

Mantenimiento óptimo de activos: aerogeneradores.

Predicción de potencia eléctrica en turbinas de viento a partir de redes neuronales con información física y cuantificación de la incertidumbre



**UNIVERSIDAD
DE GRANADA**

04/12/2024



IA4TES

INTELIGENCIA ARTIFICIAL

PARA LA

TRANSICIÓN ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL

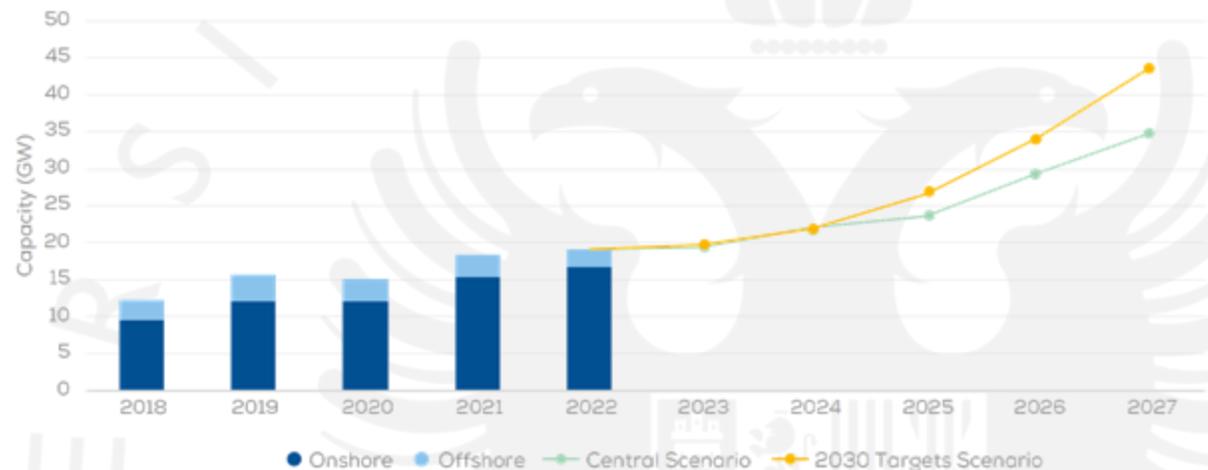


Plan de Recuperación,
Transformación
y Resiliencia

1. Contexto

- Según numerosas agencias y empresas internacionales, las energías renovables (y en concreto **la eólica**) **están creciendo a un buen ritmo**.
- En este escenario, es crucial optimizar las operaciones de las turbinas de viento y desarrollar métodos automáticos de diagnóstico de fallos.
- A día de hoy, **no hay modelos físicos fiables** para calcular la potencia generada por turbinas a partir de la energía cinética del viento.
- En la **era del Big Data y la Inteligencia Artificial**, los modelos basados en datos ofrecen nuevas oportunidades.
- Este tipo de modelos, aunque prometedores, todavía tienen **retos por resolver**, como la falta de **explicabilidad o la cuantificación de la incertidumbre**.

New installations in Europe – WindEurope's scenarios



Source: WindEurope

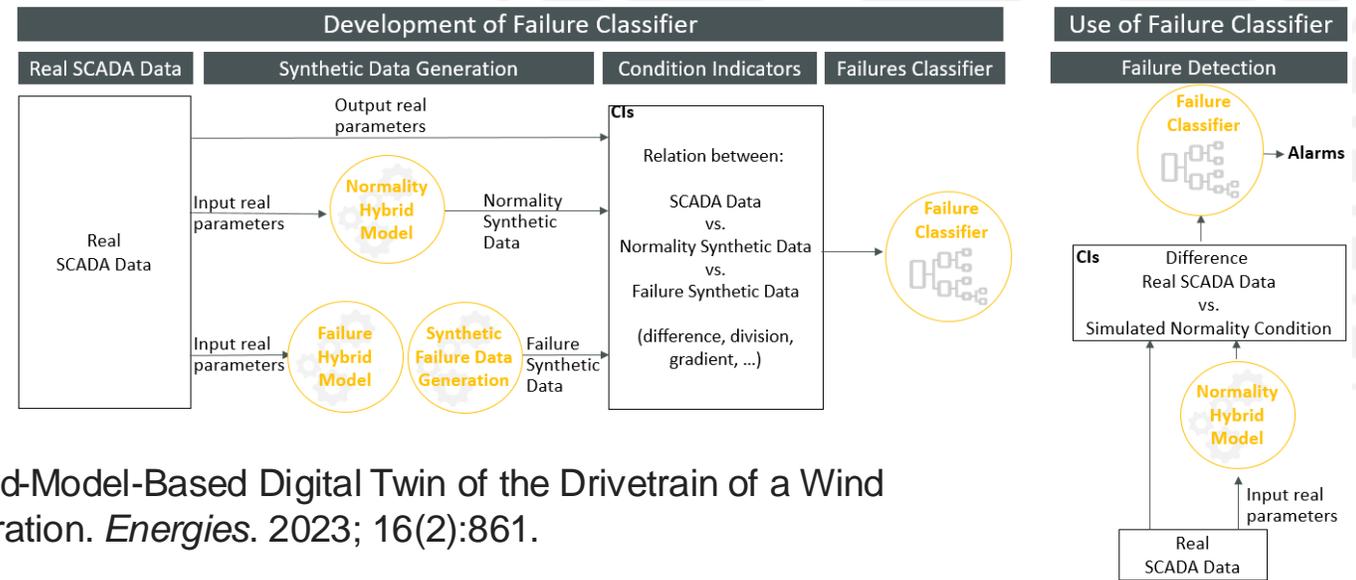
1. Contexto

- Con respecto a la explicabilidad, los **modelos híbridos** (utilizan datos y principios físicos) están ganando popularidad.

- Ecuaciones de estado: $P = gT\omega$, $P = \frac{1}{2}C_p\rho Av^3$.

- Fórmula empírica: $C_p(\lambda, \beta) = c_0(c_1\gamma - c_2\beta - c_3\beta^{c_4} - c_5)e^{-c_6\gamma} + c_7\lambda$, $\gamma = \frac{1}{\lambda + d_0\beta + d_1} - \frac{d_2}{1 + \beta^3}$.

- Tecnia tiene un modelo físico basado en estas ecuaciones y han desarrollado un método estadístico de generación de datos sintéticos para clasificación de fallos.



Pujana A, Esteras M, Perea E, Maqueda E, Calvez P. Hybrid-Model-Based Digital Twin of the Drivetrain of a Wind Turbine and Its Application for Failure Synthetic Data Generation. *Energies*. 2023; 16(2):861.

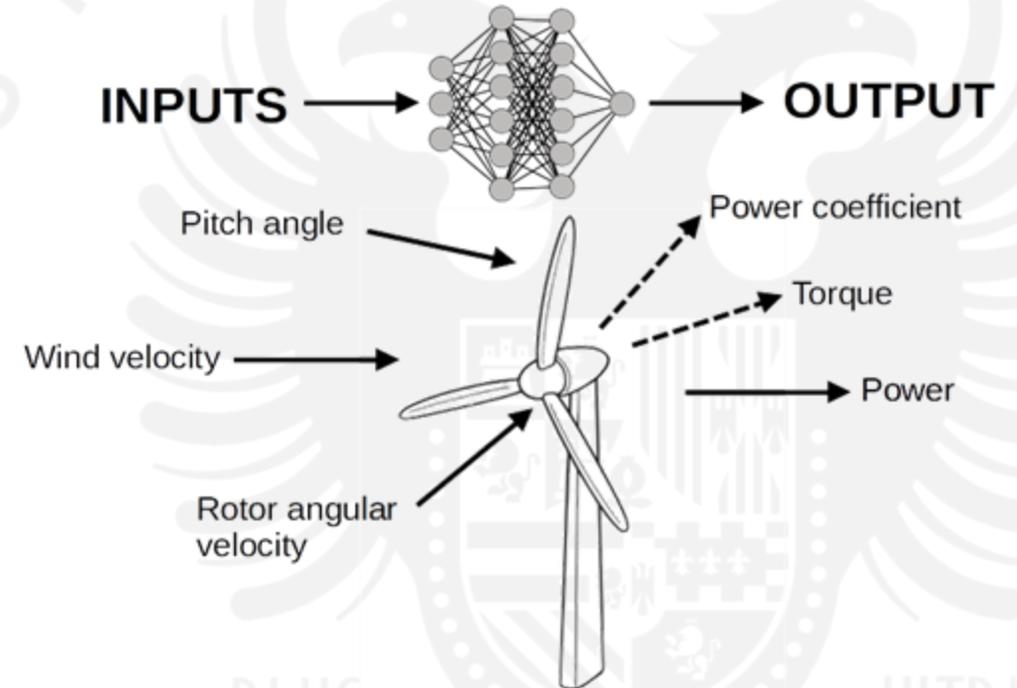
<https://doi.org/10.3390/en16020861>

1. Contexto

- Desde la UGR, proponemos un **modelo basado en redes neuronales** para predecir directamente potencia P , u obtenerla a partir de variables intermedias como torque T o coeficiente de potencia C_p .
- Requisitos del modelo:
 - Suficiente **flexibilidad** para predecir los datos de forma precisa.
 - **Robustez y transferibilidad**. Respetar las leyes físicas subyacentes.
 - **Cuantificar incertidumbre** de predicciones.

