage profile in microgrids-integrated power distribution networks. *Frontiers in Energy*, *17*(2), 211–227. https://doi.org/10.1007/s11708-022-0847-3

Wang, R., Bu, S., y Chung, C. Y. (2024). Real-time joint regulations of frequency and voltage for TSO-DSO coordination: A deep reinforcement learning-based approach. *IEEE Transactions on Smart Grid*, *15*(2), 2294–2308. https://doi.org/10.1109/TSG.2023.3302155

Wang, S., Du, L., Fan, X., y Huang, Q. (2021). Deep reinforcement scheduling of energy storage systems for real-time voltage regulation in unbalanced LV networks with high PV penetration. *IEEE Transactions on Sustainable Energy*, *12*(4), 2342–2352. https://doi.org/10.1109/TSTE.2021.3092961

Wang, S., Sheng, W., Shang, Y., y Liu, K. (2024). Distribution network voltage control considering virtual power plants cooperative optimization with transactive energy. *Applied Energy*, *371*, Artículo 123680. https://doi.org/10.1016/j.apenergy.2024.123680

Wang, X., Zhang, J., Xu, W., Tang, A., y Gao, W. (2024). Piecewise affine power flow model for distribution network optimization using CIM aided data-driven approach. *Electric Power Systems Research*, *237*, Artículo 111026. https://doi.org/10.1016/j.epsr.2024.111026

Wang, Y., Mao, M., Chang, L., y Hatziargyriou, N. D. (2023). Intelligent voltage control method in active distribution networks based on averaged weighted double deep Q-network algorithm. *Journal of Modern Power Systems and Clean Energy*, *11*(1), 132–143. https://doi.org/10.35833/MPCE.2022.000146

Wang, Y., Von Krannichfeldt, L., Zufferey, T., y Toubeau, J.-F. (2021). Short-term nodal voltage forecasting for power distribution grids: An ensemble learning approach. *Applied Energy*,

304, Artículo 117880. https://doi.org/10.1016/j.apenergy.2021.117880

Wu, H., Xu, Z., Wang, M., Zhao, J., y Xu, X. (2023). Two-stage voltage regulation in power distribution system using graph convolutional network-based deep reinforcement learning in real time. *International Journal of Electrical Power & Energy Systems*, *151*, Artículo 109158. https://doi.org/10.1016/j.ijepes.2023.109158

Xu, T., Wade, N. S., Davidson, E. M., Taylor, P. C., McArthur, S. D. J., y Garlick, W. G. (2011). Case-based reasoning for coordinated voltage control on distribution networks. *Electric Power Systems Research*, *81*(12), 2088–2098. https://doi.org/10.1016/j.epsr.2011.08.005

Yang, J., Luo, J., y Zhang, H. (2020). Fuzzy neural network based optimal and fair real power management for voltage security in distribution networks with high PV penetration. *Journal of Electrical Engineering & Technology*, *15*(6), 2471–2478. https://doi.org/10.1007/s42835-020-00527-1

Yang, Q., Wang, G., Sadeghi, A., Giannakis, G. B., y Sun, J. (2020). Two-timescale voltage control in distribution grids using deep reinforcement learning. *IEEE Transactions on Smart Grid*, *11*(3), 2313–2323. https://doi.org/10.1109/TSG.2019.2951769

Yu, P., Zhang, H., Hu, Z., y Song, Y. (2025). Voltage control of distribution grid with district cooling systems based on scenario-classified reinforcement learning. *Applied Energy*, *377*, Artículo 124415. https://doi.org/10.1016/j.apenergy.2024.124415

Žarković, M., Šošić, D., y Dobrić, G. (2014). Fuzzy based prediction of wind distributed generation impact on distribution network: Case study—Banat region, Serbia. *Journal of Renewable and Sustainable Energy*, *6*(1), Artículo 013120. https://doi.org/10.1063/1.4862988

Zhang, B., Hu, W., Ghias, A. M. Y. M., Xu, X., y Chen, Z. (2022). Multi-agent deep reinforcement learning-based coordination control for grid-aware multi-buildings. *Applied Energy*, *328*, Artículo 120215. https://doi.org/10.1016/j.apenergy.2022.120215

Zhang, J., Li, Y., Wu, Z., Rong, C., Wang, T., Zhang, Z., y Zhou, S. (2021). Deep-reinforcement-learning-based two-timescale voltage control for distribution systems. *Energies*, *14*(12), Artículo 3540. https://doi.org/10.3390/en14123540

