

Predicción de demanda y generación renovable con Deep Learning: Aplicación a la optimización de estaciones de carga de vehículos eléctricos

Ramos-Perez, Francisco^{a,*}, Vivas, Carlos^a, R. Rubio, Francisco^a

^aDepartamento de Ingeniería de Sistemas y Automática, Escuela Técnica Superior de Ingeniería, Universidad de Sevilla, Camino Descubrimientos, S/N. , 41092, Sevilla, España.

To cite this article: Ramos-Perez, Francisco, Vivas, Carlos, Rubio, Francisco 2023. Charge demand and renewable generation forecasting with Deep Learning: application to electric vehicle station optimization. XLIV Jornadas de Automática, 346-351. <https://doi.org/10.17979/spudc.9788497498609.346>

Resumen

Los vehículos eléctricos se están popularizando y son claves para el transporte del futuro debido a su contribución en la reducción de las emisiones de carbono. Uno de los desafíos que plantea la electrificación de la movilidad es el soporte que tendrá que dar la infraestructura actual de red eléctrica a estos vehículos. Un aspecto crucial para resolución de este problema pasa por una gestión y planificación inteligentes del proceso de carga. El uso de técnicas basadas en datos y de aprendizaje automático (Machine Learning) para entender y predecir el comportamiento de carga de vehículos eléctricos y de generación renovable (fotovoltaica) pueden servir para mejorar estos algoritmos de planificación. En este artículo se propone un caso de estudio para evaluar el impacto de las técnicas mencionadas en los algoritmos de planificación dinámica de la demanda de carga. Este algoritmo hace uso de predicciones de la demanda y de la producción fotovoltaica generadas por modelos de redes neuronales. Estos modelos secuenciales han sido entrenados con datos obtenidos de una base de datos pública en el caso de la demanda y de una planta fotovoltaica real en el caso de la producción. En predicción de la demanda, el modelo que ha obtenido mejores resultados ha sido el modelo con redes LSTM con una ventana temporal de 4 días, obteniendo un MAE de 4.41 kW y un RMSE de 4.10 kW sobre los datos de testeo. En la predicción de la generación, el mejor modelo ha resultado ser el modelo de redes CNN+LSTM con una ventana temporal de 1 día, obteniendo un MAE de 55.60 kW y un RMSE de 104.61 kW sobre los datos de testeo.

Palabras clave: Vehículos eléctricos y solares, Inteligencia artificial en el transporte, Control de la energía en el transporte, Funcionamiento y planificación del almacenamiento de energía, Control basado en datos, Aprendizaje automático, Modelización de series temporales

Charge demand and renewable generation forecasting with Deep Learning: application to electric vehicle station optimization

Abstract

Electric vehicles are becoming increasingly popular and are key to the transport of the future due to their contribution to reducing carbon emissions. One of the key challenges, however, is how the grid infrastructure could provide support to all the electric vehicle charging stations that comes with large-scale EV deployment. The solution to this lies in the utilization of smart scheduling algorithms to manage the growing public charging demand. The use of data-driven techniques and Machine Learning to learn the behaviour of electric vehicle charging and photovoltaic generation can be used to improve these scheduling algorithms. Therefore, in this article, a case study simulator and a smart scheduling algorithm to manage charging demand are proposed. This algorithm makes use of demand and photovoltaic production forecasting generated by neural network models. These sequential models have been trained with data obtained from a public database in the case of demand and from a real PV plant in the case of production. In demand forecasting, the model that obtained the best results was the model with LSTM networks with window size of 4 days, obtaining an MAE of 4.41 kW and an RMSE of 4.10 kW on the test data. In generation forecasting, the best model was the CNN+LSTM networks model with a window size of 1 day, obtaining an MAE of 55.60 kW and an RMSE of 104.61 kW on the test data.

