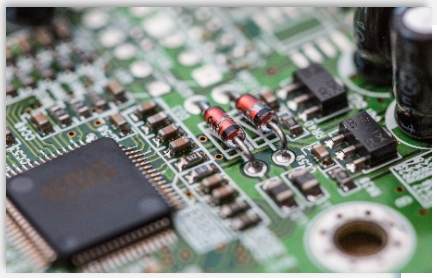

PROMINT-CM

PROgrama Microrredes INTeligentes Comunidad de Madrid

Reunión del Subcomité científico-técnico

Grupo GHEODE-UAH

OBJETIVO 5.

APRENDIZAJE MÁQUINA APLICADO A MICRORREDES, VEHÍCULO ELÉCTRICO Y GESTIÓN ENERGÉTICA

Web: geiser.depeca.uah.es/promint

UNIÓN EUROPEA
Fondos Estructurales
Invertimos en tu futuro

UNIÓN EUROPEA
Fondo Social Europeo
El FSE invierte en tu futuro

Comunidad de Madrid

Avances en los objetivos del Programa

- Objetivo 5.1. Algoritmos de predicción para recurso renovable
  - Predicción a corto y largo plazo del nivel de agua en una reserva hidroeléctrica
  - Estimación de demanda de energía
  - Predicción de radiación solar
  - TFM: Predicción de nivel de agua embalsada para producción de energía hidroeléctrica

- Objetivo 5.2. Algoritmos de optimización para diseño y planificación de Microrredes
  - Localización y dimensionamiento óptimos de ESSs en líneas de ferrocarril

- Objetivo 5.3. Algoritmos de aprendizaje máquina para problemas relacionados con la incorporación de vehículos eléctricos en microrredes.
  - Programación de cargas y descargas de VE

Predicción a corto y largo plazo del nivel de agua en una reserva hidroeléctrica

- Datos
  - Reserva de Belasar (Río Miño), 1963-2015
  - Para corto plazo se han tomado también
    - Variables hidrologicas (altura y caudal)
    - Cantidad de agua empleada para generar electricidad
    - Nieve (acumulada y derretida). ERA5 del Climate Data Store API

- Corto plazo:
  - Redes neuronales **MLP**
  - Support Vector Regression
  - Modelos Gaussianos