Zhang, T., Yu, L., Yue, D., Dou, C., Xie, X., y Chen, L. (2023). Coordinated voltage regulation of high renewable-penetrated distribution networks: An evolutionary curriculum-based deep reinforcement learning approach. *International Journal of Electrical Power & Energy Systems*, *149*, Artículo 108995. https://doi.org/10.1016/j.ijepes.2023.108995

Zhang, X., Wu, Z., Sun, Q., Gu, W., Zheng, S., y Zhao, J. (2024). Application and progress of artificial intelligence technology in the field of distribution network voltage control: A review. *Renewable and Sustainable Energy Reviews*, *192*, Artículo 114282. https://doi.org/10.1016/j.rser.2024.114282

Zhao, J., Zhang, Z., Yu, H., Ji, H., Li, P., Xi, W., Yan, J., y Wang, C. (2023). Cloud-edge collaboration-based local voltage control for DGs with privacy preservation. *IEEE Transactions on Industrial Informatics*, *19*(1), 98–108. https://doi.org/10.1109/TII.2022.3172901

Zhao, Y., Liu, J., Liu, X., Yuan, K., y Ding, T. (2024). Enhancing the tolerance of voltage regulation to cyber contingencies via graph-based deep reinforcement learning. *IEEE Transactions on Power Systems*, *39*(2), 4661–4673. https://doi.org/10.1109/TPWRS.2023.3319699

Zhao, Y., Zhang, G., Hu, W., Huang, Q., Chen, Z., y Blaabjerg, F. (2023a). Meta-learning based voltage control for renewable energy integrated active distribution network against topology change. *IEEE Transactions on Power Systems*, *38*(6), 5937–5940. https://doi.org/10.1109/TPWRS.2023.3309536

Zhao, Y., Zhang, G., Hu, W., Huang, Q., Chen, Z., y Blaabjerg, F. (2023b). Meta-learning based voltage control strategy for emergency faults of active distribution networks. *Applied Energy*, *349*, Artículo 121399. https://doi.org/10.1016/j.apenergy.2023.121399

Apéndice B

Repositorio Técnico Entregado: Guía de Uso y Trazabilidad Computacional

B.1. Propósito del Apéndice

Este apéndice presenta la guía de uso del repositorio técnico entregado como soporte computacional del trabajo de investigación. El repositorio contiene el código fuente, configuraciones, datos de entrada y utilidades necesarias para preparar escenarios, entrenar controladores, ejecutar evaluaciones y generar salidas experimentales asociadas al estudio de control de tensión en una red de distribución activa basada en el alimentador IEEE de 33 barras.

El paquete debe leerse como una base de reproducción y auditoría computacional. Las salidas numéricas y gráficas reportadas en el documento principal se obtienen mediante la ejecución del flujo experimental descrito en este apéndice. Por ello, el documento se enfoca en explicar cómo está organizado el repositorio, cómo preparar el entorno y cómo avanzar desde los datos y configuraciones hasta la generación de resultados.

Lectura del repositorio. El repositorio se entrega como base computacional del trabajo. El lector puede usarlo para preparar escenarios, ejecutar entrenamientos y evaluaciones, y generar salidas a partir de los scripts y configuraciones disponibles. El paquete no es una carpeta de resultados finales precomputados; las salidas se generan mediante el flujo descrito.

B.2. Ruta Rápida de Lectura

Tabla B1
Ruta rápida de lectura del repositorio.

Necesidad del lector	Sección recomendada
Conocer la estructura del repositorio	Secciones B.4–B.5
Instalar dependencias	Sección B.6
Identificar datos y configuraciones	Sección B.7
Entrenar o evaluar controladores	Sección B.8
Controlar atención y pronóstico	Sección B.9
Evaluar BASE y contingencias N-1	Sección B.10
Revisar niveles de penetración FV	Sección B.11
Visualizar y analizar salidas generadas	Sección B.12
Relacionar scripts con escenarios del libro	Sección B.13
Generar tablas y figuras a partir de salidas	Sección B.14
Hacer una prueba mínima del repositorio	Sección B.15
Registrar trazabilidad de corridas	Sección B.16

B.3. Mapa General del Flujo Computacional

El flujo de uso conecta el entorno de ejecución, los datos temporales, las configuraciones YAML, el entrenamiento del controlador, las evaluaciones comparativas y el análisis posterior. La Figura B1 resume esta secuencia de trabajo.