Keywords: Electric and solar vehicles, Artificial intelligence in transportation, Energy control in transportation, Energy storage operation and planning, Data-driven control, Machine Learning, Time series modelling

1. Introducción

La creciente penetración del vehículo eléctrico ha incrementado la necesidad e importancia de las estaciones de carga que suministran energía a estos vehículos. En particular, el soporte que la infraestructura eléctrica actual debe brindar a las estaciones de carga que se están instalando a gran escala es un desafío clave.

Por otro lado, las energías renovables están adquiriendo gran importancia debido al abaratamiento de costes de estas tecnologías y al desarrollo de nuevas formas económicamente viables de almacenar energía. A medida que el uso de energías renovables continúa creciendo, es crucial modernizar la red eléctrica.

El objetivo global de este trabajo es proponer un simulador de una micro-red inteligente que integre energías renovables y disponga de almacenamiento energético, capaz de gestionar la demanda de carga de vehículos eléctricos y planificar eficientemente el uso de la energía. La solución a este problema requiere el uso de algoritmos de planificación inteligentes para gestionar la creciente demanda de carga. Las técnicas basadas en datos y Machine Learning se utilizan para comprender el comportamiento de la carga de los vehículos eléctricos y la generación fotovoltaica Hüttel et al. (2021) Zhu et al. (2019) Shahriar et al. (2021) Kim and Kim (2021), lo que permite mejorar los algoritmos de planificación. El algoritmo propuesto proporciona predicciones de la demanda y la producción fotovoltaica generadas por modelos de redes neuronales.

En primer lugar, se ha desarrollado e implementado un simulador de un sistema unificado de una instalación de carga inteligente de vehículos eléctricos con soporte renovable. De esta forma, se muestra cómo las fluctuaciones de la potencia disponible pueden ser compensadas y reguladas mediante la tecnología V2G-G2V (Vehículo a la Red - Red al Vehículo) y un banco de baterías como almacenamiento de energía. A continuación, se aborda la optimización y planificación dinámica en una estación de carga de vehículos eléctricos. Para finalizar se aborda el principal desafío de este trabajo, la predicción de la demanda futura de carga que soportará la estación, así como la generación de energía fotovoltaica utilizando técnicas avanzadas de Deep Learning.

Para ello, se hace uso de datos reales, previamente preprocesados, obtenidos de bases de datos públicas y de una planta fotovoltaica experimental. Además, se realiza un estudio y comparación de diferentes arquitecturas de redes neuronales con el fin de encontrar los modelos e hiperparámetros óptimos para predecir estas series temporales de demanda y generación.

2. Simulador de estación de vehículos eléctricos

En este apartado se introduce el modelado e implementación de un simulador para una instalación de carga inteligente de vehículos eléctricos con soporte renovable. La estación incluye cargadores de carga lenta y rápida, un banco de baterías para almacenamiento y un panel de control para monitoreo. Además, cuenta con generación renovable a través de una planta fotovoltaica y una turbina eólica.

Se requiere el diseño de una micro-red que administre los flujos de energía provenientes de los vehículos eléctricos y el banco de almacenamiento. Se explicará y analizará la arquitectura general de la estación en detalle.

2.1. Arquitectura general

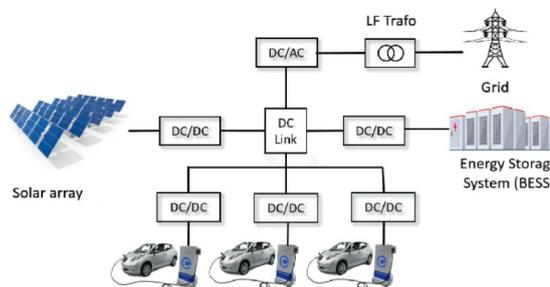


Figura 1: Esquema de la arquitectura de la estación de carga.

La instalación se abastece principalmente de dos fuentes de energía: la red eléctrica y los paneles fotovoltaicos. Los vehículos se cargan utilizando cargadores de corriente continua y alterna, conectados a buses DC y AC respectivamente. Los paneles fotovoltaicos y el banco de baterías se conectan en paralelo al bus DC.

