OWC
An Aqualis Company

The **Renewable Energy** Consultants.

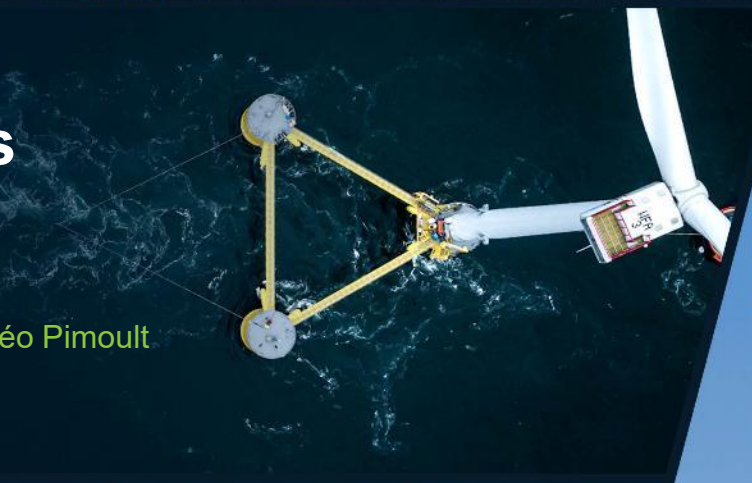


Evaluación rápida de vida remanente de aerogeneradores mediante modelos predictivos de cargas

Autora: Patricia Mayoral Gregorio

Colaboradores: Eva Plaza, Clémentine Girandier, Louis Papillon, Samy Zouhri, Matéo Pimoult