Figura B1
Flujo general de uso del repositorio técnico.

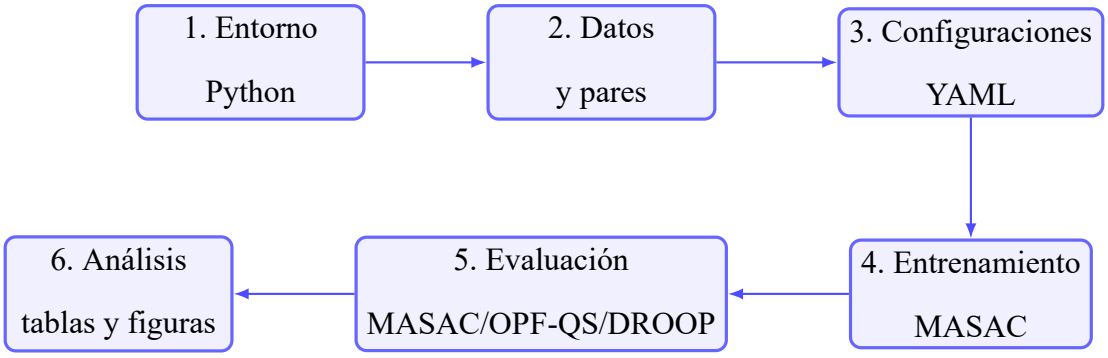

Flujo mínimo sugerido. Instalar dependencias, verificar configuraciones, revisar datos, ejecutar una prueba corta, entrenar o suministrar un checkpoint compatible, evaluar métodos y generar análisis.

B.4. Estructura del Repositorio

La estructura permite separar el código del controlador, los scripts de ejecución, las configuraciones, los insumos de datos y las herramientas de análisis. El siguiente resumen destaca los elementos principales de la carpeta técnica entregada.

```
Repositorio/
|-- README.md
|-- README_figuras_capitulo_7.md
|-- requirements.txt
|-- comparaciones_montecarlo.py
|-- compare_load_curves.py
|-- config.py
|-- gen_eval_pairs.py
|-- viz_fault_dashboard.py
|-- viz_qs_dashboard.py
|-- masac/
|   |-- xai/
|-- network_visualization/
|   |-- adapters/
|   |-- app_dash/
|   |-- state/
|   |-- vis/
|-- qs/
|-- run/
|   |-- configs/
|-- src/
|   |-- analysis/
|-- synthetic_data/
|   |-- Datos_Base/
|   |-- NOMBRES_CURVAS/
|-- synthetic_data_multi_loads/
|   |-- Datos_Base/
|   |-- NOMBRES_CURVAS/
|-- tools/
```

B.5. Componentes Principales

Tabla B2
Componentes principales del repositorio técnico.

Componente	Función dentro del flujo
`masac/`	Implementación del entorno, modelos, entrenamiento y utilidades del controlador.
`run/`	Scripts de entrenamiento, evaluación, diagnóstico y visualización.
`run/configs/`	Configuraciones YAML de red, entorno, evaluación y variantes FV.
`synthetic_data/`	Insumos de datos, pares de evaluación y archivos auxiliares.
`synthetic_data_multi_loads/`	Pares multi-carga y datos asociados.
`qs/`	Código auxiliar para referencia OPF-QS.
`network_visualization/`	Módulos de visualización de red y tableros de inspección.
`src/analysis/`	Utilidades de análisis complementario.
`tools/`	Herramientas auxiliares de procesamiento y verificación.

Los directorios de salida se crean durante la ejecución de los scripts de entrenamiento, evaluación y análisis, de acuerdo con las rutas definidas por el usuario.

B.6. Entorno Computacional e Instalación

El archivo `requirements.txt` fija las dependencias de Python usadas por el repositorio. Entre las bibliotecas principales se encuentran `torch`, `pandapower`, `numpy`, `pandas`, `matplotlib`, `plotly`, `scikit-learn`, `scipy`, `optuna` y `tensorboard`. La documentación del repositorio recomienda Python 3.11 y, para entrenamiento acelerado, una GPU NVIDIA compatible con CUDA 12.1.