Semanal

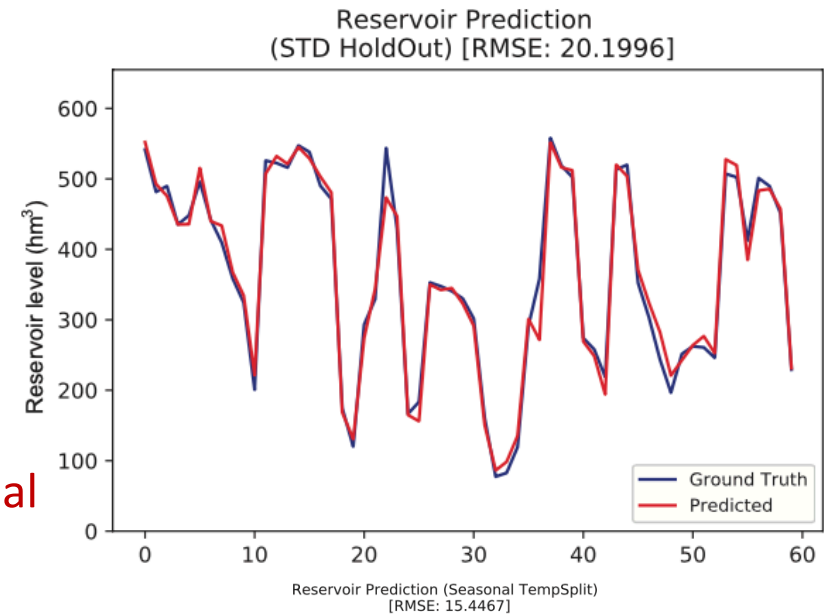

Estacional

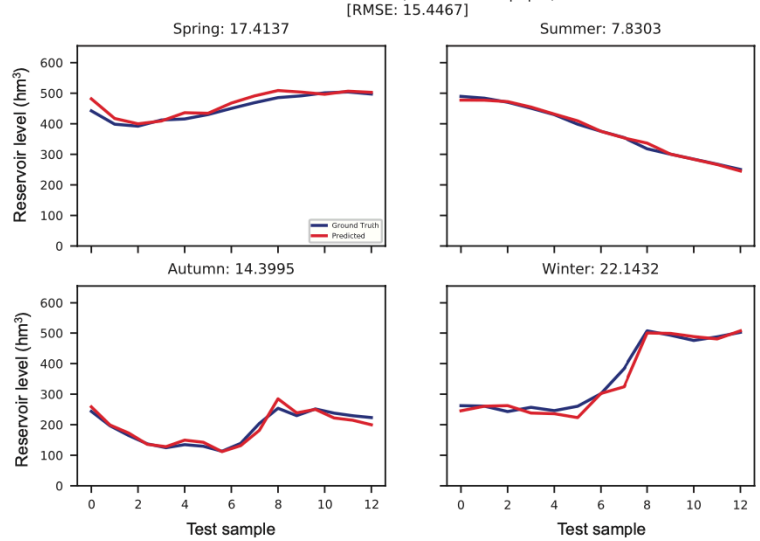

UNIÓN EUI
Fondos Estruc
Invertimos en t

PROMINT-CM

PROgrama Microrredes INTeligentes Comunidad de Madrid

Predicción a corto y largo plazo del nivel de agua en una reserva hidroeléctrica

- Largo plazo:
  - Análisis de fluctuación sin tendencia (Detrended Fluctuation Analysis, DFA)
  - Modelos autorregresivos
  - Persistencia