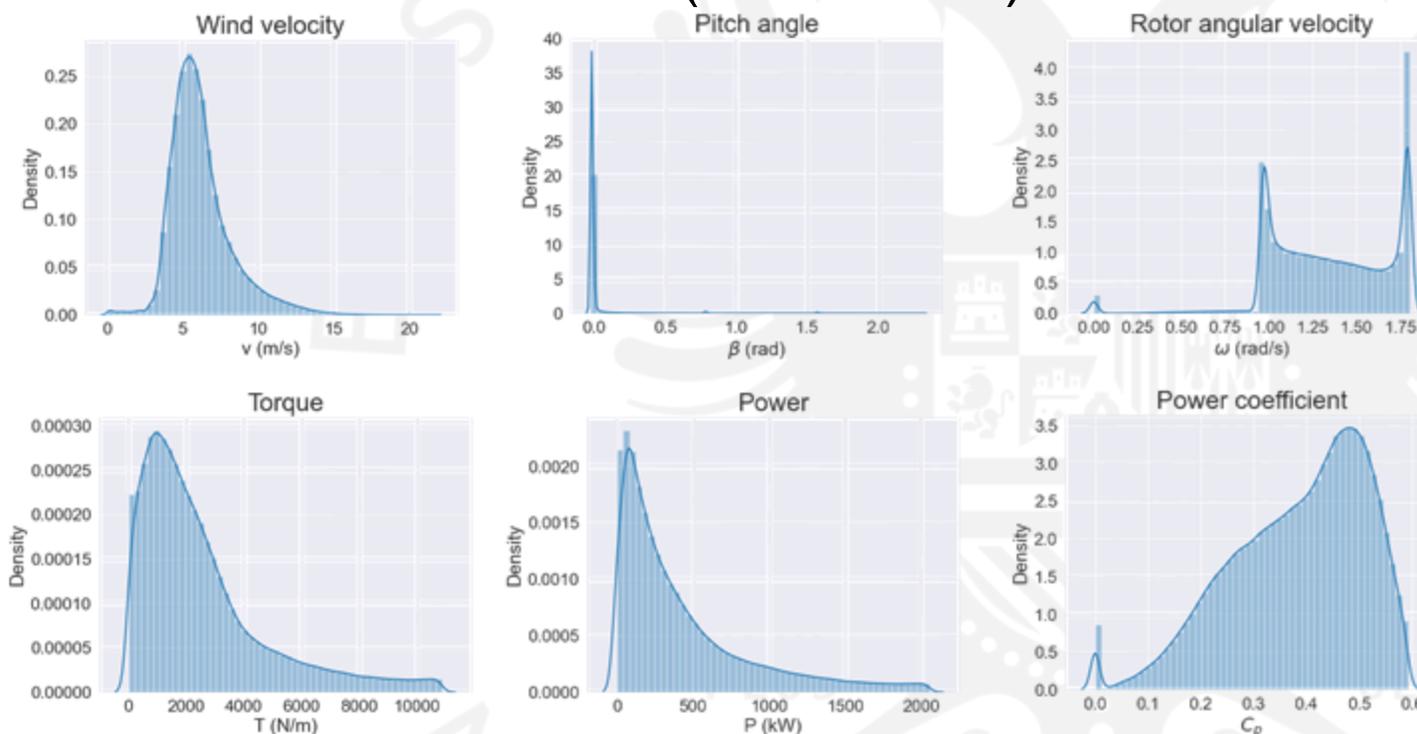
Gijón, A., Pujana-Goitia, A., Perea, E., Molina-Solana, M., & Gómez-Romero, J. (2023). Prediction of wind turbines power with physics-informed neural networks and evidential uncertainty quantification. <https://arxiv.org/abs/2307.14675>

Código disponible: https://github.com/alfonsogijon/WindTurbines_PINNs



2. Datos y definición del problema

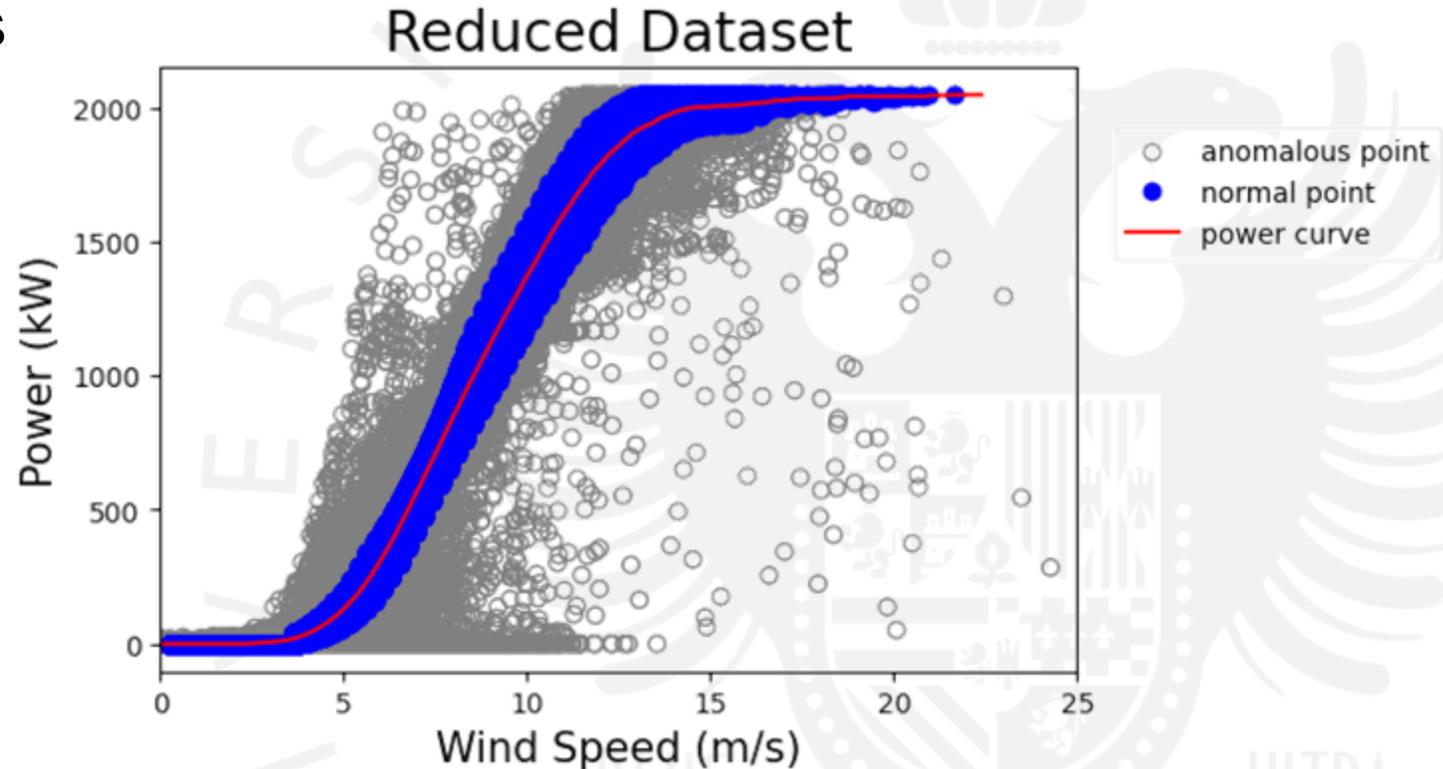
- **Dataset open-source** de 4 turbinas MM82 del parque eólico "La Haute Borne" de [Engie](#).
- **80 variables SCADA** monitorizadas durante 8 años (2013-2020).
- Nos centramos en las 5 variables (v, β, w, T, P) y C_p .



P : generated power
 C_p : power coefficient
 ρ : air density
 A : area swept by the blades
 v : wind speed
 T : torque
 ω : angular velocity

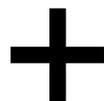
2. Datos y definición del problema

- **Preprocesamiento** de los datos eliminando puntos anómalos.
- **Criterios** de eliminación:
 - $C_p > 0.5926$
 - $|P - P_{median}| > 3\sigma$
 - $P > 25 \text{ kW}$ con $v < 3.5 \text{ m/s}$
- Pasamos de 1 millón a 700000 datos, un **70%**.