Los comandos siguientes asumen que la terminal está ubicada en la raíz del repositorio

técnico.

```
python -m venv masac_env
```

```
source masac_env/bin/activate
```

En Windows PowerShell, la activación equivalente puede realizarse con:

```
.\masac_env\Scripts\Activate
```

```
python -m pip install --upgrade pip
pip install -r requirements.txt \
  --extra-index-url https://download.pytorch.org/whl/cu121
```

Una verificación inicial de dependencias puede ejecutarse con:

```
python -c "import torch, pandapower, pandas; \
  print('torch:', torch.__version__); \
  print('cuda:', torch.cuda.is_available())"
```

B.7. Datos, Pares de Evaluación y Configuraciones

El repositorio trabaja con perfiles diarios de 288 pasos, equivalentes a una resolución temporal de 5 minutos. Los pares carga–irradiancia se emplean como entrada temporal para entrenamiento y evaluación, mientras que los archivos YAML definen la red, los límites operativos, semillas, variantes de penetración fotovoltaica y parámetros de evaluación.

Tabla B3
Insumos de datos y configuración usados por el flujo.

Insumo	Uso dentro del flujo
Configuraciones YAML	Definen red, límites, escenarios, semillas, variantes FV y parámetros de evaluación.
Pares carga–irradiancia	Sirven como entrada temporal para entrenamiento y evaluación.
Archivos Excel de GHI	Fuente para generar o reconstruir pares de irradiancia.
Datos base de red y curvas	Permiten construir perfiles de carga y escenarios.
Manifiestos de pares	Documentan la generación de insumos y trazabilidad de perfiles.

Tabla B4
Configuraciones YAML principales.

Archivo	Rol dentro del flujo
`run/configs/base.yaml`	Configuración general del entorno, límites y parámetros base.
`run/configs/base_qs_opf_tuned.yaml`	Parámetros ajustados para evaluación OPF-QS.
`run/configs/best_config.yaml`	Configuración asociada a una variante seleccionada del entrenamiento.
`run/configs/network_ieee33.yaml`	Red IEEE de 33 barras base.
`run/configs/network_ieee33_pv_opt1.yaml`	Red con ubicación FV empleada en el flujo recomendado.
`run/configs/network_ieee33_pv_opt1_pen030.yaml`	Variante de penetración FV del 30 %.
`run/configs/network_ieee33_pv_opt1_pen060.yaml`	Variante de penetración FV del 60 %.
`run/configs/network_ieee33_pv_opt1_pen090.yaml`	Variante de penetración FV del 90 %.
`run/configs/network_ieee33_pv_opt1_pen120.yaml`	Variante de penetración FV del 120 %.
`run/configs/network_ieee33_pv_opt1_pen150.yaml`	Variante de penetración FV del 150 %.
`run/configs/optuna.yaml`	Rangos y opciones para búsqueda de hiperparámetros.
`run/configs/override_step6.yaml`	Sobrescritura de parámetros para variantes específicas.
`run/configs/viz.yaml`	Opciones de visualización.

Estas configuraciones son el punto de entrada para reproducir variantes de red, penetración fotovoltaica, evaluación OPF-QS, entrenamiento y visualización.

Tabla B5
Scripts clave del repositorio.

Script	Rol dentro del flujo
`run/run_masac.py`	Entrena controladores MASAC desde datos y configuraciones.
`run/eval_masac.py`	Evalúa un controlador MASAC con un checkpoint compatible.
`run/eval_qs.py`	Evalúa la referencia OPF-QS y variantes QS.
`run/eval_local.py`	Evalúa reglas locales Volt/Var tipo DROOP.
`gen_eval_pairs.py`	Genera pares carga–irradiancia de 5 minutos y 288 pasos.
`comparaciones_montecarlo.py`	Consolida métricas y genera comparaciones estadísticas a partir de CSV de evaluación generados.
`run/merge_ranges.py`	Une archivos CSV generados por evaluaciones por rangos.
`run/extract_fault_window.py`	Extrae ventanas temporales desde salidas de contingencia.
`run/compare_fault_window.py`	Compara una ventana base contra una ventana con contingencia.
`run/plot_penetration_trends.py`	Grafica tendencias asociadas a sensibilidad de penetración FV.
`run/plot_training_moving_avg.py`	Visualiza curvas de entrenamiento a partir de registros generados.
`run/smoke_test.sh`, `run/smoke_test.bat`	Ejecutan pruebas rápidas del flujo en Linux/macOS y Windows.
`viz_qs_dashboard.py`, `viz_fault_dashboard.py`	Abren tableros de inspección para series temporales compatibles.