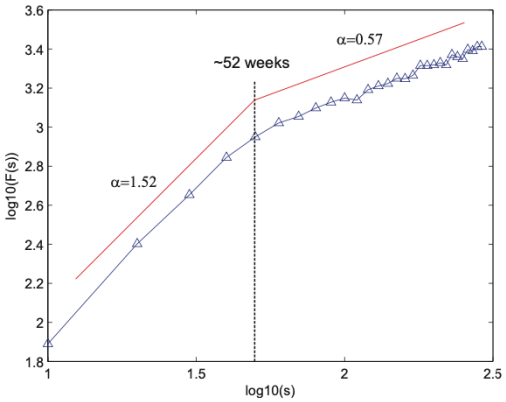

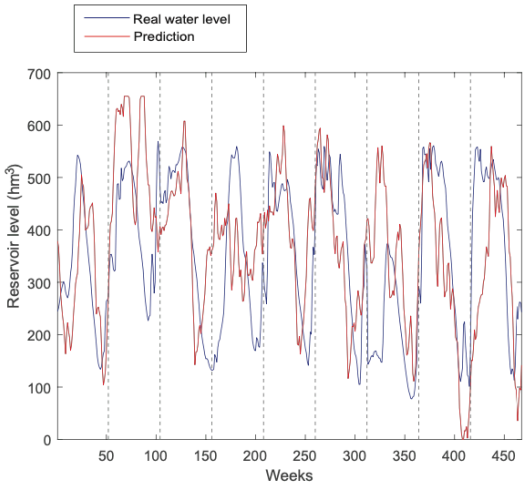

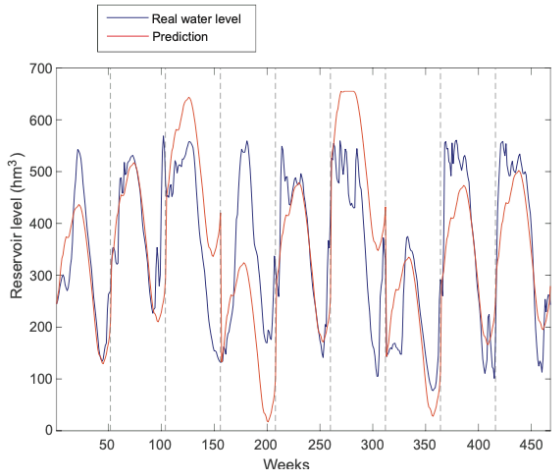

Predicción de radiación solar

- Predicción evitando el uso de datos radiométricos de estaciones de medida y de variables atmosféricas

- Variables predictivas
  - Reflectividad (SEVIRI, Meteosat)
  - Radiación solar (CAMS y SolarGIS)
  - Radiación en Clear Sky
  - Índice de nubes

- Metodología: evolutionary neural networks
  - ANN con back-propagation suele caer frecuentemente en óptimos locales
  - Evolutionary ANN: se realiza una exploración global del espacio de búsqueda para evitar los mínimos locales
    - MSE (Mean Square Error)

Predicción de radiación solar

	Best RMSE model				$\overline{\text{RMSE}}$
	MBE	MAE	RMSE	r^2	$[W/m^2]$
	$[W/m^2]$	$[W/m^2]$	$[W/m^2]$		
SU-LO	2.26	39.17	59.06	0.9622	*60.73 ± 0.85*
RBF-LO	2.70	37.33	**57.07**	**0.9648**	62.31 ± 4.79
SU-PU	1.58	38.64	58.41	0.9630	**59.99 ± 0.90**
Heliosat-2	19.07	96.21	133.72	0.8105	-
CAMS	5.06	58.09	85.71	0.9212	-
SolarGIS	*−1.28*	57.96	86.09	0.9202	-
ELM	3.14	**36.04**	*57.26*	*0.9645*	60.78 ± 2.56
GPR	**1.07**	*37.19*	61.63	0.9589	80.62 ± 14.13
MLP	1.87	47.30	67.69	0.9504	74.05 ± 3.06
SVR	4.38	43.07	61.82	0.9591	64.17 ± 1.47

Cornejo-Bueno L, Casanova-Mateo C, Sanz-Justo J, Salcedo-Sanz S. Machine learning regressors for solar radiation estimation from satellite data. Sol En- ergy 2019;183:768e75.

	Best RMSE model				$\overline{\text{RMSE}}$
	MBE	MAE	RMSE	r^2	$[W/m^2]$
	$[W/m^2]$	$[W/m^2]$	$[W/m^2]$		
Configuration 1					
SU-LO	2.26	39.17	59.06	0.9622	60.73 ± 0.85
RBF-LO	2.70	37.33	57.07	0.9648	62.31 ± 4.79
SU-PU	1.58	38.64	58.41	0.9630	59.99 ± 0.90
Configuration 2					
SU-LO	1.92	34.59	*51.89*	*0.9708*	*55.29 ± 1.52*
RBF-LO	1.64	36.27	55.47	0.9667	61.54 ± 6.85
SU-PU	1.09	**33.46**	**51.82**	**0.9709**	57.02 ± 9.27
Configuration 3					
SU-LO	2.55	33.88	52.46	0.9702	**55.09 ± 2.79**
RBF-LO	1.42	34.11	52.74	0.9698	63.05 ± 22.66
SU-PU	1.70	*33.49*	52.17	0.9705	57.63 ± 10.07
Configuration 4					
SU-LO	−2.95	36.95	56.15	0.9659	67.42 ± 13.92
RBF-LO	*−1.04*	36.92	55.14	0.9670	60.38 ± 4.85
SU-PU	**0.30**	33.61	52.12	0.9705	56.38 ± 2.67

Estimación de demanda de energía

- Grammatical Swarm (Particle Swarm Optimization)
- Objetivo: estimación de la demanda de energía a un año vista (Francia y España)
- Datos: variables macroeconómicas

