

Optimización energética local de edificios.



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

Financiado por el Ministerio de Asuntos Económicos y Transformación Digital dentro del proyecto IA4TES MIA.2021.M04.0008

Contexto

Climatización de edificios

Problema de optimización multi-objetivo:

- Reducir el consumo energético.
- Garantizar el confort térmico.



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:

Alternativas...



**Controladores basados
en reglas / PID**



MPC



**Reinforcement
learning**



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

Contexto:

	Control adaptativo	Control predictivo	Horizonte de predicción	Requiere un modelo del sistema	Datos requeridos	Requisitos computacionales	Gestión de restricciones	Adopción en la industria	Barrera de adopción
RBC / PID	No	No	—	No	Ninguno	Bajos	Impuestas explícitamente (pueden no cumplirse al ser un control reactivo)	Alta	Ninguna
MPC	No en su forma más básica	Sí	Horas/días	Sí	Días/semanas	Altos (online)	Impuestas explícitamente (pueden no cumplirse debido a incertidumbre o imprecisión del modelo)	Baja	Configuración y complejidad de optimización
RL	Sí	Sí	“Infinito”	Sí, en model-based RL	Años	Altos (offline)	Implícitas en la recompensa (se espera que no se cumplan)	Muy baja	Eficiencia de datos

Nagy, Zoltan, et al. "Ten questions concerning reinforcement learning for building energy management." *Building and Environment* (2023): 110435

Contexto:

	PROS	CONTRAS
RBC / PID	• Simplicidad • Eficiencia	• Poco escalables • Ajuste complejo / conocimiento experto • Sin predicción
MPC	• Precisión • Predicción	• Calibración compleja • Difícil de transferir entre edificios • Alto coste computacional / datos
RL	• Aprendizaje por interacción • Flexibilidad en las observaciones • Horizonte de predicción prácticamente infinito	• Gran cantidad de datos • Model-based RL → modelo del sistema • Definición de recompensa • Explicabilidad

(*) Las ventajas e inconvenientes de MPC y RL son compatibles, lo que motiva a su combinación.