3. Redes neuronales con información física (PINNs)

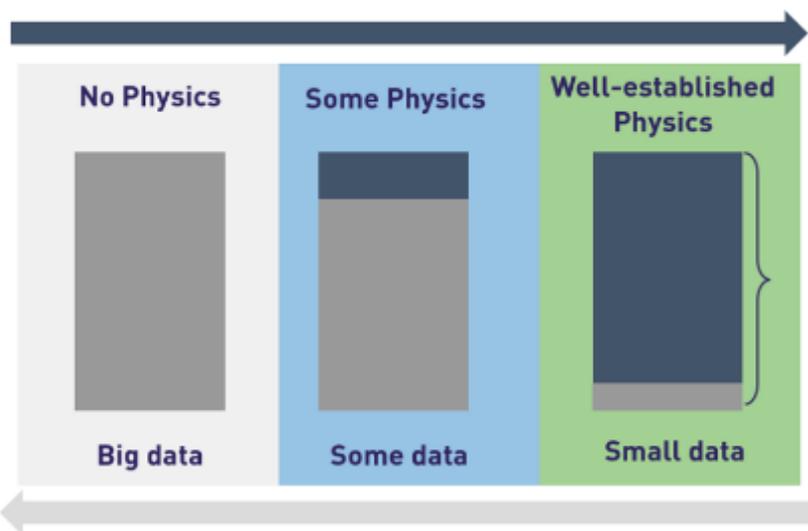
DATOS



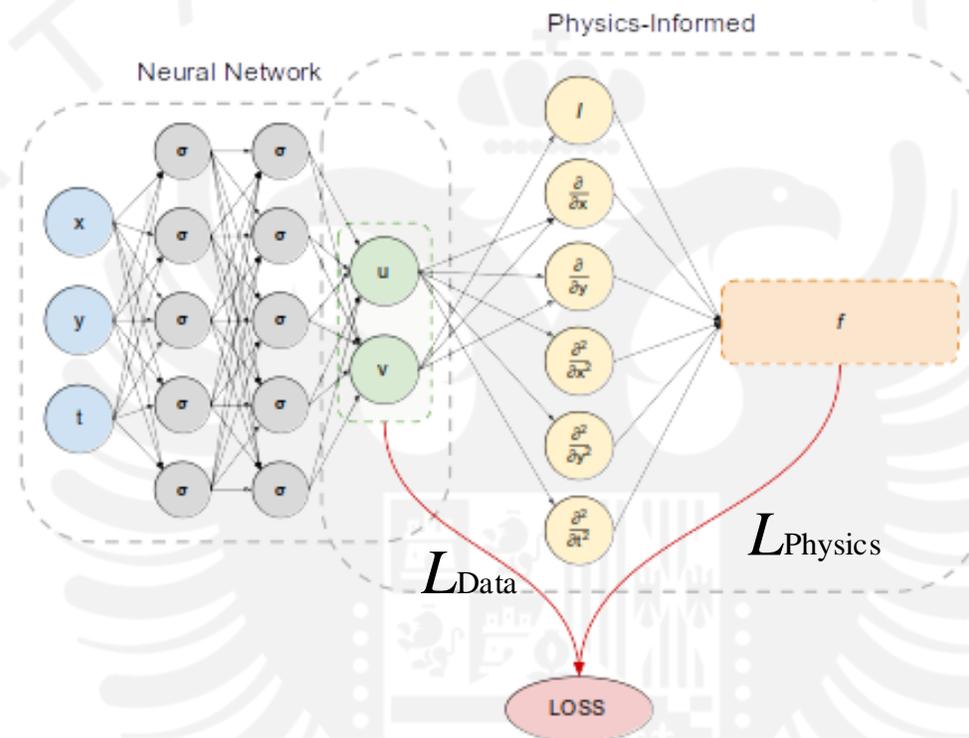
FÍSICA

(simetrías, leyes de conservación, ecuaciones dinámicas, condiciones de contorno...)

Data-driven



Physics-based



$$L = L_{\text{Data}} + L_{\text{Physics}}$$



INTELIGENCIA ARTIFICIAL
PARA LA TRANSICIÓN
ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL



Plan de Recuperación,
Transformación
y Resiliencia

3. Métodos: PINNs y capas de incertidumbre

- Utilizando (v, β, w) como inputs podemos construir **modelos de regresión** de los outputs $\{P, C_p, T\}$:

Target P	Target C_p	Target T
$L_{\text{data}} = \frac{1}{N} \sum_{i=1}^N \text{NN}_i - P_i ,$ $L_{\text{phys}} = \frac{1}{N} \sum_{i=1}^N \text{NN}_i - gT_i\omega_i .$	$L_{\text{data}} = \frac{1}{N} \sum_{i=1}^N \text{NN}_i - C_{p,i} ,$ $L_{\text{phys}} = \frac{1}{N} \sum_{i=1}^N \left \text{NN}_i - \frac{2gT_i\omega_i}{\rho A v_i^3} \right .$	$L_{\text{data}} = \frac{1}{N} \sum_{i=1}^N \text{NN}_i - T_i ,$ $L_{\text{phys}} = \frac{1}{N} \sum_{i=1}^N \left \text{NN}_i - \frac{P_i}{g\omega_i} \right .$

- La **incertidumbre del output** es estimada con una capa evidencial final: $(y, \Delta y)$.

P : generated power
 C_p : power coefficient
 ρ : air density
 A : area swept by the blades
 v : wind speed
 T : torque
 ω : angular velocity

Target: $y \sim \mathcal{N}(\mu, \sigma^2)$

$$\mu \sim \mathcal{N}(\gamma, \sigma^2, \nu^{-1}),$$

$$\sigma^2 \sim \Gamma^{-1}(\alpha, \beta),$$

$$L(x) = L^{\text{NLL}}(x) + \lambda L^{\text{EL}}(x).$$

Maximiza predicción

Minimiza la incertidumbre



INTELIGENCIA ARTIFICIAL
PARA LA TRANSICIÓN
ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL



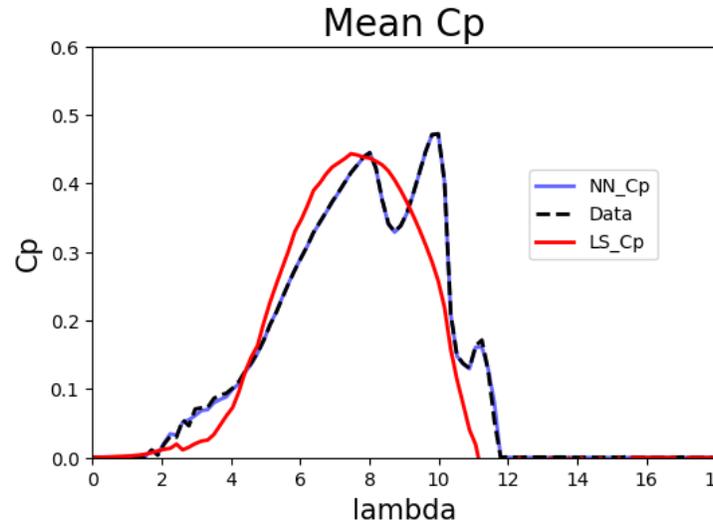
Plan de Recuperación,
Transformación
y Resiliencia

3. PINNs: Resultados

Red Neuronal 

Modelo empírico óptimo 

$$C_p(\lambda, \beta) = c_0(c_1\gamma - c_2\beta - c_3\beta^{c_4} - c_5)e^{-c_6\gamma} + c_7\lambda$$



	LS_Cp	NN_Cp
MAE (kW)	113.196	15.341
RMSE (kW)	167.893	27.770
MAPE (%)	37.65	3.63
R2	0.8570	0.9961

NNs y PINNs reproducen bien datos y la física:
MAPE < 4%, MAE < 16 kW

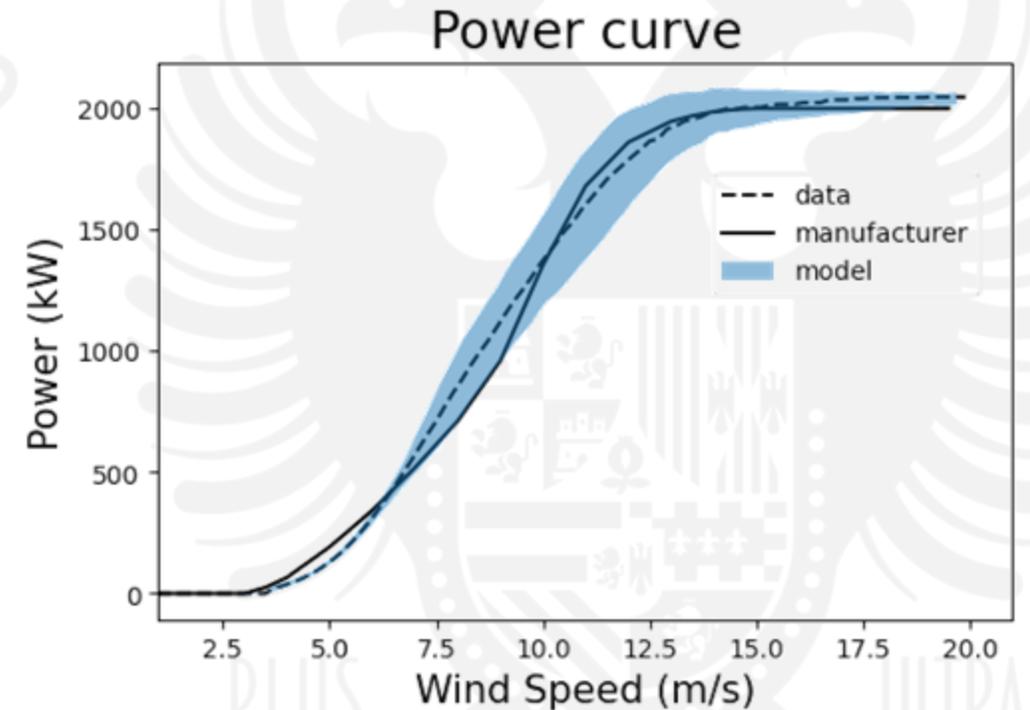
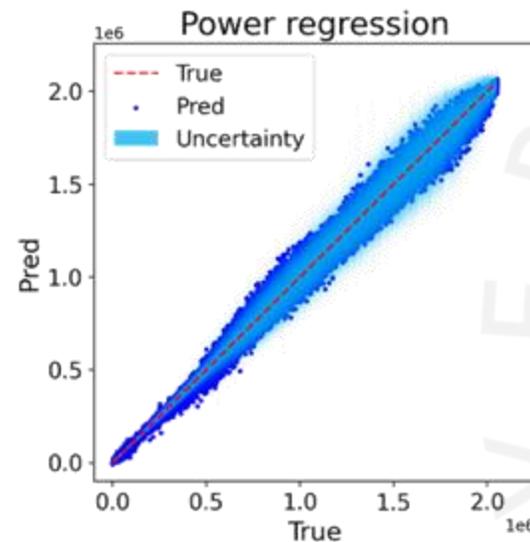
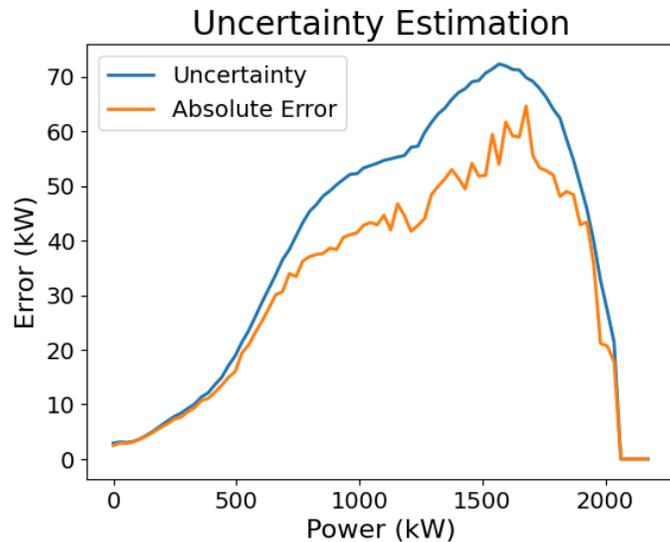
	NN_Cp		PINN_Cp		NN_T		PINN_T		NN_P		PINN_P	
	Data	Phys	Data	Phys	Data	Phys	Data	Phys	Data	Phys	Data	Phys
MAE (kW)	15.341	15.122	15.375	14.513	15.797	14.399	15.431	14.601	15.363	15.173	15.545	14.543
RMSE (kW)	27.770	27.856	27.940	26.967	28.511	26.901	27.898	27.144	27.785	27.967	28.016	26.946
MAPE (%)	3.63	3.63	3.70	3.40	3.92	3.33	3.72	3.37	3.64	3.63	3.84	3.44
R2	0.9961	0.9962	0.9960	0.9964	0.9959	0.9964	0.9960	0.9963	0.9961	0.9961	0.9960	0.9964