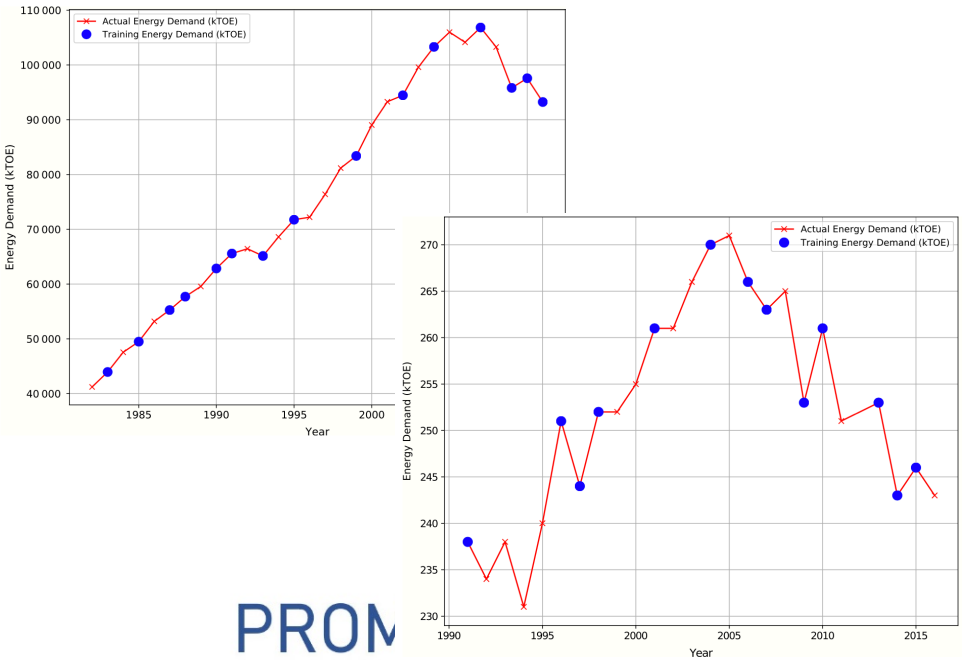

1. Gross Domestic Product (€)
2. Population
3. Exports (€)
4. Imports (€)
5. Energy production (kTOE)
6. Electricity power transport (kWh)
7. Electricity production (kWh)
8. GDP per unit of energy use (€ per kTOE)
9. Energy imports net (% use)
10. Fossil fuel consumption (% total)
11. Electric power consumption (kWh)
12. CO_2 emissions (Mton)
13. Unemployment rate
14. Diesel consumption in road (kTOE)