INTELIGENCIA ARTIFICIAL
PARA LA TRANSICIÓN
ENERGÉTICA SOSTENIBLE



Financiado por
la Unión Europea
NextGenerationEU



GOBIERNO
DE ESPAÑA

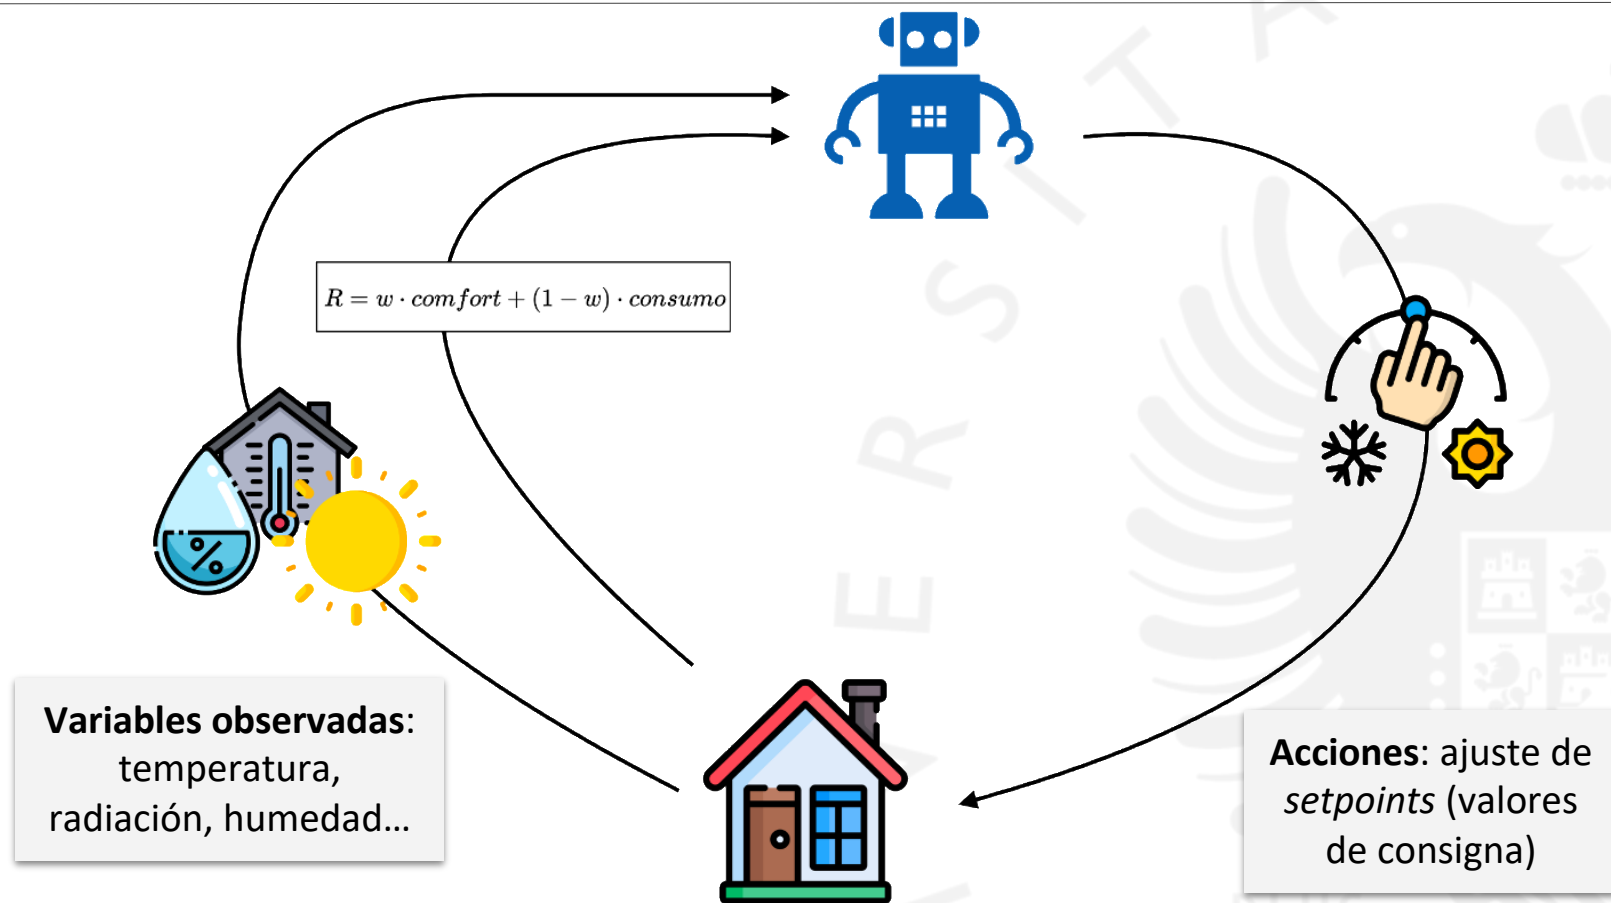
MINISTERIO
DE ASUNTOS ECONÓMICOS
Y TRANSFORMACIÓN DIGITAL

SECRETARÍA DE ESTADO
DE DIGITALIZACIÓN
E INTELIGENCIA ARTIFICIAL



Plan de Recuperación,
Transformación
y Resiliencia

Contexto:



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

Contexto:



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

Contexto:



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

Sinergym



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

Sinergym





- Framework open source basado en Python para la simulación y control energético de edificios mediante algoritmos de DRL.
- Siguen el estándar de Gymnasium.
- Funciona sobre el simulador EnergyPlus.
- Incluye múltiples funcionalidades extra como wrappers propios (ej. normalización), funciones de recompensa, loggers, etc.

<https://github.com/ugr-sail/sinergym>



Campoy-Nieves, A., Manjavacas, A., Jiménez-Raboso, J., Molina-Solana, M., Gómez-Romero, J. (2025) ***SINERGYM - A virtual testbed for building energy optimization with Reinforcement Learning*** Energy and Buildings 327 , 115075. <http://doi.org/10.1007/s10462-024-10819-x>

Sinergym



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

En la práctica...