P , C_p y T sirven como variables outputs.

3. PINNs: Resultados

Estimaciones de incertidumbre consistentes con error real.
 $\Delta \geq \text{MAE}$

Curva de potencia consistente con dataset y especificaciones de fabricación



3. PINNs: Conclusiones

- Hemos **diseñado y validado modelos predictivos** de la potencia generada por turbinas de viento a partir de velocidad del viento, ángulo de pitch y velocidad angular del rotor, entrenados con datos históricos de 4 turbinas.
- Los modelos empíricos parametrizados no reproducen bien los datos, mientras que las **redes neuronales son capaces de capturar con precisión las relaciones no lineales** entre output e input.
- Las **PINNs** nos permiten **aprender a la vez de los datos y de las leyes físicas** del sistema.
- El uso de capas **evidenciales permite cuantificar la incertidumbre** asociada a las predicciones y definir intervalos de confianza en la curva de potencia, alcanzándose un buen acuerdo con las especificaciones del fabricante.
- Los modelos desarrollados son **robustos** y útiles para **detección de anomalías**. Además, al ser completamente derivables, también pueden ser utilizados para construir **controladores del ángulo de pitch**.
- Estos modelos, preentrenados sobre un dataset concreto, podrían ser **transferidos** a datos provenientes de otros fabricantes, con la ventaja de que ya respetan la física subyacente.

Pero no sólo eso...



INTELIGENCIA ARTIFICIAL
PARA LA TRANSICIÓN
ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL



Plan de Recuperación,
Transformación
y Resiliencia

Propuesta adicional: Hybrid Semi-Parametric Model

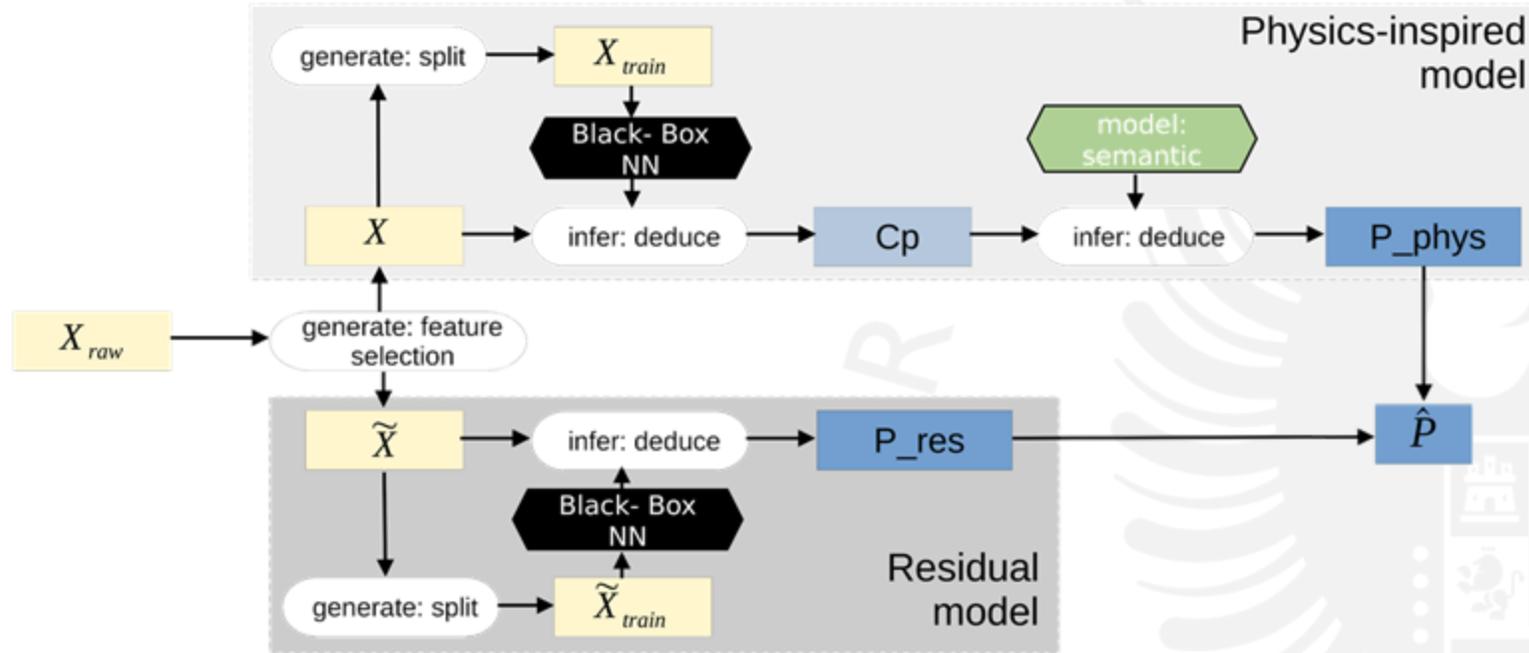
Para superar las deficiencias de los modelos de caja negra basados en datos y los modelos físicos.

Híbrido, basado en física y orientado a datos (entrenable).