Estimación de demanda de energía

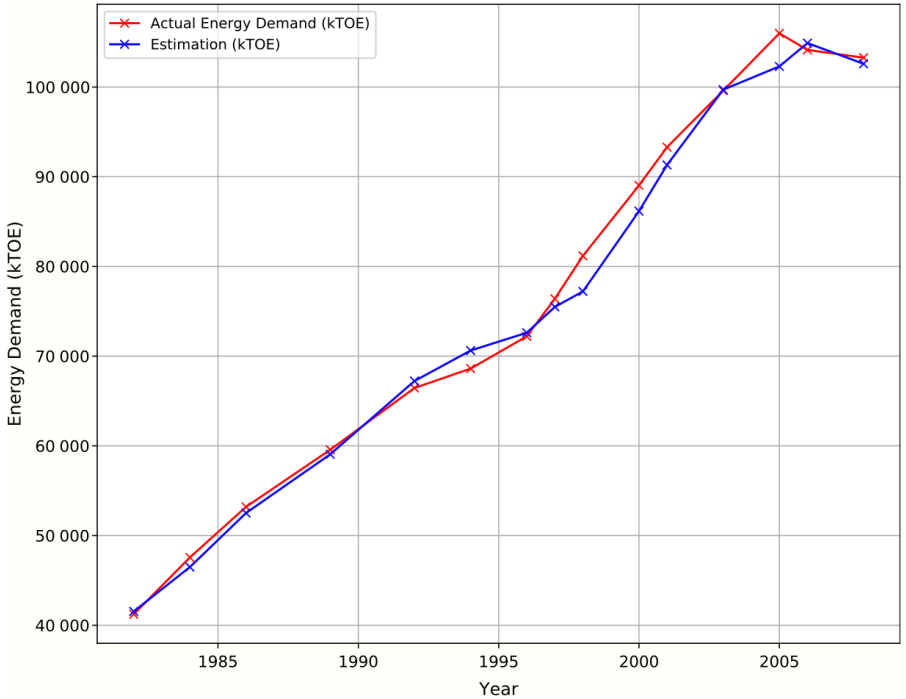

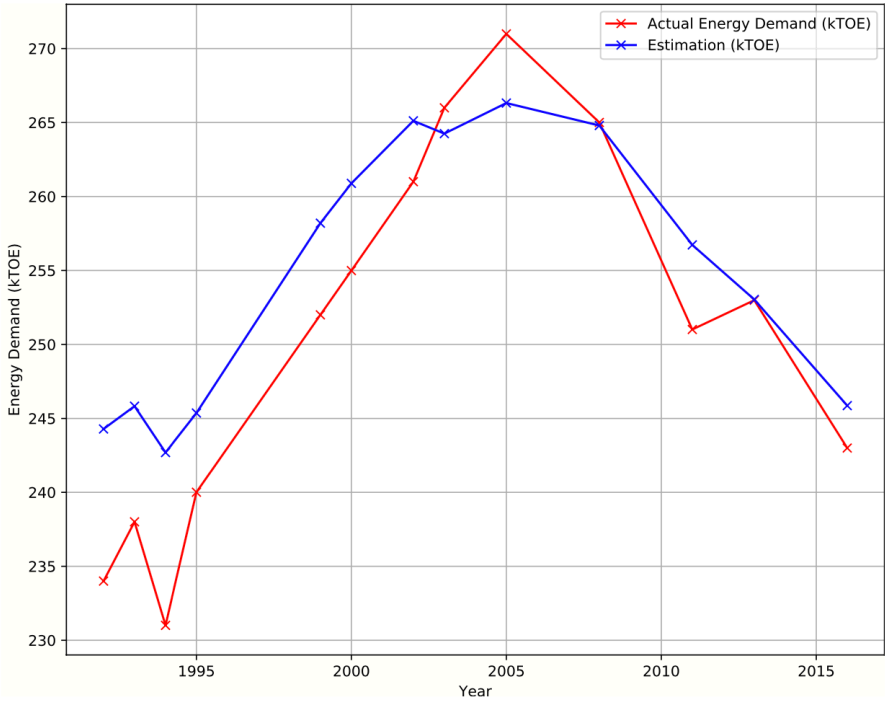

Country	Spain				France			
Data set	Training		Test		Training		Test	
Algorithm	ε_R^*	$\overline{\varepsilon_R}$	ε_R^*	$\overline{\varepsilon_R}$	ε_R^*	$\overline{\varepsilon_R}$	ε_R^*	$\overline{\varepsilon_R}$
GE	1.46	3.48	6.53	53.25	0.78	1.44	1.57	3.48
GE + DE	1.66	2.27	11.25	59.39	0.81	1.03	1.66	2.68
GS	1.52	2.37	1.75	3.27	1.33	1.40	2.10	2.74

Localización y dimensionamiento óptimos de ESSs en líneas de ferrocarril

- Determinar:
  - Número de ESSs a instalar
  - Localización de las ESSs
  - Potencia (kW) de cada ESS
  - Capacidad (kWh) de cada ESS