owcltd.com









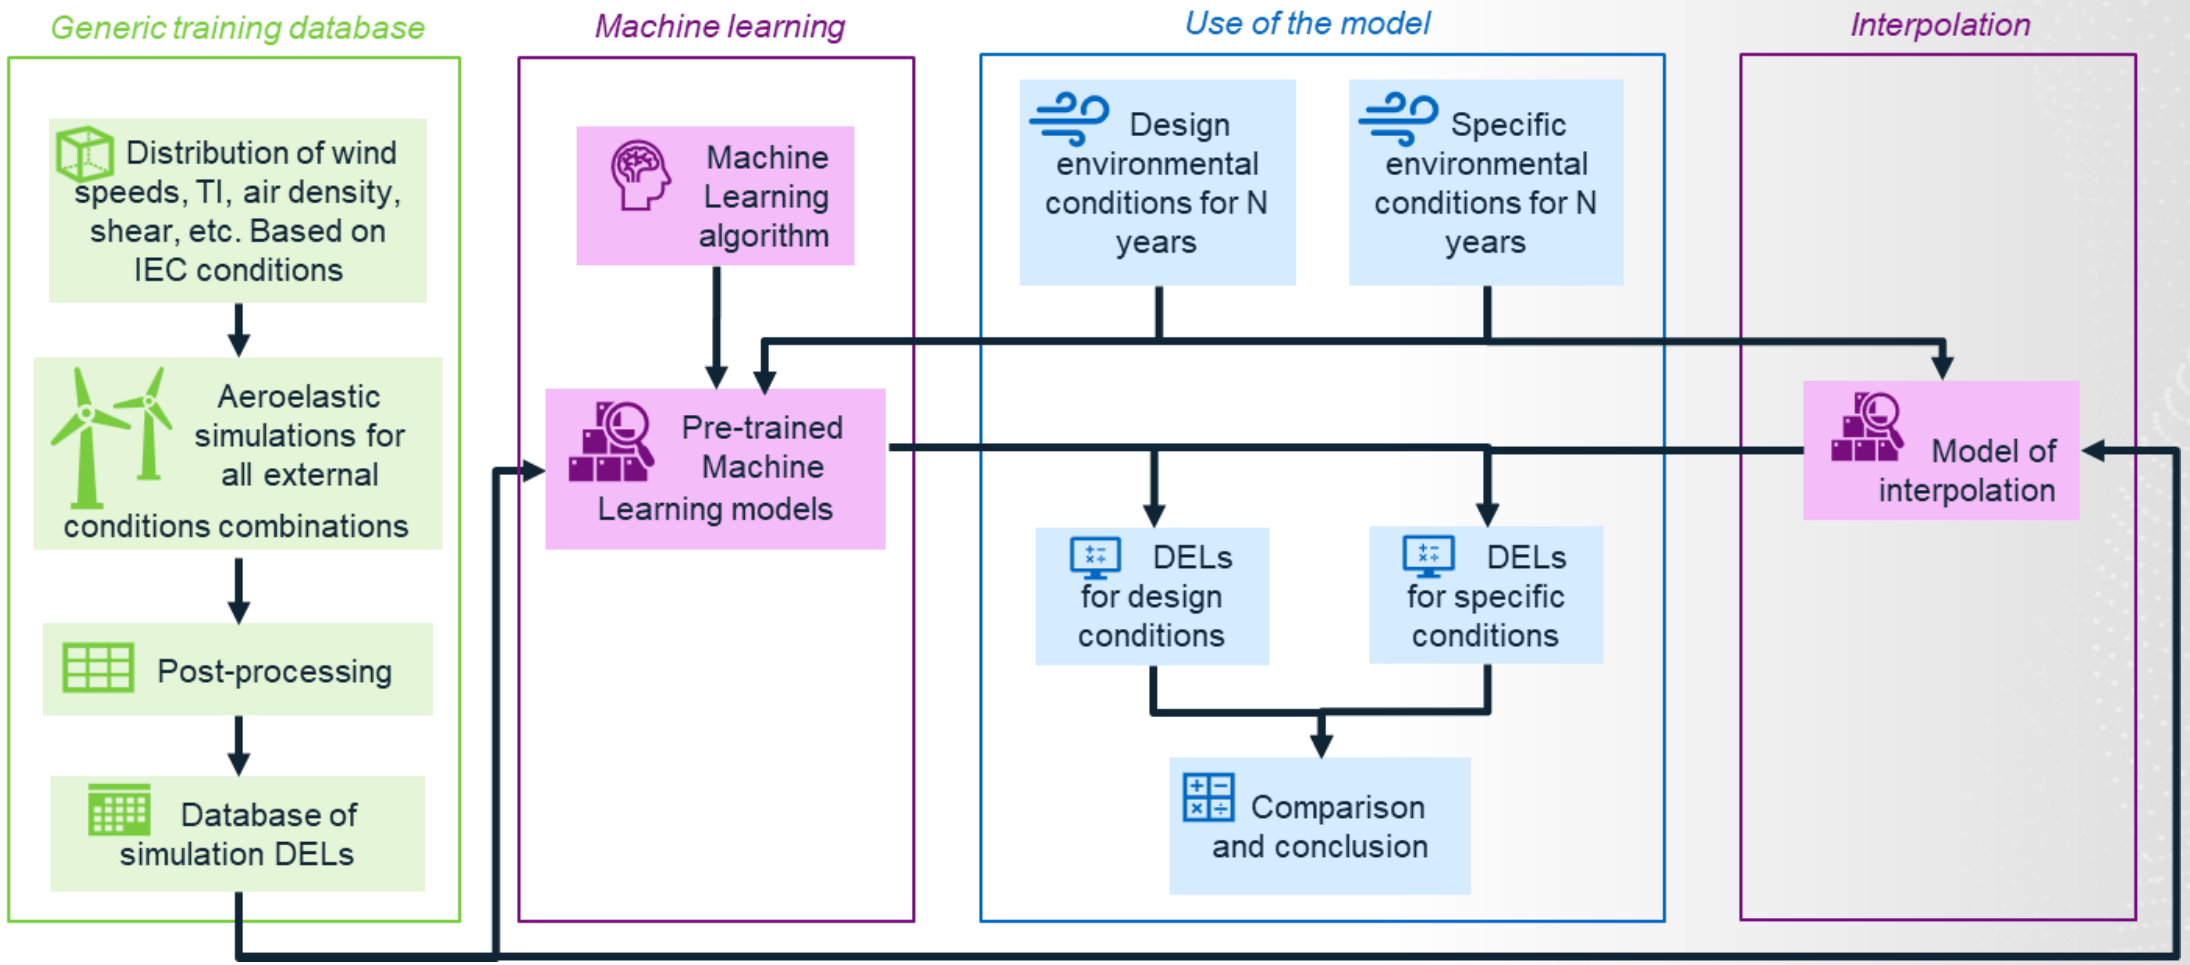
© 2026 Aqualis

1. Contexto y motivación

- Una proporción creciente de la flota terrestre europea se está acercando o ha superado su vida útil de diseño original, y entre 10 y 12GW de los parques operativos en España llevan más de 15 años en funcionamiento.
- La extensión de vida útil requiere una evaluación de fatiga específica para el emplazamiento para cuantificar el margen estructural disponible.
- Las simulaciones aeroelásticas siguen siendo la referencia de la industria para la evaluación de cargas, pero ejecutar un conjunto completo de simulaciones de fatiga para cada verificación implica un elevado coste computacional.
- La herramienta desarrollada ofrece una alternativa eficiente basada en modelos predictivos, haciendo posible realizar una **amplia gama de estudios a lo largo del ciclo de vida del parque y en múltiples parques** equipados con el mismo aerogenerador.