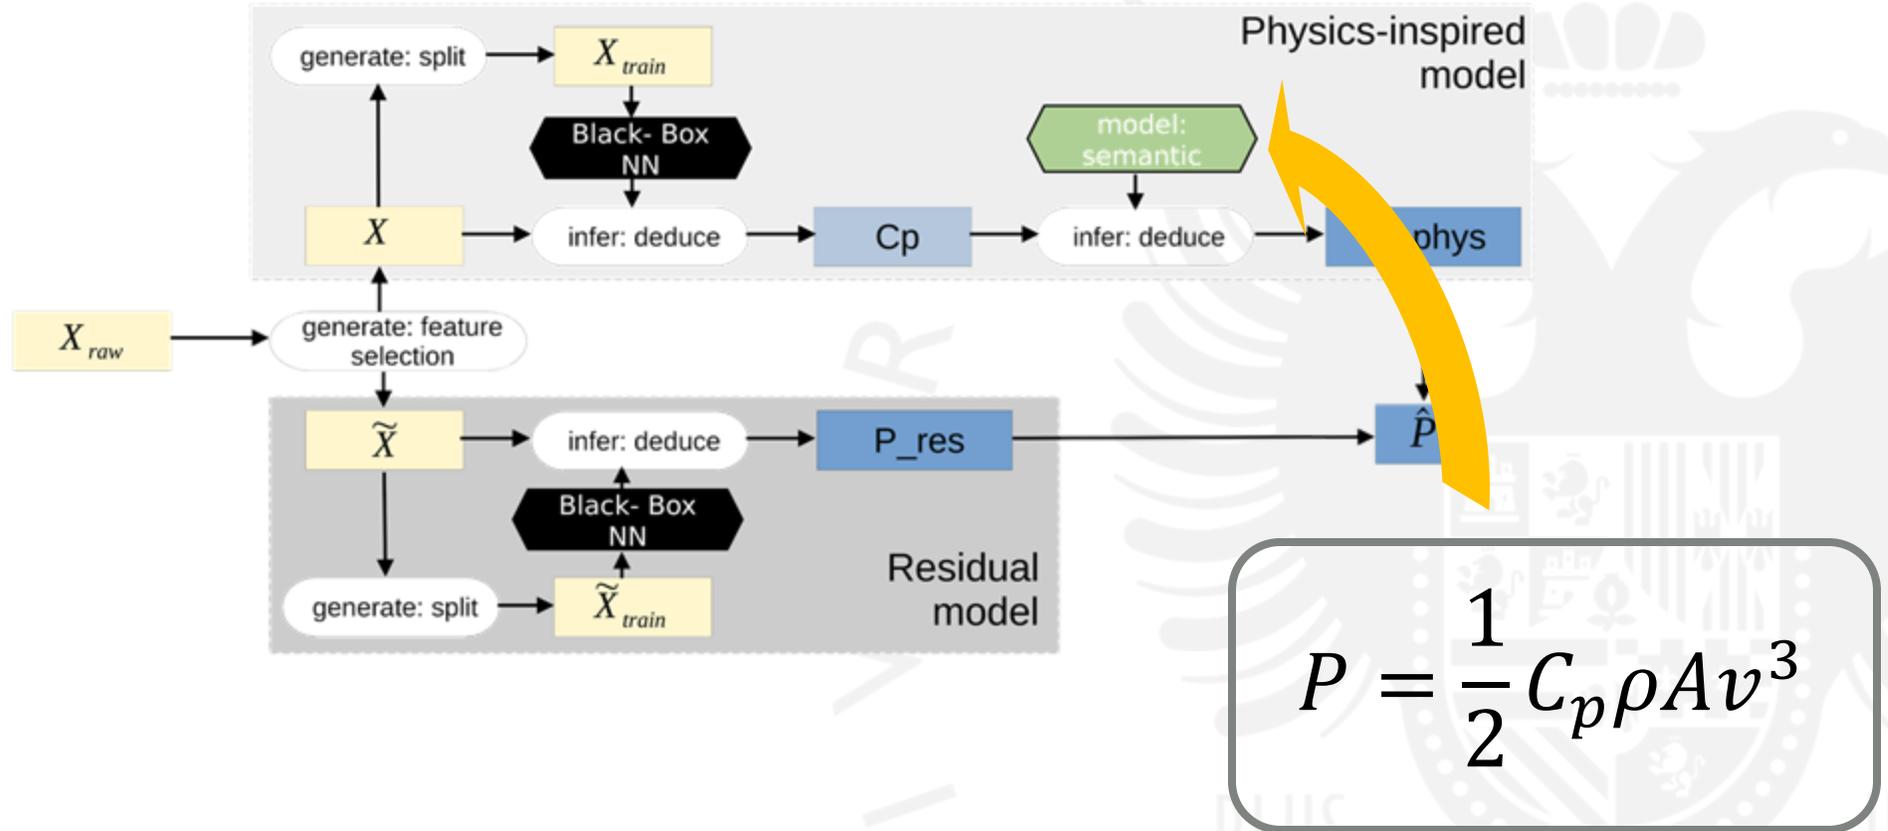
Semi-paramétrico, porque es un conjunto de dos modelos: uno no paramétrico y uno paramétrico.

Gijón, A., Eiraudó, S., Manjavacas, A., Bottaccioli, L., Lanzini, A., Molina-Solana, M., Gómez-Romero, J. (2024). *Explainable hybrid semi-parametric model for prediction of power generated by wind turbines*. Int. Conf. Computational Science (ICCS 2024) http://doi.org/10.1007/978-3-031-63775-9_21

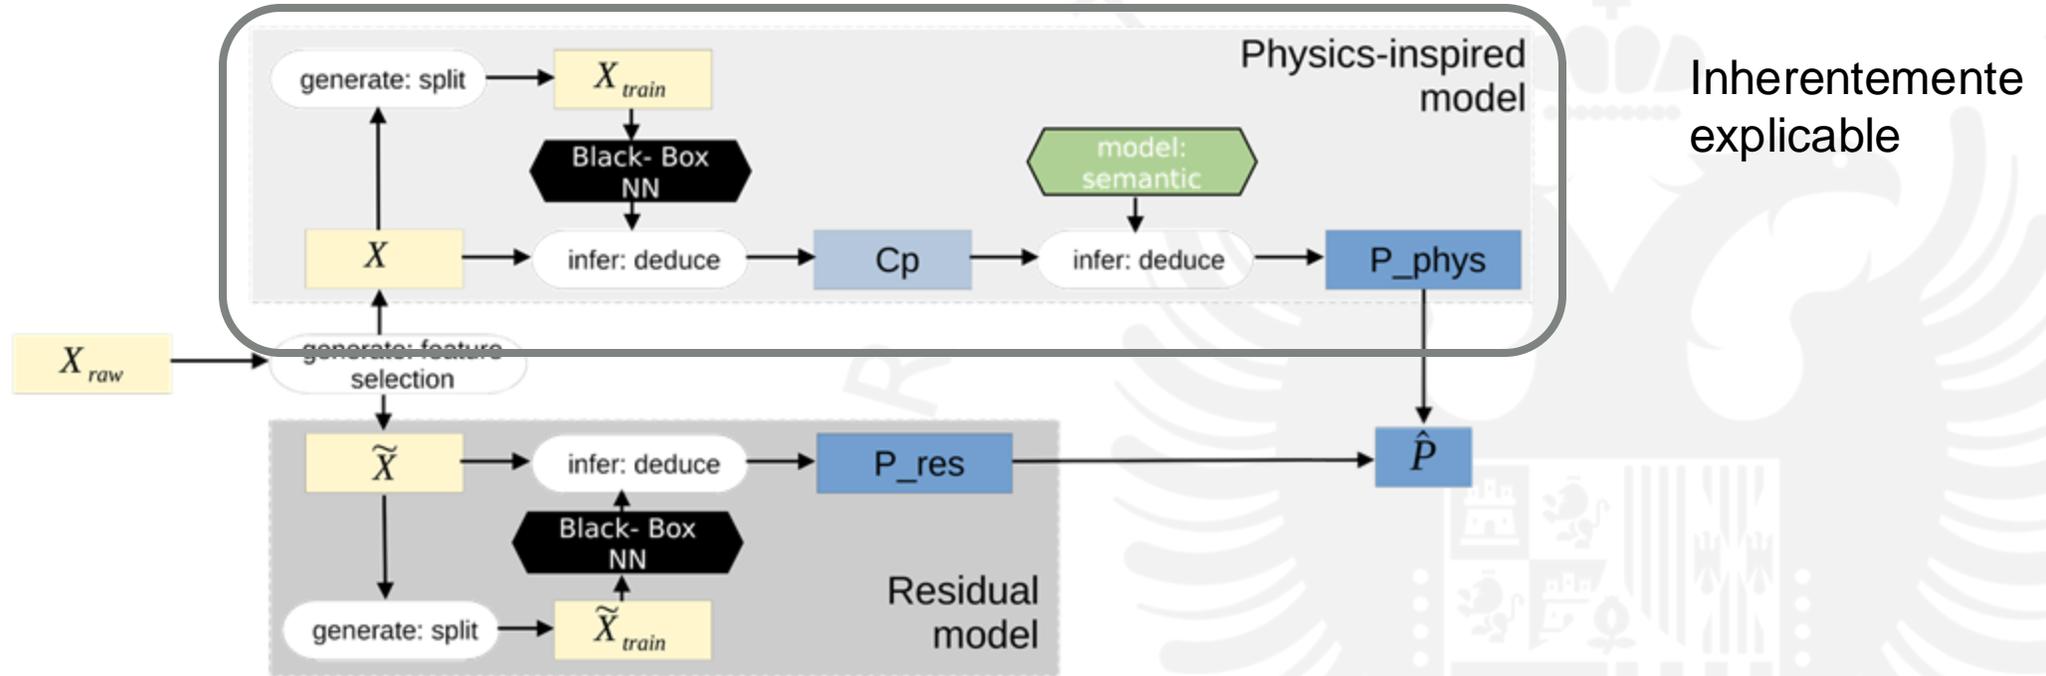
Propuesta adicional: Hybrid Semi-Parametric Model