Manjavacas, A., Campoy-Nieves, A., Jiménez-Raboso, J., Molina-Solana, M., Gómez-Romero, J. (2024)

An experimental evaluation of deep reinforcement learning algorithms for HVAC control.

Artificial Intelligence Review 57, 173

<http://doi.org/10.1007/s10462-024-10819-x>

An experimental evaluation of Deep Reinforcement Learning algorithms for HVAC control

Antonio Manjavacas^{1*}, Alejandro Campoy-Nieves¹, Javier Jiménez-Raboso¹, Miguel Molina-Solana¹ and Juan Gómez-Romero¹

¹Department of Computer Science and Artificial Intelligence, Universidad de Granada, Granada, 18071, Spain.

*Corresponding author(s). E-mail(s): manjavacas@ugr.es;
Contributing authors: alejandroc7@ugr.es; jajimer@correo.ugr.es;
miguelmolina@ugr.es; jgomez@decsai.ugr.es;

Abstract

Heating, Ventilation, and Air Conditioning (HVAC) systems are a major driver of energy consumption in commercial and residential buildings. Recent studies have shown that Deep Reinforcement Learning (DRL) algorithms can outperform traditional reactive controllers. However, DRL-based solutions are generally designed for ad hoc setups and lack standardization for comparison. To fill this gap, this paper provides a critical and reproducible evaluation, in terms of comfort and energy consumption, of several state-of-the-art DRL algorithms for HVAC control. The study examines the controllers' robustness, adaptability, and trade-off between optimization goals by using the SINERGYM framework. The results obtained confirm the potential of DRL algorithms, such as SAC and TD3, in complex scenarios and reveal several challenges related to generalization and incremental learning.

Keywords: Reinforcement Learning, HVAC, Building Energy Optimization, Sinergym



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

Experimentación

- Algoritmos:


RBC	Control reactivo
PPO	<i>Policy-based</i>
TD3	<i>Actor-critic</i>
SAC	<i>Actor-critic</i>

- Climas:


	Localización	Tª media	Humedad relativa
Hot dry	Arizona (USA)	21.7°C	34.9%
Mixed humid	Nueva York (USA)	12.6°C	68.5%
Cool marine	Washington (USA)	9.3°C	81.1%

- Edificios:

	Zonas	Dimensiones	Equipamiento
5Zone	5 (4 exteriores, 1 interior)	464.5152 m ²	DX VAV
Datacenter	2	491.3 m ²	DX VAV



(a) 5ZONEAutoDXVAV representation



(b) 2ZONEDataCenterHVAC representation



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

Experimentación

Variables observadas (espacio de observación)

Table 1: Observation variables in 5ZONEAUTODXVAV

Variable name	Max.	Min.
Site Outdoor Air Drybulb Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Outdoor Air Relative Humidity	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Wind Speed	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Wind Direction	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Diffuse Solar Radiation Rate per Area	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Direct Solar Radiation Rate per Area	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Thermostat Heating Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Thermostat Cooling Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Thermal Comfort Mean Radiant Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Air Relative Humidity	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Thermal Comfort Clothing Value	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone Thermal Comfort Fanger Model PPD	$-5 \cdot 10^6$	$5 \cdot 10^6$
Zone People Occupant Count	$-5 \cdot 10^6$	$5 \cdot 10^6$
People Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Facility Total HVAC Electricity Demand Rate	$-5 \cdot 10^6$	$5 \cdot 10^6$
Current year	1	2050
Current month	1	31
Current day	1	12
Current hour	0	23