Los transformadores son componentes clave que reciben energía de la red y suministran baja tensión al resto de la instalación, con elementos de filtrado adicionales (Shakeel and Malik (2019)).

El sistema emplea diferentes convertidores para ajustar la tensión y la corriente. Estos incluyen un convertidor AC/DC bidireccional previo al bus DC, un convertidor elevador para los paneles fotovoltaicos al bus DC, y convertidores bidireccionales en los puntos de carga DC y en el banco de baterías.

Por último, la estación cuenta con un centro de control que permite gestionar los vehículos conectados, supervisar las operaciones de carga y descarga, y dirigir los flujos de energía entre los componentes principales de la micro-red. También se presenta un balance general de potencia para el monitoreo de la estación desde el centro de control.

3. Optimización y planificación dinámica en la estación de carga de EV

La producción de energía renovable y la demanda de carga de vehículos eléctricos pueden ser variables y causar fluctuaciones en la potencia disponible. En una estación eléctrica con soporte renovable, estas fluctuaciones pueden ser compensadas mediante la tecnología V2G-G2V y un banco de baterías. Para abordar este desafío, se propone una micro-red inteligente que optimiza y planifica los flujos de energía de manera eficiente. Esto ayuda a estabilizar la red durante los picos de demanda y maximiza el beneficio económico y la utilización de recursos.

En este trabajo, se utiliza el Deep Learning para predecir las curvas de demanda y producción, lo que permite un enfoque dinámico en la planificación de la carga. Estas curvas se utilizan

* Autor para correspondencia: curro.ramosperez@gmail.com, vivas@us.es, rubio@us.es

junto con un algoritmo de optimización clásico para determinar las mejores decisiones en un horizonte temporal.

A continuación, se presenta el problema de optimización y el algoritmo propuesto.

3.1. Problema de optimización

El problema de optimización se ha formulado teniendo como objetivo la minimización del coste monetario de la planta. La función objetivo debe incluir todas las variables que se pueden controlar, que son la potencia absorbida/cedida por las baterías de la planta y por la red eléctrica.

$$\min_u J(t) = \sum_{k=1}^{SH} (J_{GRID}(t_k|t) + J_{BES}(t_k|t)) \quad (1)$$

El término $J_{GRID}(t_k|t)$ es la penalización provocada por utilizar la potencia suministrada por la red eléctrica en el instante t_k , conocidos los datos del instante t . Este término podría reducir el coste total del sistema si la planta vende potencia a la red.

El término $J_{BES}(t_k|t)$ tiene en cuenta la depreciación que sufren las baterías después de cada kWh cargado o descargado y la penalización provocada por el deterioro de las baterías asociado a los ciclos de carga y descarga. El lector interesado puede consultar (Llamas (2022)) para una descripción más detallada.

4. Predicción demanda

La predicción precisa de la demanda puede generar beneficios económicos y sociales significativos. El objetivo del modelo de optimización propuesto es facilitar el crecimiento de las tecnologías de vehículos eléctricos y su integración en los sistemas de energía, al mismo tiempo que sirve como un ejemplo de aplicación de la inteligencia artificial en los sistemas energéticos sostenibles.

Las técnicas de predicción se clasifican comúnmente según la longitud de la secuencia de entrada y el horizonte temporal de predicción. En este caso, al utilizar un horizonte temporal de 24 horas (24 valores), se considera un problema de predicción a medio-largo plazo.

4.1. Datos

Describimos a continuación el proceso de preparación de los datos de entrenamiento para poder ser usados en los modelos de predicción propuestos. Para realizar predicciones de la demanda de carga se utilizan datos públicos reales de sesiones de carga en una estación de la Universidad de Caltech, en Estados Unidos (Lee et al. (2019)).

Los datos disponibles en la citada base de datos contienen pormenorizados de sesiones de carga individuales. Por este motivo es necesario un preprocesamiento previo antes de ser utilizados por los algoritmos de predicción para disponer de series temporales de la demanda de carga horaria en la estación que incluyan la potencia media y energía intercambiada en cada franja horaria.