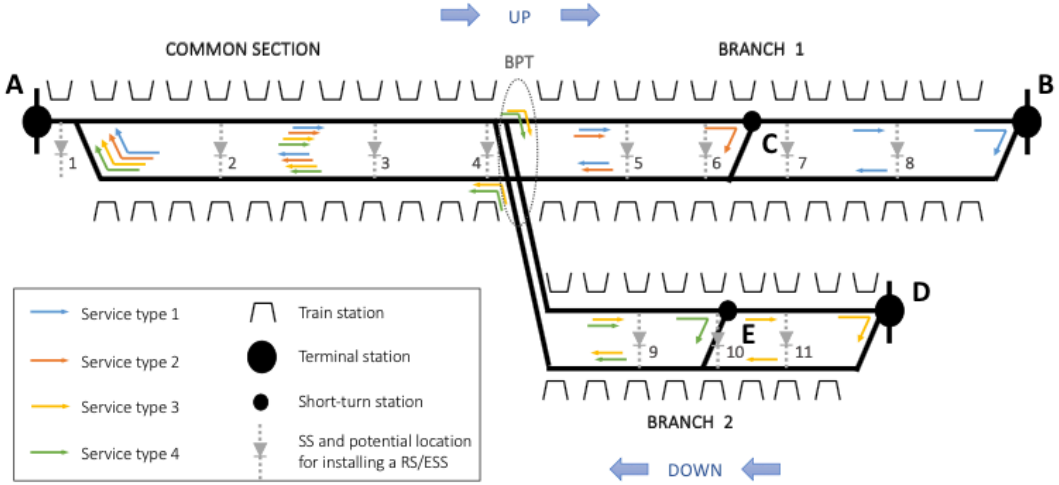

- Optimización del Coste Neto Presente (NPV) de la instalación
  - Si NPV>0 en el periodo T, entonces es rentable económicamente

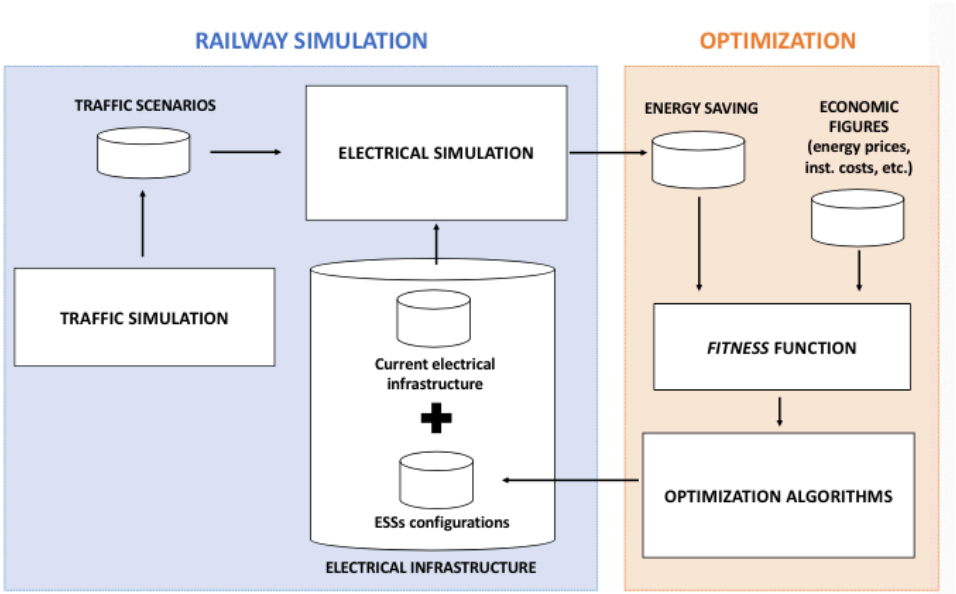

PROMINT-CM

PROgrama Microrredes INTeligentes Comunidad de Madrid

UNIÓN EUROPEA
Fondos Estructurales
Invertimos en tu futuro

UNIÓN EUROPEA
Fondo Social Europeo
El FSE invierte en tu futuro

Comunidad de Madrid

Localización y dimensionamiento óptimos de ESSs en líneas de ferrocarril

- CRO-SL (HS, DE, 2Px, MPx, GM)