Table 2: Observation variables in 2ZONEDATACENTERHVAC

Variable name	Max.	Min.
Site Outdoor Air Drybulb Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Outdoor Air Relative Humidity	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Wind Speed	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Wind Direction	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Diffuse Solar Radiation Rate per Area	$-5 \cdot 10^6$	$5 \cdot 10^6$
Site Direct Solar Radiation Rate per Area	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Thermostat Heating Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Thermostat Cooling Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Thermal Comfort Mean Radiant Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Air Relative Humidity	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Thermal Comfort Clothing Value	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone Thermal Comfort Fanger Model PPD	$-5 \cdot 10^6$	$5 \cdot 10^6$
West Zone People Occupant Count	$-5 \cdot 10^6$	$5 \cdot 10^6$
West People Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Thermostat Heating Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Thermostat Cooling Setpoint Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Thermal Comfort Mean Radiant Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Air Relative Humidity	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Thermal Comfort Clothing Value	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone Thermal Comfort Fanger Model PPD	$-5 \cdot 10^6$	$5 \cdot 10^6$
East Zone People Occupant Count	$-5 \cdot 10^6$	$5 \cdot 10^6$
East People Air Temperature	$-5 \cdot 10^6$	$5 \cdot 10^6$
Facility Total HVAC Electricity Demand Rate	$-5 \cdot 10^6$	$5 \cdot 10^6$
Current year	1	2050
Current month	1	31
Current day	1	12
Current hour	0	23

Temperatura, viento, humedad, radiación solar, ocupación, hora, fecha, consumo...

Experimentación

Variables controladas (espacio de acciones)

Table 3: Action variables for 5ZONEAUTODXVAV

Variable name	Max.	Min.
Zone Thermostat Heating Setpoint Temperature	15	22.5
Zone Thermostat Cooling Setpoint Temperature	22.5	30

Table 4: Action variables for 2ZONEDATACENTERHVAC

Variable name	Max.	Min.
East Zone Thermostat Heating Setpoint Temperature	15	22.5
East Zone Thermostat Cooling Setpoint Temperature	22.5	30
West Zone Thermostat Heating Setpoint Temperature	15	22.5
West Zone Thermostat Cooling Setpoint Temperature	22.5	30

Setpoints (valores de consigna para calefacción y refrigeración)



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

Experimentación

Función de recompensa

$$r_t = -\omega \lambda_P P_t - (1 - \omega) \lambda_T (|T_t - T_{up}|_+ + |T_t - T_{low}|_+)$$

Consumo

Confort

Ponderación (ω): 50% – 50%

λ_P y λ_T → factores de escala

P_t → potencia consumida (w)

T_t → temperatura interior

T_{up} , T_{low} → límites de confort



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

Experimentación: Metodología



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

Experimentación

Configuración

Episodios de entrenamiento: 20


- 1 episodio = 1 año simulado

Métricas de evaluación:

- Recompensa media por episodio
- Consumo medio
- % de tiempo bajo violación de confort

Rangos definidos por ASHRAE

Interacciones agente – entorno cada 15 minutos



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

Resultados




Fig. 6: Results for 20 evaluation episodes in 2ZONE DATACENTER HVAC




Fig. 5: Results for 20 evaluation episodes in 5ZONE AUTO DXVAV

TD3 y SAC obtienen los mejores resultados (similares o superiores a RBC en la mayoría de escenarios)



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

Resultados

- *TD3*
- *Datacenter*
- *Hot temp*

Temperaturas dentro
de los límites de
confort definidos



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

Resultados

- SAC
- 5Zone
- Mixed temp.

Adaptación a
cambios estacionales
de los límites de
confort



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

Resultados

- SAC
- 5Zone
- Mixed temp.

Pruebas con
diferentes
ponderaciones
confort-consumo



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

Conclusiones

Los agentes basados en RL pueden alcanzar/superar el rendimiento de RBCs.

- La complejidad del edificio es un factor importante a considerar.

Peor rendimiento cuando el agente es desplegado en un entorno con condiciones diferentes a las empleadas en su entrenamiento.

- Gran dependencia de los hiperparámetros (!)

La función de recompensa es efectiva y permite incorporar otros criterios que guíen el aprendizaje.

El despliegue en entornos reales sigue siendo un reto a abordar (!)

- Necesario que las variables observadas/controladas sean similares a las del entrenamiento.
- El agente debe seguir aprendiendo una vez desplegado.
- Explicabilidad (!)



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

¡GRACIAS!



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