

## DESARROLLO DE HERRAMIENTA SIMPLIFICADA PARA LA EVALUACIÓN DE MEJORAS CONSTRUCTIVAS EN VIVIENDAS COMBINANDO SIMULACIONES BEM Y REDES NEURONALES

### DEVELOPMENT OF A SIMPLIFIED TOOL FOR THE EVALUATION OF CONSTRUCTION IMPROVEMENTS IN HOUSES COMBINING BEM SIMULATIONS AND NEURAL NETWORKS

Pedro Galione<sup>a</sup>, Federico Favre<sup>a</sup>, Gabriel Pena<sup>a</sup>, Christian Díaz-Cuadro<sup>a</sup>, Mauricio Vanzulli<sup>a</sup>

<sup>a</sup>Instituto de Ingeniería Mecánica y Producción Industrial, Universidad de la República, J. Herrera y Reissig 565, 11300 Montevideo, Uruguay, <http://www.fing.edu.uy/iimpi>

**Palabras clave:** Modelado Energético de Edificios, Redes Neuronales Artificiales, Evaluación Técnico Económica.

**Resumen.** Para el diseño de viviendas más eficientes térmicamente, se presenta la necesidad de contar con herramientas simplificadas (para usuarios no especialistas en modelado), de diagnóstico rápido, para analizar el impacto energético y económico de posibles modificaciones en el diseño de las viviendas. Aquí se desarrolla una herramienta de este tipo, a partir de correlacionar los resultados de simulación BEM (Building Energy Modeling) de múltiples casos con la variación de algunos parámetros constructivos relevantes. El trabajo se divide en varias etapas: inicialmente se definen los parámetros relevantes a modificar y su rango de variación; luego se simulan (en EnergyPlus) múltiples casos variando los parámetros elegidos y obteniendo la demanda energética para períodos de calefacción y refrigeración; luego se desarrolla y configura un modelo subrogado (red neuronal) a partir de los resultados de las simulaciones; y finalmente se elabora una herramienta de evaluación (hoja de cálculo) del consumo energético y de impacto económico de los cambios, a partir de una estimación de los costos y de los ahorros energéticos generados. Se realizaron más de 3000 simulaciones y se logró reproducir los resultados de manera muy satisfactoria.

**Keywords:** Building Energy Modeling, Artificial Neural Networks, Techno-economic evaluation.

**Abstract.** For the design of more thermally efficient homes, there is a need for simplified tools (aimed at non-specialist users in modeling), for quick diagnosis, to analyze the energy and economic impact of potential modifications to the design of these homes. Here, a tool of this kind is developed by correlating the results of Building Energy Modeling (BEM) simulations from multiple cases with variations in relevant construction parameters. The work is divided into several stages: initially, the relevant parameters to be modified along with their range of variation are defined; then, multiple cases are simulated (using EnergyPlus) by varying the chosen parameters and obtaining energy demand data for heating and cooling periods; next, a surrogate model (neural network) is developed and configured based on the simulation results; and finally, an evaluation tool (spreadsheet) for energy consumption and economic impact of changes is created, based on an estimation of costs and the energy savings generated. Over 3000 simulations were conducted, and the results were successfully reproduced.

## 1. INTRODUCCIÓN

En el marco de un asesoramiento realizado a dos instituciones públicas de Uruguay, Dirección Nacional de Energía y a MEVIR (Movimiento de Erradicación de la Vivienda Insalubre Rural), para el análisis de diferentes tipologías constructivas de viviendas que se están implementando en Uruguay, se trabajó en el desarrollo de una herramienta simplificada para asistir a la toma de decisiones con respecto al diseño de las mismas. La finalidad de la herramienta es dar insumos para analizar de forma ágil y sencilla el impacto energético y económico de posibles modificaciones en el diseño de la envolvente de las viviendas de la tipología “Cardal” en sus dos versiones (“Tradicional” y “Madera”), ubicadas en dos localidades de Tacuarembó y Rivera. Tomando como base las tipologías ya construidas, la herramienta de cálculo es capaz de determinar el ahorro energético y económico al variar de forma moderada la composición material de la envolvente opaca (cubierta y muros exteriores), así como la orientación de la misma.

En la tesis de Signor (1999) se encuentra un antecedente a nivel regional (Brasil) de elaboración de correlaciones de consumo energético de edificios para refrigeración, a partir de resultados de simulación energética de edificios (BEM) de modificaciones en la envolvente. En ese trabajo, las correlaciones elaboradas son lineales con alrededor de 10 parámetros de entrada. En lo que respecta a la combinación de redes neuronales artificiales (RN) y modelos BEM, se puede mencionar el trabajo de Harbinger et al. (2023), en el que se utiliza una red multicapa perceptrón como modelo subrogado, con fines de calibrar un modelo BEM, es decir, para encontrar los parámetros físicos que resultan en una mejor concordancia entre las mediciones y los resultados del modelo. El uso de RN resulta en un proceso de calibración con menor requerimiento computacional y por ende de menor tiempo. En Fathi et al. (2019) se indica que los trabajos publicados entre 2015 y 2018 se han enfocado principalmente en predecir el consumo de electricidad, calefacción y refrigeración, y energía total en edificios tanto urbanos como comerciales obteniendo métricas aceptables.