2. Visión general de la herramienta



4. Metodología de validación

1. **Generación de la base de datos de entrenamiento utilizando el modelo NREL de 2.3MW en OpenFast [1]**

2. **Definición de 3 casos de prueba: representativos de las condiciones ambientales terrestres europeas**

	Empl. 1: Terreno estándar	Empl. 2: Terreno complejo	Empl. 3: Terreno abierto
Densidad del aire [kg/m3]	1.23 (nivel del mar, clima templado)	1.18 (~800m de altitud, clima templado)	1.23 (nivel del mar, clima frío)
Cizalladura del viento (shear)	0.14 (cizalladura estándar)	0.25 (bosque o terreno accidentado)	0.10 (zona abierta)
[-]	0.14 (IEC Class B)	0.16 (IEC Class A)	0.12 (IEC Class C)
Iref [-]	1° (estándar)	5° (alta variabilidad direccional)	0.5° (estable)
Ángulo de incidencia [°]	2	1.8	2.2
Weibull shape [-]	7.5	6.5	8.5
Weibull scale [m/s]			

3. **Definición de una base de datos de validación**

300 casos que cubren todo el espacio de parámetros de entrada utilizando la estrategia de muestreo cuasi aleatorio Latin Hypercube Sampling (LHS), con las mismas distribuciones que el entrenamiento.

4. **Comparación de las predicciones de los modelos predictivos frente a las simulaciones aeroelásticas**

Se ejecutan simulaciones aeroelásticas para los tres casos de ensayo y el conjunto de validación. Las predicciones se obtienen a partir de los distintos modelos predictivos estudiados considerando las mismas condiciones ambientales. Los resultados entre simulaciones (Sim) y modelos sustitutos (Pred) se comparan mediante dos métricas principales (SMAPE, DEL error).

$$SMAPE = \frac{2}{n}\sum_{t=1}^{n}\frac{|Pred_t - Sim_t|}{|Pred_t| + |Sim_t|} \qquad DEL\ error = \frac{DEL_{Sim} - DEL_{Pred}}{DEL_{Sim}}$$

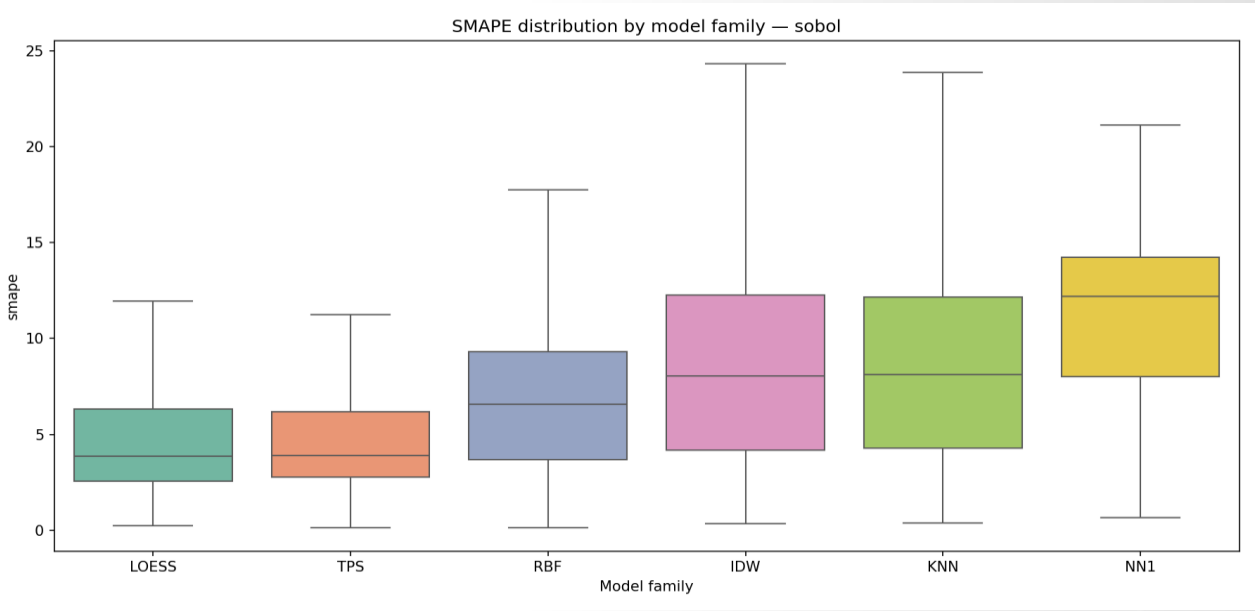
[1] NREL, “IEA-scaled/NREL-2.3-116,” 06 2024. [Online]. Available: https://github.com/NatLabRockies/openfast-turbine-models/tree/main/IEA-scaled/NREL-2.3-116