Inicialmente, se leen y se cargan los datos. Usando la hora de inicio y fin de la sesión se calcula el tiempo de duración. Posteriormente, se calcula la potencia media de la sesión de carga dividiendo la energía de la sesión entre el intervalo de tiempo. Se obtienen además el número de sesiones de carga concurrentes en cada franja de tiempo y la mediana de las potencias medias de dichas sesiones.

4.2. Modelos

La selección de una buena arquitectura de red es crucial para el desempeño de los algoritmos de predicción. Es por eso que se prueban distintas modelos con arquitecturas y con distintos tipos de redes neuronales.

Se proponen modelos de redes neuronales simples, recurrentes, con LSTM, convolucionales, bidireccionales y combinaciones de ellas. A continuación se detallan las distintas arquitecturas y se explica por qué se han escogido.

- Red neuronal simple, perceptrón multicapa (ANN) Las redes neuronales, como los Perceptrones Multicapa (MLP), tienen diversas capacidades. Son robustas al ruido en los datos y pueden aprender y predecir incluso en ausencia de algunos valores. Además, las redes neuronales pueden aprender relaciones lineales y no lineales, y admiten entradas multidimensionales con un número arbitrario de características. Sin embargo, en un MLP, se pierde la dimensión temporal de una secuencia de datos.
- Red neuronal recurrente (RNN): Las redes neuronales recurrentes tienen la capacidad de tener en cuenta la temporalidad de los datos. Es por ello que lo hace teóricamente un modelo más apropiado para un problema de predicción de series temporales.
- Red neuronal recurrente multicapa (st-RNN): Este modelo contará con dos capas apiladas de neuronas recurrentes. La secuencia de entrada al modelo pasa por la primera capa, que genera de nuevo otra secuencia que al pasar por la segunda obtiene un valor a su salida, que tras pasar por una neurona común, será la salida del valor futuro predicho.
- Red neuronal recurrente LSTM (LSTM): Este modelo es el mismo que el modelo RNN pero utilizando neuronas del tipo LSTM, que en principio deberían mejorar el funcionamiento del modelo al tener estas neuronas la capacidad de memorizar información pasada en secuencias más largas.
- Red neuronal recurrente LSTM multicapa (st-LSTM): Del mismo modo que se construyó la RNN-st, se construye una red neuronal recurrente multicapa con neuronas del tipo LSTM.
- Red neuronal recurrente bidireccional (Bi-LSTM): Para este modelo se utilizan neuronas del tipo recurrentes bidireccionales que podrán tener en cuenta valores del pasado y del futuro a la hora de calcular las activaciones de las neuronas.
- Red neuronal convolucional y LSTM (CNN+LSTM): La capacidad de las CNN para aprender y extraer automáticamente características de los datos de entrada puede aplicarse a los problemas de previsión de series temporales. En este modelo se utiliza una capa convolucional que genera una secuencia unidimensional que se pasa posteriormente por dos capas de neuronas recurrentes del tipo LSTM. Este modelo es el más complejo y es posible

que sea más adecuado para problemas de predicción más difíciles, en el que la dimensión de las secuencias de entrada sean mayores.

4.3. Resultados

Se entrenan los modelos para distintas longitudes de secuencias de entrada. Se compararán los resultados obtenidos para unas ventanas temporales de tamaño 96 y 168, es decir, ventanas temporales de 4 y 7 días respectivamente, recordando que los datos que se usan son horarios.

En la Tabla 1 se muestra la comparativa de los resultados de los distintos modelos con las distintas ventanas temporales.

El modelo clásico del perceptrón multicapa (ANN) con una ventana temporal de 168 valores obtuvo los peores resultados, mostrando dificultad para captar dependencias temporales en secuencias largas. En contraste, las redes LSTM demostraron una excelente capacidad para capturar patrones y memorizar información a largo plazo, logrando los mejores resultados con una ventana temporal de 96 valores.