Para obtener un modelo subrogado de un modelo de EnergyPlus, debido a que se constata la relación no lineal entre algunos parámetros de interés y la demanda y a la gran potencialidad presentada por la combinación de RN y modelos BEM, en este trabajo se opta por el uso de redes neuronales tipo perceptrón multicapa.

## 2. METODOLOGÍA

La metodología elegida se puede resumir de la siguiente manera:

- 1 A partir de un análisis de resultados previos, se elige un conjunto de parámetros constructivos de interés, los cuales se entiende afectan significativamente al consumo de energía para acondicionamiento.
- 2 Se configura el conjunto de simulaciones en EnergyPlus, estableciendo el rango de variación de cada parámetro así como su división, y se realizan la totalidad de simulaciones. Se extraen los resultados de consumo de calefacción y refrigeración para cada temporada (fría y calurosa) y se incorporan a un archivo de datos en los que también se detallan los parámetros utilizados.
- 3 Se configura una red neuronal utilizando PyTorch (Pazke et al., 2019), la cual se entrena y testea con los parámetros y resultados de las simulaciones antes mencionadas. Una vez obtenidos resultados satisfactorios, se extrae el conjunto de coeficientes de la red y se la reconstruye en una hoja de cálculo.
- 4 En la hoja de cálculo se incorpora una base de datos de propiedades físicas de materiales, con la posibilidad de elegirlos para conformar la envolvente; la orientación; así como la posibilidad de realizar un análisis económico.

## 2.1 Caso de estudio y selección de parámetros

La tipología “Cardal” de MEVIR, tiene una disposición que separa las áreas de dormitorios de las áreas de estar (Figura 1). El estar y la cocina conforman un único espacio siendo un espacio integral. Los dormitorios conforman espacios de mayor privacidad, comunicados por un pasillo (o circulación). La tipología resuelve el cerramiento horizontal como un techo a dos aguas con cielorraso acompañando la pendiente en el sistema tradicional y cielorraso horizontal en el sistema constructivo en madera.




Figura 1: Esquema de tipología Cardal. Las imágenes del centro y derecha muestran la solución constructiva en madera (dos aguas) en orientaciones definidas de 0° y 90°.

Cabe destacar que del análisis previo surge que el período de mayor demanda es el período caluroso, y que en el período frío la demanda es un orden de magnitud más pequeña. A partir del análisis de resultados de las simulaciones en EnergyPlus realizado previamente, se identificaron y seleccionaron las variables de diseño con mayor incidencia en la demanda de energía para acondicionar térmicamente la vivienda, tanto en el periodo caluroso como frío (Figura 2).

Todas las simulaciones se realizaron bajo ciertas hipótesis y/o consideraciones, siendo estas:

- Clima: Se utilizó el año meteorológico típico (Alonso-Suárez et al., 2016) de Rivera con algunas correcciones/adaptaciones.
- Ocupación y criterios de apertura y cierre de ventanas y protecciones solares de un “usuario eficiente”, el cual toma decisiones sobre la apertura y cierre de ventanas y protecciones solares según sea conveniente para minimizar las demandas de energía.
- Criterio de confort adaptativo (ASHRAE Standard 55:2017). Es decir, se determina la demanda necesaria para mantener un mínimo nivel de confort.
- Demanda de energía de calefacción y/o refrigeración para alcanzar la mínima condición de confort en las habitaciones con ocupantes durante todo el tiempo de permanencia de los mismos.

Bajo estos supuestos se obtuvieron resultados de carga de refrigeración y calefacción para alimentar de datos a las redes neuronales. Se observa que la inclusión de persianas adicionales (M1), la disminución de permeabilidad del edificio (M2) y la inclusión de doble vidrio hermético en las ventanas (M8) tienen muy poco o nulo impacto. Con respecto a la medida M1, se debe aclarar que el caso base ya incluye persianas en los dormitorios, mientras que no las incluye en la cocina y el living/comedor; por lo tanto, la medida de “mejora” implica el cambio de cortinas (incluidas en caso base) por persianas en estas últimas. Con respecto a la medida M6 (U paredes) se observa que impacta negativamente en la demanda anual, lo cual se debe a que en los meses de mayor demanda (calurosos) la pared actúa mayormente como una

superficie de evacuación del calor. En la Tabla 1 se observan los parámetros finalmente elegidos como variables para el estudio consiguiente y su rango de variación utilizado.