3. Base de datos y modelos predictivos

Parámetros ambientales	Rango / Grado de libertad (distribución Sobol)
Velocidad del Viento [m/s]	[Vin, Vout]
Coeficiente de cizalladura del viento (shear)	[0, 0.4]
Densidad del aire [kg/m^3]	[1, 1.3]
Ángulo de incidencia [deg]	[0, 20]
Intensidad de turbulencia	Valores de IT derivados de [I_{ref} min, I_{ref} max]
Yaw misalignment [deg]	[-8, 8]

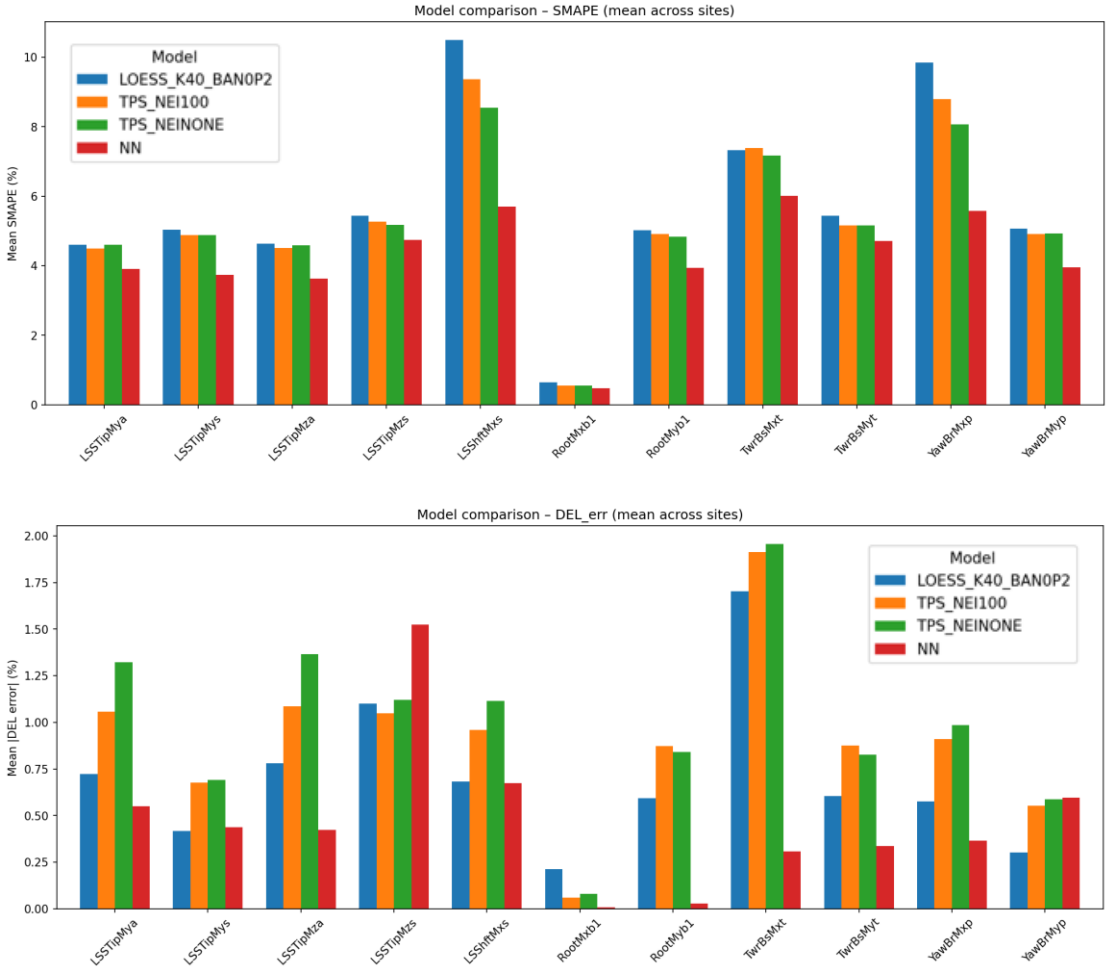
Canales de carga	Valores de Wohler (m)
Momentos en el buje	4
Momentos en raíz de pala	10
Momentos en la base de la torre	4
Momentos en la parte superior de la torre	4