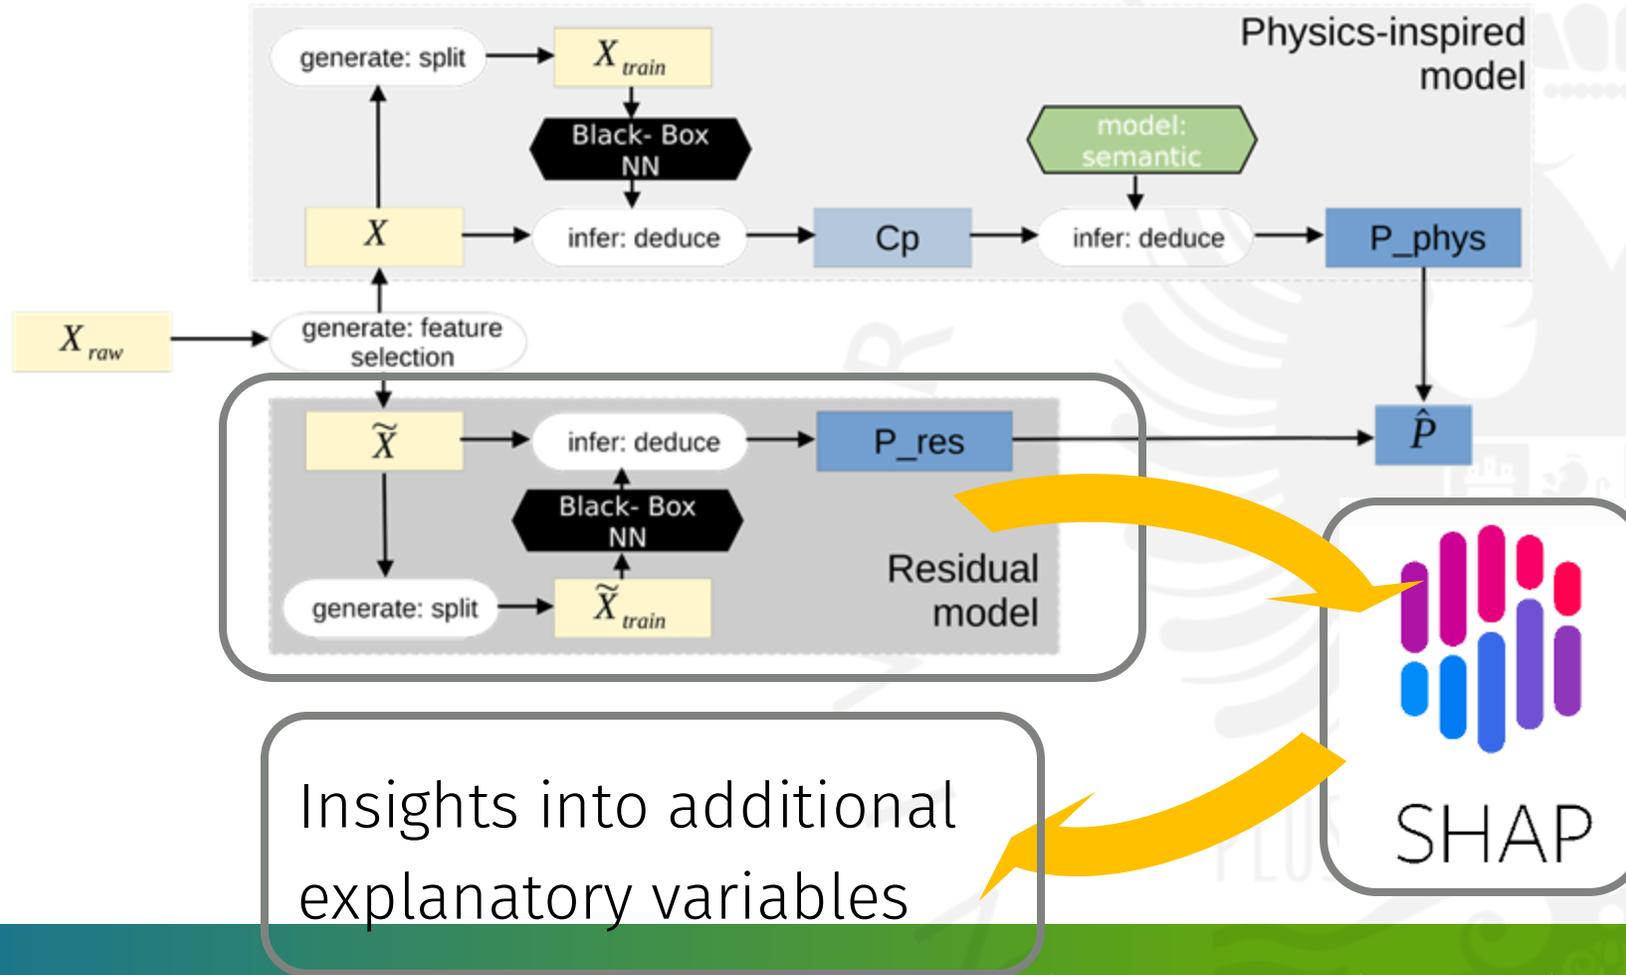
Propuesta adicional: Hybrid Semi-Parametric Model



Propuesta adicional: Hybrid Semi-Parametric Model



Propuesta adicional: Hybrid Semi-Parametric Model



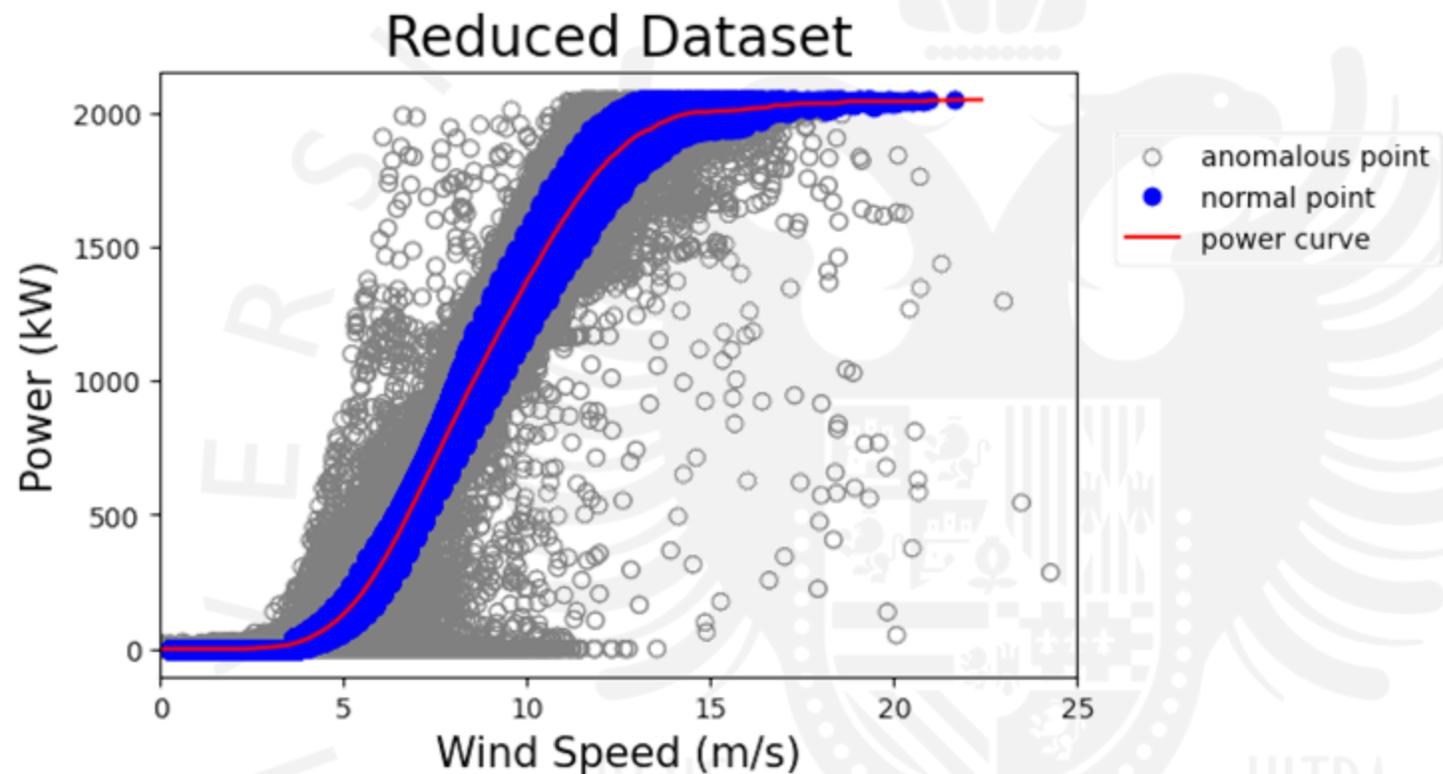
Hybrid Semi-Parametric Model: Dataset

Mismo dataset

4 turbines located in “La Haute Borne” wind farm.

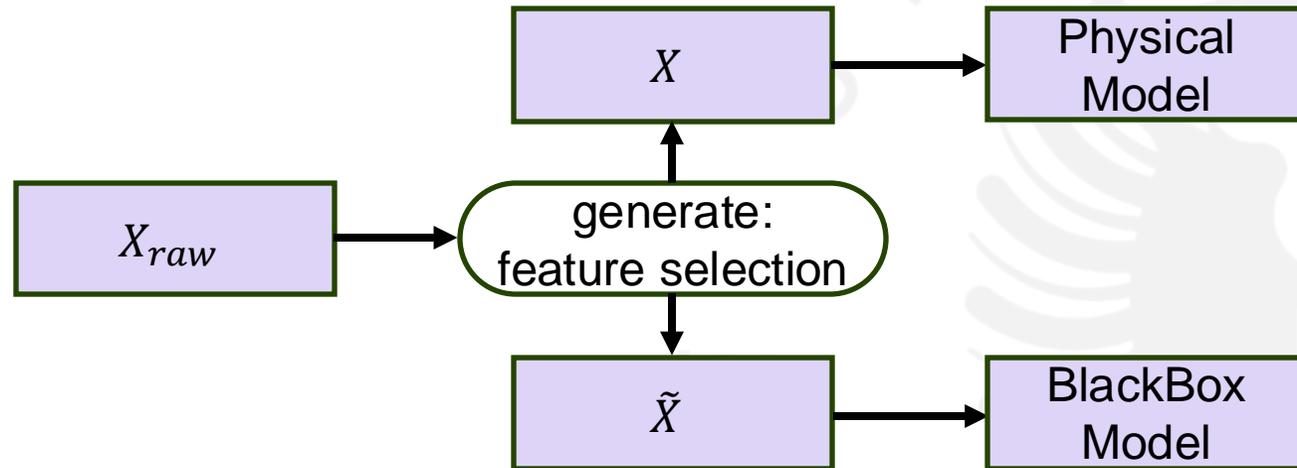
Time Resolution: 10 minutes
Data collected between 2013 and 2020

The dataset contains data from the turbines and weather data.