En cuanto al tamaño de la ventana temporal, se observó un mejor rendimiento en modelos más simples como las redes recurrentes simples y las LSTM con una secuencia de entrada más pequeña. Sin embargo, en modelos más complejos como las redes bidireccionales o el modelo de convolución con LSTM, se prefirió utilizar ventanas temporales más grandes.

Se presentan los resultados de comparación de predicciones a 24 horas en las Figuras 2c y 2d. También se muestra el historial de entrenamiento del modelo de redes LSTM en la Figura 2a, junto con un ejemplo de predicciones consecutivas a 24 horas utilizando dicho modelo en la Figura 2b.

Se puede observar que el coste de entrenamiento ha ido disminuyendo de manera progresiva sin muchas oscilaciones, esto afirma que el optimizador elegido ha sido adecuado. Por otro lado, el coste de validación, aunque en algunos entrenamientos ha sido más inestable, se observa que ha ido disminuyendo conforme lo ha ido haciendo el coste de entrenamiento, esto significa que no está habiendo *overfitting* a los datos de entrenamiento y que, por tanto, el número de épocas elegido ha sido acertado.

5. Predicción generación

La energía solar fotovoltaica es una importante fuente de energía renovable que convierte la radiación solar en electricidad. Sin embargo, su producción está fuertemente influenciada por las condiciones meteorológicas, como las nubes y la temperatura.

Dado el crecimiento significativo de las plantas fotovoltaicas, es crucial aprender a gestionar su variabilidad inherente. Por lo tanto, la predicción de la energía solar fotovoltaica es una herramienta fundamental para garantizar un funcionamiento confiable y rentable de la red eléctrica. En este sentido, se propone utilizar modelos de Deep Learning con redes neuronales para abordar este problema de predicción.

A diferencia del enfoque anterior, en este caso se utiliza una entrada multidimensional. Los modelos se entrenarán con secuencias de variables múltiples que incluyen información tanto sobre los valores de producción pasados como sobre otras variables relacionadas con las condiciones meteorológicas.

Se proponen diferentes modelos con diversas arquitecturas de redes neuronales para realizar predicciones a largo plazo en un horizonte temporal de 24 horas. Este problema de predicción puede clasificarse como a medio-largo plazo debido al horizonte temporal utilizado.

En primer lugar, se realiza el preprocesamiento de los datos para el entrenamiento. Luego se seleccionan los modelos que se entrenarán y validarán. Finalmente, se realizan pruebas con los modelos entrenados y se analizan los resultados obtenidos.

5.1. Datos

Se utilizan datos históricos reales de una planta fotovoltaica experimental ubicada en la Escuela Técnica Superior de Ingeniería en Sevilla para entrenar a los modelos de predicción.

Los datos se cargan utilizando Matlab. Para los días en los que no se han podido recoger datos debido a fallos en los sensores o mantenimientos, se ha copiado el día anterior para no dejar huecos grandes en la serie temporal. Tampoco se han eliminado directamente para no perder la temporalidad de los datos.

En este apartado se aborda el procesamiento de los datos y la transformación de los mismos para tener la estructura necesaria y así puedan ser alimentados a los modelos para ser entrenados.

5.1.1. Preprocesamiento

Los datos originales de la planta fotovoltaica se muestrean cada 5 segundos. Después de un procesamiento inicial en Matlab, el tiempo de muestreo se cambia a 5 minutos.

En primer lugar, se realiza un filtrado de valores atípicos para las variables de temperatura, presión y humedad. Se eliminan los datos por encima del cuantil 85 y por debajo del cuantil 15. Además, se abordan los datos vacíos que pueden ser causados por fallas en los sensores o mantenimiento. Estos datos se reconstruyen copiando los valores vecinos previos disponibles.

Finalmente, se realiza el remuestreo de los datos, tomando el valor medio de los datos consecutivos en intervalos de una hora, lo que se convierte en el nuevo tiempo de muestreo.

Finalmente, se muestran los datos una vez han sido procesados en la Figura 3.