B.8. Flujo de Trabajo Recomendado

Esta sección presenta una ruta de ejecución desde la preparación del entorno hasta la generación de comparaciones. Las rutas entre signos <> deben reemplazarse por carpetas o archivos

definidos por el usuario.

B.8.1. Preparar Entorno

```
python -m venv masac_env
source masac_env/bin/activate
python -m pip install --upgrade pip
pip install -r requirements.txt \
  --extra-index-url https://download.pytorch.org/whl/cu121
```

B.8.2. Verificar Datos y Configuraciones

```
python -c "import yaml, pathlib; \
  pathlib.Path('run/configs/base.yaml').read_text(); \
  pathlib.Path('run/configs/network_ieee33_pv_opt1.yaml').read_text(); \
  print('YAML disponibles')"
```

```
python -c "from pathlib import Path; \
  files=list(Path('synthetic_data_multi_loads/Datos_Base').glob('
   train_pair_*.csv')); \
  print('pares:', len(files)); \
  print(files[0] if files else 'sin pares')"
```

B.8.3. Generar Pares Carga–Irradiancia

```
python gen_eval_pairs.py \
  --base-dir synthetic_data/Datos_Base \
  --base-glob train_pair_*.csv \
  --ghi-xlsx synthetic_data/Datos_Base/ENE-JUN2025.xlsx \
  --out-dir <directorio_de_pares> \
  --n-pairs 1000 \
```

```
  --seed 42 \
  --overwrite
```

B.8.4. Entrenar MASAC

```
python run/run_masac.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --train-pairs-dir synthetic_data_multi_loads/Datos_Base \
  --episodes 250 \
  --batch-size 256 \
  --seed 42 \
  --output-dir <directorio_de_salida> \
  --log-dir <directorio_de_logs> \
  --topo-bias 0.05 \
  --head-div 0.01 \
  --export-deliverables 0 \
  --plot-net \
  --precheck-voltages
```

Para una ablación sin atención, se usa explícitamente `--no-attention` y se dejan en cero los pesos asociados a la versión con atención:

```
python run/run_masac.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --train-pairs-dir synthetic_data_multi_loads/Datos_Base \
  --episodes 250 \
  --batch-size 256 \
  --seed 42 \
  --output-dir <directorio_de_salida_noatt> \
  --log-dir <directorio_de_logs_noatt> \
  --no-attention \
  --topo-bias 0.0 \
  --head-div 0.0 \
  --export-deliverables 0 \
  --plot-net \
  --precheck-voltages
```

B.8.5. Evaluar MASAC

La evaluación carga los actores guardados en el checkpoint entrenado. El script `run/eval_masac.py` no recibe opciones de atención; la consistencia que debe cuidarse en evaluación es el uso de variables de pronóstico, porque `--disable-forecast-features` cambia la dimensión de entrada de los actores.

```
python run/eval_masac.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --scenario BASE \
  --ckpt <checkpoint_entrenado.pt> \
  --out <csv_masac.csv>
```

B.8.6. Evaluar OPF-QS y DROOP

```
python run/eval_qs.py \
  --config run/configs/base_qs_opf_tuned.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --scenario BASE \
  --opf \
  --out <csv_opf_qs.csv>
```

```
python run/eval_local.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
```

```
  --scenario BASE \
  --out <csv_droop.csv>
```

B.8.7. Generar Comparaciones y Figuras

```
python comparaciones_montecarlo.py \
  --method "MASAC=<csv_masac.csv>" \
  --method "OPF-QS=<csv_opf_qs.csv>" \
  --method "DROOP=<csv_droop.csv>" \
  --columns "mean_abs_dev,p95_abs_dev,frac_out_095_105,loss_mwh_day,
   tap_changes,cap_changes" \
  --horizontal \
  --run-name <nombre_analisis> \
  --outdir <directorio_de_figuras>
```

B.9. Control de Atención, Pronóstico y Regularización

El repositorio permite ejecutar variantes de MASAC con y sin mecanismo de atención, y con o sin variables de pronóstico fotovoltaico. Estas dos decisiones son independientes. La atención se desactiva explícitamente mediante la opción `--no-attention`; en ausencia de esta opción, el script de entrenamiento usa la configuración con atención definida por defecto. Las variables de pronóstico se desactivan mediante `--disable-forecast-features`.