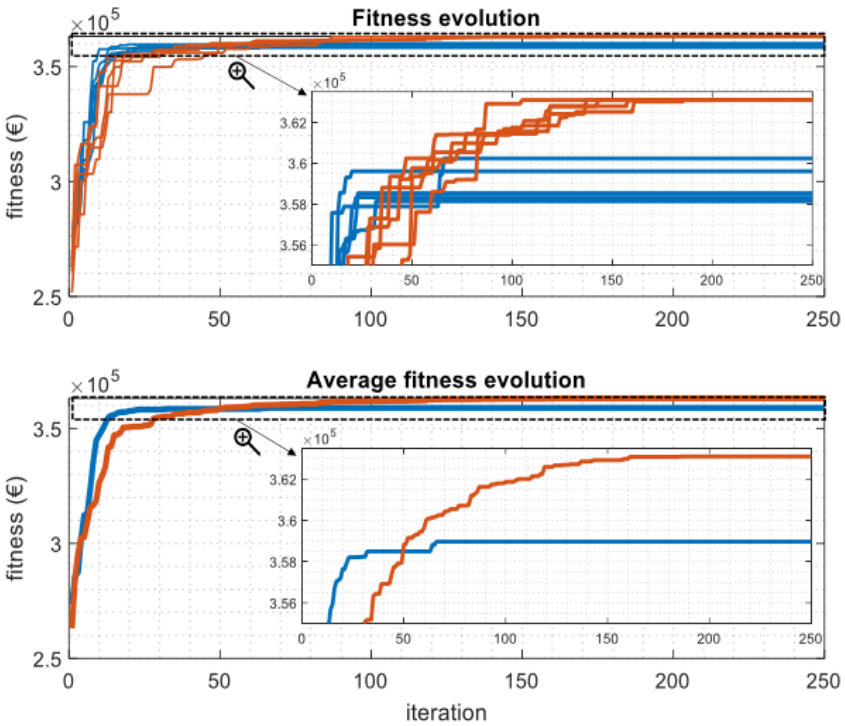

Location	CRO-SL Solution $\mathcal{P}$	$\mathcal{C}$
1	500	2.5
2	500	5
3	500	5
4	500	5
5	–	–
6	–	–
7	–	–
8	500	5
9	–	–
10	–	–
11	500	5
Fitness	**363.1** [k€]	

Location	Solution #1 $\mathcal{P}$	$\mathcal{C}$
1	500	5
2	500	2.5
3	500	2.5
4	500	5
5	–	–
6	–	–
7	–	–
8	500	7.5
9	–	–
10	–	–
11	500	2.5
Fitness	**360.2** [k€]	

Resultados alcanzados

1. C. Castillo-Botón, D. Casillas-Pérez, C. Casanova-Mateo, L.M. Moreno-Saavedra, B. Morales-Díaz, J. Sanz-Justo, P.A. Gutiérrez, S. Salcedo-Sanz. Analysis and Prediction of Dammed Water Level in a Hydropower Reservoir Using Machine Learning and Persistence-Based Techniques. *Water* **2020**, *12*, 1528.
2. D. Roch-Dupré, C. Camacho-Gómez, A. P. Cucala, S. Jiménez-Fernández, A. López-López, A. Portilla-Figueras, R. R. Pecharromán, A. Fernández-Cardador, S. Salcedo-Sanz. Optimal location and sizing of energy storage systems in DC-electrified railway lines using a Coral Reefs Optimization algorithm with Substrate Layers. *Applied Soft Computing.* **Under review**