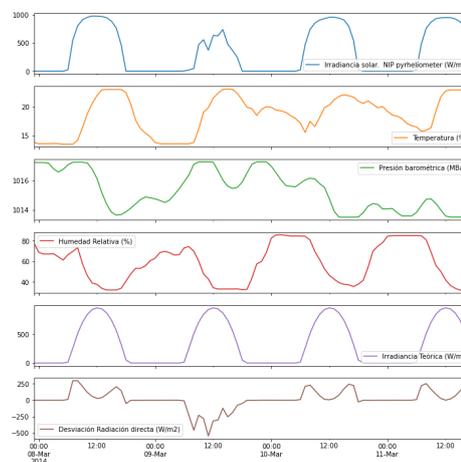
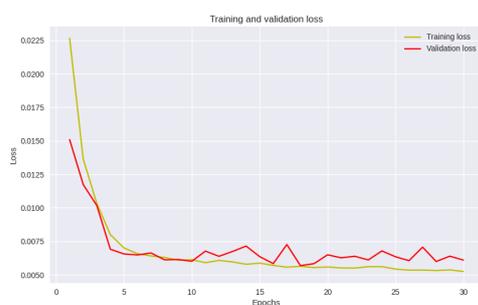


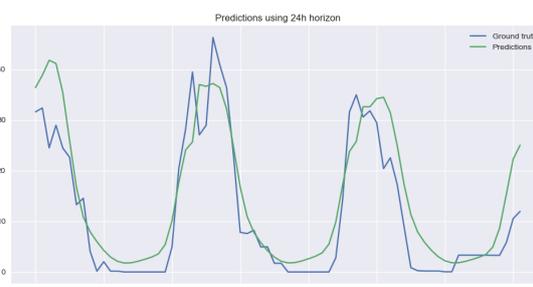
Figura 3: Datos procesados.

Tabla 1: Comparación de los modelos de predicción de demanda eléctrica en la estación

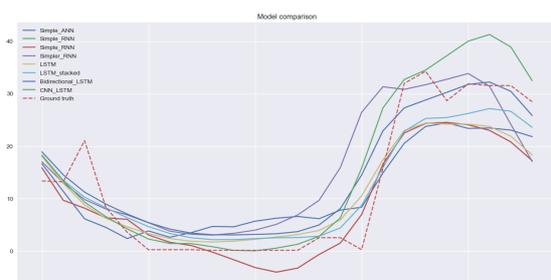
w_size	Métricas	ANN	RNN	st-RNN	LSTM	st-LSTM	Bi-LSTM	CNN + LSTM
96	RMSE train (kW)	4.46	4.20	4.27	4.09	4.03	4.15	4.17
	RMSE test (kW)	4.62	4.30	4.25	4.10	4.07	4.23	4.23
	MAE train (kW)	3.10	2.94	2.99	2.69	2.69	2.83	2.84
	MAE test (kW)	3.21	3.09	2.93	2.66	2.70	2.86	2.88
168	RMSE train (kW)	4.51	4.22	4.21	4.05	4.07	3.93	4.08
	RMSE test (kW)	4.72	4.39	4.35	4.12	4.13	3.96	4.08
	MAE train (kW)	3.40	2.85	2.95	2.72	2.70	2.72	2.76
	MAE test (kW)	3.59	2.86	3.06	2.73	2.68	2.68	2.75



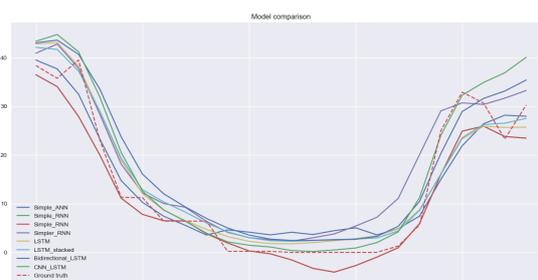
(a) Historial de entrenamiento del modelo LSTM



(b) Resultados de varias predicciones consecutivas con horizonte de 24h



(c) Comparación de predicciones con horizonte de 24h



(d) Comparación de predicciones con horizonte de 24h

Figura 2: Resultados de entrenamiento (a) con predicciones (b) del modelo LSTM y comparación de predicciones (c, d).