Los parámetros `--topo-bias` y `--head-div` no son interruptores de activación de atención. En la configuración final con atención se usan como pesos asociados al sesgo topológico y a la diversidad entre cabezas de atención. La configuración empleada para la versión con atención y pronóstico usa `--topo-bias 0.05 --head-div 0.01`. Para una ablación sin atención se recomienda usar `--no-attention --topo-bias 0.0 --head-div 0.0`.

Tabla B6
Configuraciones principales para ablación de atención y pronóstico.

Configuración	Atención	Pronóstico FV	Opciones principales
MASAC-noAtt-noFc	No	No	`--no-attention --topo-bias 0.0 --head-div 0.0 --disable-forecast-features`
MASAC-noAtt-Fc	No	Sí	`--no-attention --topo-bias 0.0 --head-div 0.0`
MASAC-Att-noFc	Sí	No	`--topo-bias 0.05 --head-div 0.01 --disable-forecast-features`
MASAC-Att-Fc	Sí	Sí	`--topo-bias 0.05 --head-div 0.01`

Regla práctica. Para entrenar con atención, no use `--no-attention` y fije los pesos de atención de la configuración final: `--topo-bias 0.05 --head-div 0.01`. Para entrenar sin atención, use `--no-attention` y deje ambos pesos en cero.

B.10. Evaluaciones BASE y Contingencias N-1

Las evaluaciones del repositorio distinguen entre el escenario BASE, donde la red opera completa, y el escenario N-1, donde se desconecta una línea durante una ventana temporal definida. Para comparar métodos, el rango de pares, la configuración de red, la semilla y la ventana de contingencia deben mantenerse iguales.

Parámetros de contingencia. La contingencia se activa con `--scenario N1`. La línea afectada se define con `--n1-line`; el intervalo temporal se define con `--t_fail` y `--t_restore`.

Tabla B7
Opciones principales para evaluaciones BASE y N-1.

Opción	Rol dentro del flujo
`--scenario BASE`	Evalúa la red completa, sin contingencia.
`--scenario N1`	Evalúa una contingencia de una línea fuera de servicio.
`--n1-line`	Identifica la línea desconectada durante la contingencia.
`--t_fail`	Define la hora de inicio de la falla en formato `HH:MM`.
`--t_restore`	Define la hora de restauración en formato `HH:MM`.
`--out-diagnostic`	Guarda detalle adicional para inspección de ventanas, barras y líneas.

Ejemplo de evaluación MASAC con contingencia N-1:

```
python run/eval_masac.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --ckpt <checkpoint_entrenado.pt> \
  --scenario N1 \
  --n1-line 25 \
  --t_fail 12:00 \
  --t_restore 13:00 \
  --scenario-label MASAC_N1 \
  --out <csv_masac_n1.csv> \
  --out-diagnostic <csv_masac_n1_diagnostic.csv>
```

Ejemplo de evaluación OPF-QS con la misma contingencia:

```
python run/eval_qs.py \
  --config run/configs/base_qs_opf_tuned.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --scenario N1 \
  --n1-line 25 \
  --t_fail 12:00 \
  --t_restore 13:00 \
  --opf \
```

```
  --inv-opt-every 1 \
  --cont-q-levels 9 \
  --cont-iters 2 \
  --oltc-radius 4 \
  --scenario-label OPFQS_N1 \
  --out <csv_opf_qs_n1.csv> \
  --out-diagnostic <csv_opf_qs_n1_diagnostic.csv> \
  --discrete-every 12 \
  --disable-forecast-features \
  --no-opt-print \
  --no-step-print
```

Ejemplo de evaluación DROOP con la misma contingencia:

```
python run/eval_local.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --scenario N1 \
  --n1-line 25 \
  --t_fail 12:00 \
  --t_restore 13:00 \
  --scenario-label DROOP_N1 \
  --out <csv_droop_n1.csv> \
  --out-diagnostic <csv_droop_n1_diagnostic.csv> \
  --discrete-every 12 \
  --no-step-print
```