Hybrid Semi-Parametric Model: Resultados

Inputs are defined for the physical model and the non-parametric model in a feature selection step.



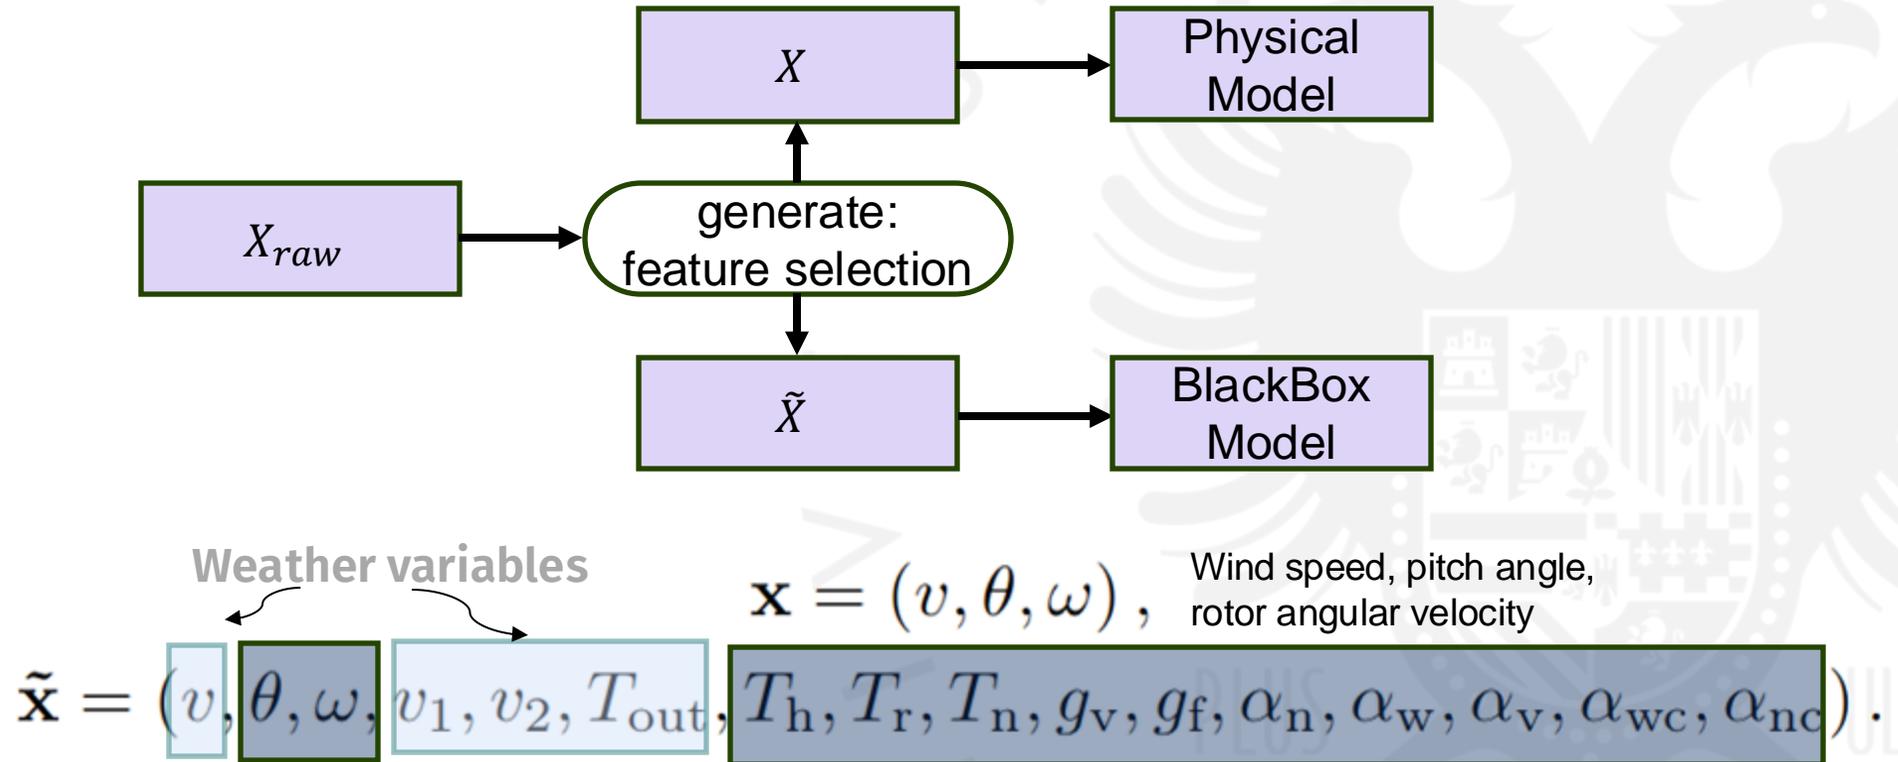
$$\mathbf{x} = (v, \theta, \omega), \quad \text{Wind speed, pitch angle, rotor angular velocity}$$

$$\tilde{\mathbf{x}} = (v, \theta, \omega, v_1, v_2, T_{\text{out}}, T_h, T_r, T_n, g_v, g_f, \alpha_n, \alpha_w, \alpha_v, \alpha_{wc}, \alpha_{nc}).$$



Hybrid Semi-Parametric Model: Resultados

Inputs are defined for the physical model and the non-parametric model in a feature selection step.



Hybrid Semi-Parametric Model: Resultados

Both the parametric submodel and the parametric one are implemented by means of Feed-Forward Neural Networks (FFNN) in Keras and hyperparameters are optimized.

Physics-inspired submodel:

- FFNN 1:
 - 3 variables input layer
 - 2-layer architecture
 - Units per layer: 128
 - Learning rate: 0.001
 - Activation: ReLU
- Semantic model

Residuals submodel:

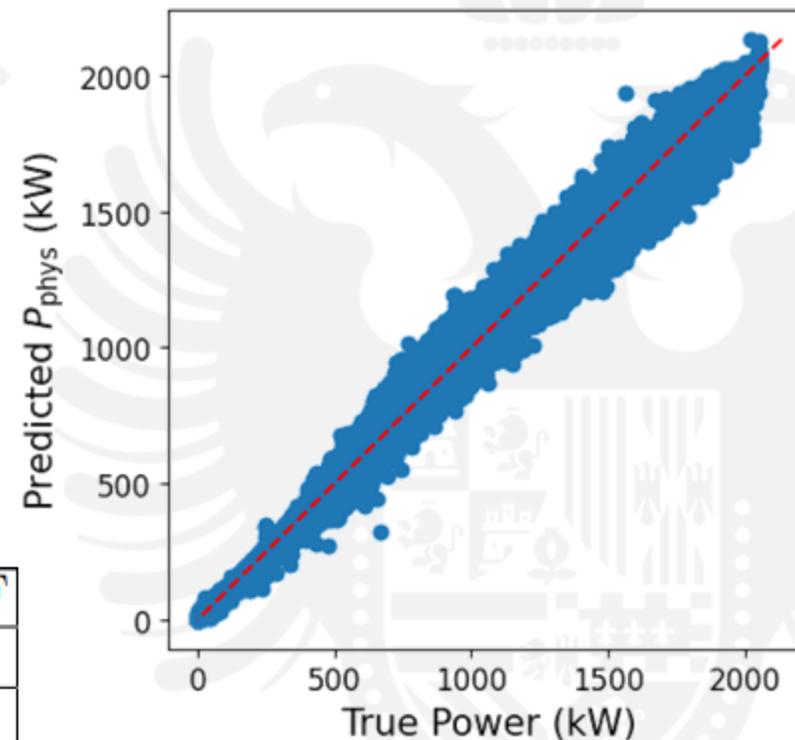
- FFNN 2:
 - 16 variables input layer
 - 2-layer architecture
 - Units per layer: 128
 - Learning rate: 0.001
 - Activation: ReLU



Hybrid Semi-Parametric Model: Resultados

The sole physics-based sub-model is capable of producing quite accurate results

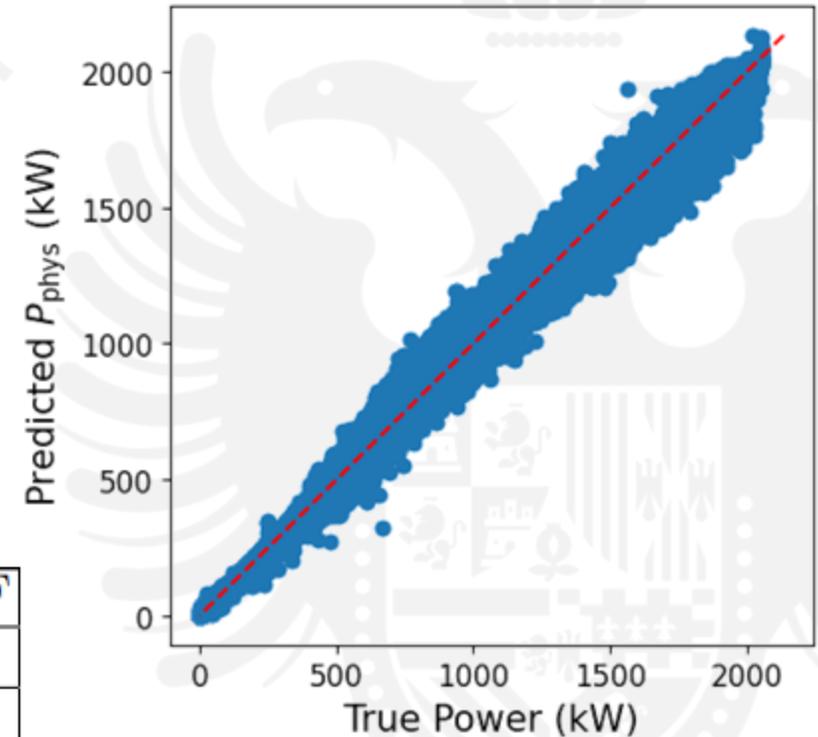
	PINN	Phys	Hybrid	Hybrid_CF
MAE (kW)	15.55	16.31	10.51	10.89
RMSE (kW)	28.02	30.63	22.07	22.74
MAPE (%)	3.838	3.706	2.159	2.203
R2 score	0.9960	0.9953	0.9976	0.9974