6. Modelos

Los modelos que se plantean para la solución al problema de predicción de la generación fotovoltaica son los mismos que se propusieron en el apartado anterior en la predicción de la demanda de carga, pero cambiando las dimensiones de la secuencia de entrada. Así, mientras que en el apartado anterior se consideraban secuencias monovariadas, en éste son multivariadas.

Las entradas (x) consistirán en secuencias que incluyen datos de las siguientes variables: irradiancia solar (W/m^2), temperatura ($^{\circ}C$), humedad relativa (%), presión barométrica (MBar) e irradiancia teórica (W/m^2).

Y las salidas o etiquetas (y) a predecir serán los datos de la variable: "Irradiancia solar. NIP pyrheliometer (W/m^2)"

Los hiperparámetros clave a ajustar son la longitud de la secuencia de entrada y la complejidad de los modelos. Se proponen diversas arquitecturas para entrenar y validar con diferentes tamaños de ventana temporal. Se compararán los modelos con distintos tamaños de ventana para encontrar la solución con las mejores predicciones.

6.1. Resultados

Se entrenan modelos con diferentes longitudes de secuencias de entrada: ventanas de 24 y 96 valores, equivalentes a 1 y 4 días respectivamente. La ventana de 168 valores se descarta debido a problemas de convergencia y un rendimiento inferior.

En la Tabla 2 se muestra la comparativa de los resultados de los distintos modelos con las distintas ventanas temporales. El modelo que ha obtenido los peores resultados ha sido el modelo RNN con una ventana temporal de 96.

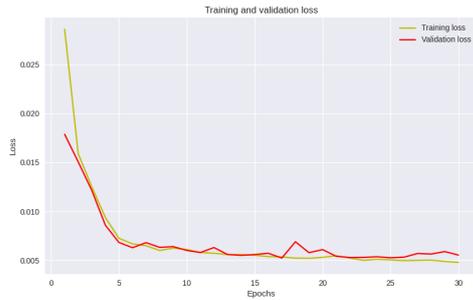
El modelo que ha obtenido los mejores resultados ha sido el formado por las redes CNN+LSTM, con una ventana temporal de 24 valores.

Respecto al tamaño la ventana temporal se puede afirmar que, en general, los modelos han obtenido mejores resultados utilizando ventanas temporales de menor tamaño.

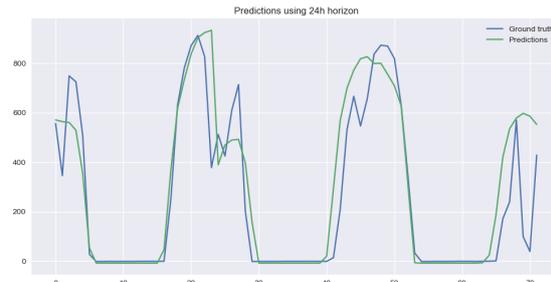
Se muestra el historial del entrenamiento del modelo de redes CNN+LSTM en la Figura 4a, así como un ejemplo del resultado de varias predicciones consecutivas con horizonte de 24h usando dicho modelo (Figuras 4c y 4d). También se muestran los resultados de una comparación de predicciones con horizonte de 24h en la Figura 4b.