Para comparar una ventana BASE contra una ventana N-1 se usa `run/compare_fault_window.py`. Este script recibe salidas detalladas mediante `--base-detail` y `--fault-detail`; la ventana activa se infiere desde el detalle de la contingencia. Cuando el CSV contiene varios pares, se indica el par con `--pair-id`.

```
python run/compare_fault_window.py \
  --base-detail <csv_base_controlled.csv> \
  --fault-detail <csv_n1_controlled.csv> \
  --base-diagnostic <csv_base_diagnostic_controlled.csv> \
  --fault-diagnostic <csv_n1_diagnostic_controlled.csv> \
  --pair-id 0 \
```

```
  --method-label MASAC \
  --out-dir <directorio_figuras_falla>
```

B.11. Evaluaciones por Nivel de Penetración Fotovoltaica

La sensibilidad por penetración FV se controla cambiando el archivo de red indicado en `--network-config`. El criterio de comparación es mantener constantes el rango de pares, método, semilla, ventana horaria y escenario, variando únicamente la configuración de red correspondiente al nivel FV.

Tabla B8
Configuraciones de red para sensibilidad de penetración FV.

Nivel FV	Configuración de red
30 %	`run/configs/network_ieee33_pv_opt1_pen030.yaml`
60 %	`run/configs/network_ieee33_pv_opt1_pen060.yaml`
90 %	`run/configs/network_ieee33_pv_opt1_pen090.yaml`
120 %	`run/configs/network_ieee33_pv_opt1_pen120.yaml`
150 %	`run/configs/network_ieee33_pv_opt1_pen150.yaml`

Ejemplo de evaluación MASAC para penetración FV de 150 % en escenario BASE:

```
python run/eval_masac.py \
  --config run/configs/base.yaml \
  --network-config run/configs/network_ieee33_pv_opt1_pen150.yaml \
  --pairs-csv-dir synthetic_data_multi_loads/Datos_Base \
  --range-init 0 \
  --range-end 19 \
  --ckpt <checkpoint_entrenado.pt> \
  --scenario BASE \
  --scenario-label MASAC_PV150 \
  --out <csv_masac_pen150.csv> \
  --out-diagnostic <csv_masac_pen150_diagnostic.csv>
```

El mismo cambio de `--network-config` se aplica a `run/eval_qs.py` y `run/eval_local.py`. Para combinar alta penetración FV con contingencia N-1, se conserva la configuración FV

y se agregan `--scenario N1`, `--n1-line`, `--t_fail` y `--t_restore`.

B.12. Visualización y Análisis de Salidas

Las salidas de evaluación pueden consolidarse en tablas comparativas, figuras estadísticas, reportes de ventanas de falla y tableros de inspección. La Tabla B9 resume los scripts usados para este cierre del flujo.

Tabla B9
Scripts de visualización y análisis de salidas.

Script	Producto generado
`comparaciones_montecarlo.py`	Tablas y figuras comparativas a partir de CSV de evaluación.
`run/extract_fault_window.py`	CSV filtrado de ventana de falla o ventana BASE equivalente.
`run/compare_fault_window.py`	Reporte comparativo entre ventana BASE y ventana N-1.
`run/plot_penetration_trends.py`	Tendencias por nivel de penetración FV desde tablas resumen.
`viz_qs_dashboard.py`	Dashboard HTML de series por barra y método.
`viz_fault_dashboard.py`	Dashboard HTML de reportes de contingencia.

```
python comparaciones_montecarlo.py \
  --method "MASAC=<csv_masac.csv>" \
  --method "OPF-QS=<csv_opf_qs.csv>" \
  --method "DROOP=<csv_droop.csv>" \
  --columns "mean_abs_dev,p95_abs_dev,frac_out_095_105,loss_mwh_day,
   tap_changes,cap_changes" \
  --horizontal \
  --run-name <nombre_comparacion> \
  --outdir <directorio_figuras>
```

```
python run/extract_fault_window.py \
  --detail <csv_n1_controlled.csv> \
```

```
  --out <csv_n1_fault_window.csv> \
  --mode fault-only \
  --scenario N1 \
  --pair-id 0
```

```
python run/plot_penetration_trends.py \
  --summary "30=<tabla_pen030.csv>" \
  --summary "60=<tabla_pen060.csv>" \
  --summary "90=<tabla_pen090.csv>" \
  --summary "120=<tabla_pen120.csv>" \
  --summary "150=<tabla_pen150.csv>" \
  --methods "MASAC,OPF-QS,DROOP" \
  --outdir <directorio_tendencias> \
  --prefix penetration_trends
```

```
python viz_fault_dashboard.py \
  --report-dir <directorio_figuras_falla> \
  --network-yaml run/configs/network_ieee33_pv_opt1.yaml \
  --method-label MASAC \
  --out-prefix <directorio_dashboard_falla>
```

```
python viz_qs_dashboard.py \
  --method "MASAC=<csv_masac.csv>" \
  --method "OPF-QS=<csv_opf_qs.csv>" \
  --method "DROOP=<csv_droop.csv>" \
  --pair-id 0 \
  --network-yaml run/configs/network_ieee33_pv_opt1.yaml \
  --out-prefix <directorio_dashboard_series>
```