Hybrid Semi-Parametric Model: Resultados

The adoption of the hybrid model enhanced overcoming the performance of a reference PINN model, with the **MAPE dropping from 3.84% to 2.16%**

	PINN	Phys	Hybrid	Hybrid_CF
MAE (kW)	15.55	16.31	10.51	10.89
RMSE (kW)	28.02	30.63	22.07	22.74
MAPE (%)	3.838	3.706	2.159	2.203
R2 score	0.9960	0.9953	0.9976	0.9974



Hybrid Semi-Parametric Model: Resultados

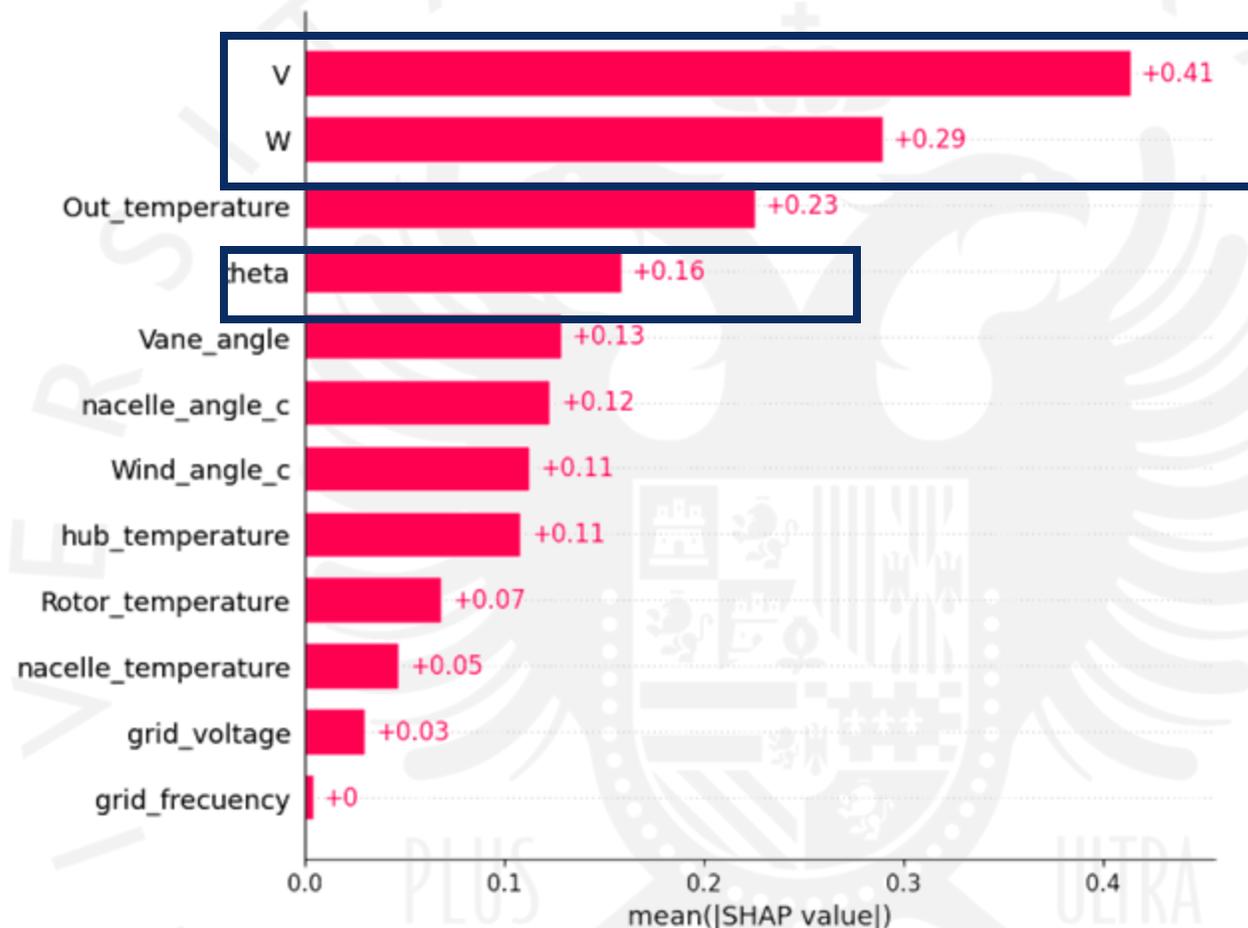


SHAP nos permite evaluar el impacto de las demás variables de entrada en la variable de salida (potencia generada).



Hybrid Semi-Parametric Model: Resultados

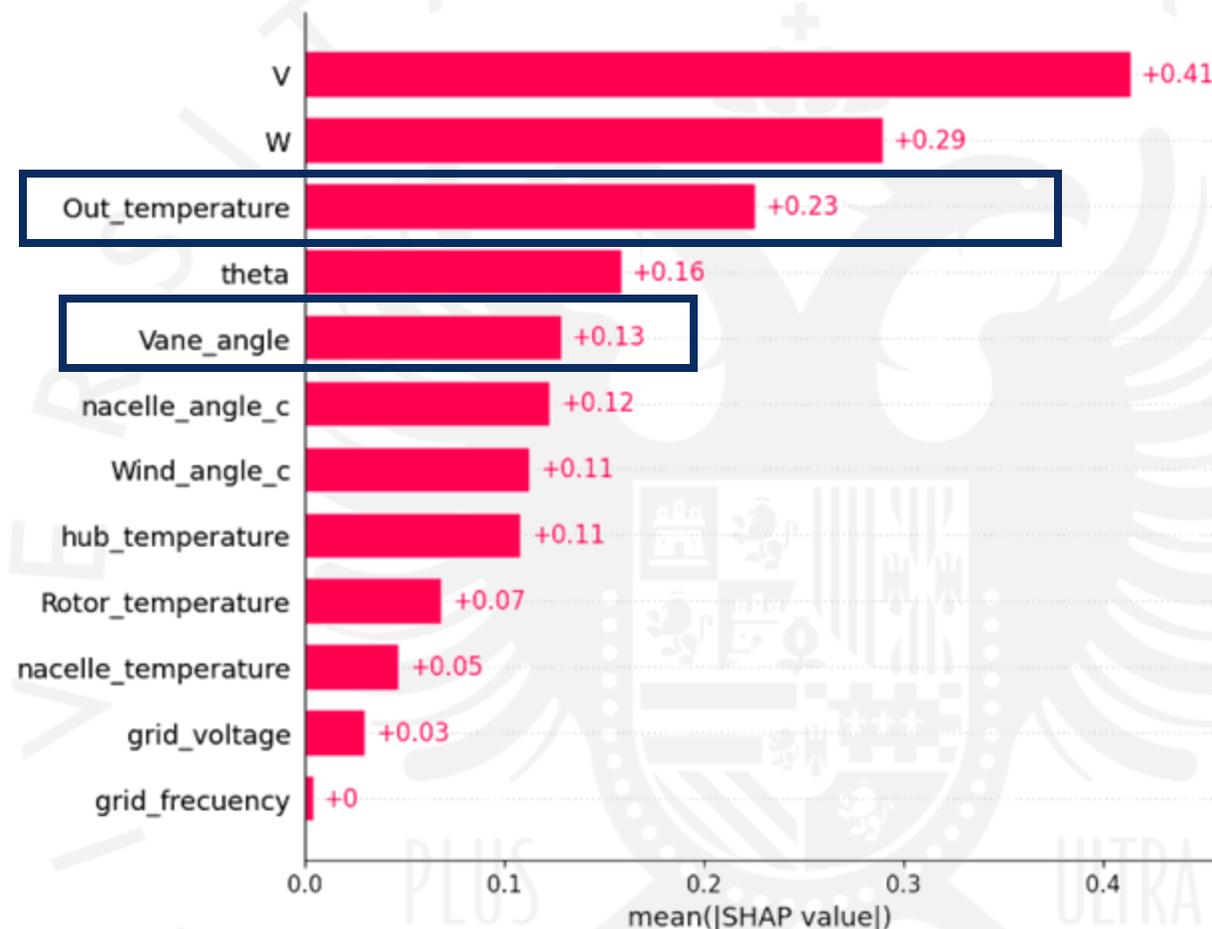
The variables which are employed in the physics-based sub-model are the most relevant.



Hybrid Semi-Parametric Model: Resultados

The variables which are employed in the physics-based sub-model are the most relevant.

Yet, other variables are discovered to play an important role as well: i.e. outdoor temperature, vane angle.



¡GRACIAS!

00



INTELIGENCIA ARTIFICIAL
PARA LA TRANSICIÓN
ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL

 **Plan de Recuperación,
Transformación
y Resiliencia**