Tabla 2: Comparación de los modelos de predicción de generación fotovoltaica

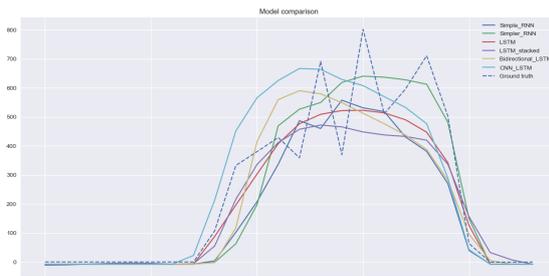
w_size	Métricas	RNN	st-RNN	LSTM	st-LSTM	Bi-LSTM	CNN + LSTM
24	RMSE train (kW)	94.21	92.71	99.78	100.67	94.69	96.28
	RMSE test (kW)	114.98	117.32	108.25	109.89	105.44	104.61
	MAE train (kW)	47.31	52.60	51.44	56.38	49.50	49.00
	MAE test (kW)	60.37	64.45	58.55	62.82	56.06	55.60
96	RMSE train (kW)	94.49	-	103.08	101.40	97.26	96.30
	RMSE test (kW)	119.57	-	107.35	115.08	108.44	110.75
	MAE train (kW)	50.88	-	53.04	57.09	55.40	52.00
	MAE test (kW)	67.46	-	58.01	69.35	61.05	62.35



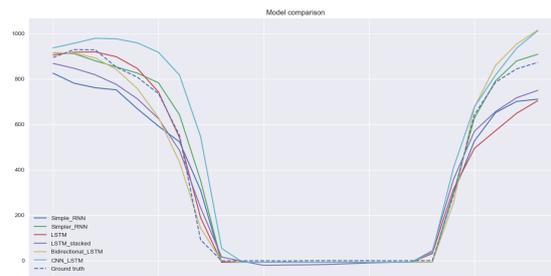
(a) Historial de entrenamiento del modelo CNN+LSTM



(b) Resultados de varias predicciones consecutivas con horizonte de 24h



(c) Comparación de predicciones con horizonte de 24h



(d) Comparación de predicciones con horizonte de 24h

Figura 4: Resultados de entrenamiento (a) con predicciones (b) del modelo CNN+LSTM y comparación de predicciones (c, d).

7. Conclusiones

Se ha podido comprobar que los modelos basados en Deep Learning son capaces de captar de manera efectiva la característica no lineal de los datos y las correlaciones temporales para predecir la demanda de carga y la generación fotovoltaica.

En trabajo futuro, se propone utilizar nuevas bases de datos, incorporando más información, como el día de la semana, tiempo meteorológico, etc. También se propone utilizar modelos espacio-temporales, que tengan en cuenta la localización de la estación y el tráfico para crear modelos más complejos que obtengan predicciones más precisas.

Agradecimientos

Los autores quieren expresar su agradecimiento al Ministerio de Ciencia e Innovación y a la Agencia Estatal de Investigación por financiar este trabajo bajo los proyectos a los proyectos TED2021-131604B-I00 y PID2020-115561RB-C32.

Referencias

- Hüttel, F. B., Peled, I., Rodrigues, F., Pereira, F. C., 2021. Deep spatio-temporal forecasting of electrical vehicle charging demand. arXiv preprint arXiv:2106.10940.
- Kim, Y., Kim, S., 2021. Forecasting charging demand of electric vehicles using time-series models. *Energies* 14 (5), 1487.
- Lee, Z. J., Li, T., Low, S. H., Jun. 2019. ACN-Data: Analysis and Applications of an Open EV Charging Dataset. In: *Proceedings of the Tenth International Conference on Future Energy Systems. e-Energy '19*.
- Llamas, A. L., 2022. In: *Optimización de carga de vehículos eléctricos con asistencia solar fotovoltaica y almacenamiento de energía*.
- Shahriar, S., Al-Ali, A.-R., Osman, A. H., Dhoh, S., Nijim, M., 2021. Prediction of ev charging behavior using machine learning. *IEEE Access* 9, 111576–111586.
- Shakeel, F. M., Malik, O. P., 2019. Vehicle-to-grid technology in a micro-grid using dc fast charging architecture. 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), 1–4.
- Zhu, J., Yang, Z., Chang, Y., Guo, Y., Zhu, K., Zhang, J., 2019. A novel lstm based deep learning approach for multi-time scale electric vehicles charging load prediction. In: *2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia)*. IEEE, pp. 3531–3536.