B.13. Escenarios del Libro y Ruta Computacional Asociada

La Tabla B10 relaciona cada escenario del libro con la ruta computacional que permite producir las salidas necesarias para el análisis.

Tabla B10
Escenarios del libro y ruta computacional asociada.

Escenario	Qué evalúa	Ruta computacional
E1	MASAC vs. sin control	Evaluar MASAC y caso sin control; luego consolidar métricas.
E2	Comparación MASAC, MASAC-noAtt, OPF-QS y DROOP	Ejecutar evaluadores y comparar CSV generados.
E3	Reentrenamiento	Entrenar MASAC-RE y evaluar sobre los 20 días.
E4	Monte Carlo ampliado	Generar/evaluar catálogo ampliado y comparar MASAC/MASAC-RE.
E5	Contingencia N-1	Ejecutar evaluación con `--scenario N1`, `--n1-line`, `--t_fail` y `--t_restore`; luego comparar ventanas BASE/N-1 con `run/compare_fault_window.py`.
E3-P	Sensibilidad a penetración FV	Usar configuraciones `network_ieee33_pv_opt1_pen*.yaml`, evaluar por nivel y graficar tendencias con `run/plot_penetration_trends.py`.
E5-P	Contingencia N-1 con alta penetración FV	Combinar configuraciones de penetración FV, especialmente 150 %, con evaluación N-1 y análisis de ventana de falla.

B.14. Generación de Salidas y Análisis

Durante el uso del repositorio, el usuario define directorios de salida para almacenar modelos entrenados, archivos CSV de evaluación, diagnósticos, tablas comparativas y figuras. La organización recomendada es separar salidas de entrenamiento, evaluación y análisis para mantener trazabilidad entre configuración, escenario y resultado.

Tabla B11
Salidas generadas durante el uso del repositorio.

Salida	Se genera a partir de	Uso
Checkpoint	Entrenamiento MASAC	Evaluación posterior del controlador.
CSV de evaluación	Evaluadores MASAC/OPF-QS/DROOP	Cálculo de métricas y comparación.
Tabla resumen	Scripts de comparación	Reporte estadístico.
Figura	Scripts de análisis	Visualización para inspección o informe.

B.15. Verificación Mínima del Repositorio

La verificación mínima confirma que el entorno puede instalarse, que las dependencias principales importan, que los datos y configuraciones se leen, y que el flujo puede iniciar una corrida corta.

- Crear y activar el entorno de Python.
- Instalar dependencias desde `requirements.txt`.
- Importar `torch`, `pandapower` y `pandas`.
- Verificar lectura de archivos YAML.
- Verificar acceso a pares carga–irradiancia.
- Ejecutar una prueba corta de entrenamiento.
- Ejecutar una evaluación con un checkpoint disponible.
- Generar una tabla o figura a partir de CSV de evaluación.

B.16. Trazabilidad y Buenas Prácticas de Uso

Para mantener trazabilidad, se recomienda registrar para cada corrida: identificador de escenario, archivo de configuración, configuración de red, semilla, rango de días evaluado, nivel de penetración FV, método de control, ruta de salida y fecha de ejecución.

Tabla B12
Campos recomendados para registrar corridas.

Campo	Ejemplo
Método	MASAC, OPF-QS, DROOP
Escenario	BASE, N1
Semilla	42
Configuración de red	`network_ieee33_pv_opt1.yaml`
Rango de días	0–19
Ventana	09:00–15:00 o 12:00–13:00
Salida	Directorio definido por el usuario

Como práctica operativa, conviene conservar junto a cada salida el comando ejecutado, la versión de las configuraciones, la semilla y un identificador corto del escenario. Esta disciplina permite revisar, comparar y auditar corridas posteriores sin mezclar salidas de entrenamiento, evaluación y análisis.