- Se evaluaron varios métodos de interpolación para identificar aquellos con mejor rendimiento:
  NN1 (nearest neighbor), KNN (k-nearest neighbor), Inverse Distance Weighting (IDW), **Local Regression (LOESS),** Radial Basis Function (RBF), **Thin Plate Spline (TPS)**

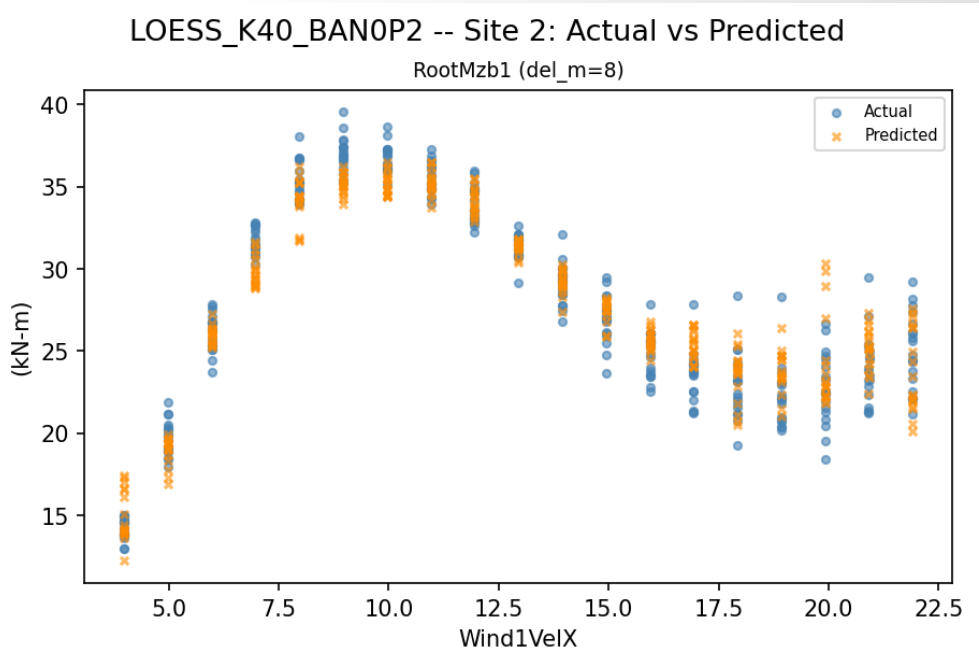


- Considerando la aplicación objetivo de la herramienta, se seleccionó una **Red Neuronal (NN)** como modelo de aprendizaje automático o de *machine learning*.

5. Resultados



- El modelo basado en NN supera a los modelos de interpolación en todas las métricas de predicción de canales (*)
- SMAPE < 10% para todos los canales, <5% para la mayoría
- DEL error <2% para todos los canales
- En una comparación canal por canal, **las predicciones de cargas son muy similares a las cargas simuladas**



(*) Solo dos excepciones para DEL error: LSSTipMzs y YawBrMyp

7. Conclusiones y perspectiva a futuro

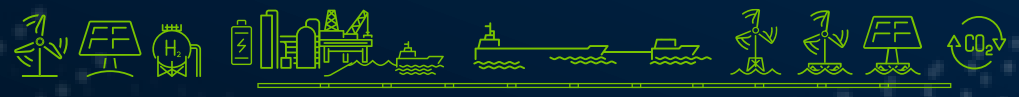
- **Conclusiones técnicas**
  - Predicción precisa de las cargas equivalentes de fatiga y de la vida remanente
  - Error medio inferior al 1% en la validación
  - Resultados consistentes en diferentes condiciones y entre distintas clases IEC
- **Perspectiva a futuro**
  - Proporciona una solución eficiente para gestores y desarrolladores de activos que permite **evaluar rápidamente el potencial de extensión de vida útil y priorizar análisis detallados**.
  - Combinado con inspecciones, modelos de costes y evaluación d estrategias de operación y mantenimiento (O&M), contribuye a una **evaluación integral de la viabilidad de la extensión de vida útil**.
- **Próximas etapas**
  - Integrar datos operacionales
  - Ampliar la cobertura de condiciones ambientales y tamaño de aerogeneradores
  - Métodos avanzados de *machine learning* (*transfer learning*)



OWC

An Aqualis Company

Driving Sustainability in Energy and Oceans.



owcltd.com | enquiries@owcltd.com | #TheRenewableEnergyConsultants

© 2026 Aqualis