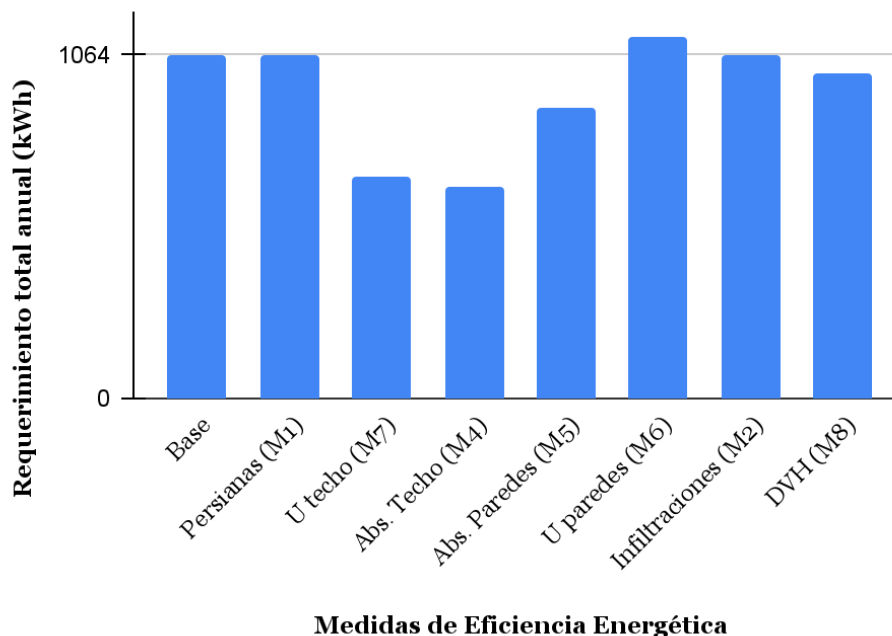


Figura 2: Requerimiento anual de casos Base y con diferentes modificaciones. M1: incorporación de persianas en cocina y living/comedor; M2: disminución de la permeabilidad a las infiltraciones; M4 y M7: disminución de la absorptividad solar y de la conductancia del techo; M5 y M6: disminución de la absorptividad solar y de la conductancia de las paredes; M8: ventanas con doble vidrio hermético.

	Tipología “Tradicional”	Tipología “Madera”
Conductancia térmica de la cubierta	0,28 a 1,45 W/m <sup>2</sup> K	-
Conductancia térmica del cielorraso	-	0,28 a 1,48 W/m <sup>2</sup> K
Absortividad solar de la cubierta	0,20 a 0,60	0,20 a 0,60
Conductancia térmica de los muros exteriores	0,24 a 0,94 W/m <sup>2</sup> K	0,27 a 1,16 W/m <sup>2</sup> K
Absortividad solar de las paredes exteriores	0,20 a 0,60	0,20 a 0,60
Orientación	0 a 359°	0 a 359°

Tabla 1: Rango de variabilidad de parámetros de diseño.

La absorptividad solar cambia con el acabado superficial, tanto de las paredes exteriores como de la cubierta. Por lo tanto, la herramienta permite seleccionar entre un menú de opciones predefinidas. Para esas superficies se asume un valor de emisividad térmica de 0,8, que si bien puede variar para distintas terminaciones, dadas las opciones disponibles se tomó este valor como representativo. La conductancia térmica de la envolvente depende de cómo está constituida la misma. Es decir, con qué materiales y el espesor de cada capa. La herramienta toma como variable la conductancia quedando por fuera la inercia térmica de la envolvente. Por lo tanto, la herramienta permite analizar con muy buena apreciación cambios en la envolvente que no generen grandes cambios en la inercia térmica de la misma. Es decir, que no se afecte

en gran medida la masa de la envolvente respecto a la configuración original.

## 2.2 Configuración y realización de simulaciones en EnergyPlus

Para cada tipología se realizaron todas las combinaciones posibles para 12 orientaciones diferentes (cada  $30^\circ$ ) y para 4 valores de cada una de las demás variables en el rango definido. Esto implica realizar 3072 simulaciones para cada tipología, lo que requiere un tiempo de cómputo de 6 días y 10 horas para cada caso. Para poder realizar esto, al igual que para los estudios previos, se implementó un código en Python utilizando las librerías Eppy que automatiza la generación de los casos, su ejecución y el procesamiento de resultados.

## 2.3 Configuración y entrenamiento de la red neuronal

Originalmente se planteó una estrategia de correlación lineal, tal como se realiza en (Signor, 1999). Sin embargo, se observó tempranamente que la dependencia entre consumo y algunos parámetros relevantes (p.ej. absortividad solar, transmitancia en techos y paredes, orientación) no siguen una dependencia lineal. Esto resulta en significativamente mayores dificultades para encontrar fórmulas adecuadas para las correlaciones.

Por otra parte, las redes neuronales permiten encontrar correlaciones no lineales, en grandes cantidades de datos y de parámetros. Estas consisten en una “red” de neuronas interconectadas (elementos que realizan una operación sencilla sobre datos de entrada y producen una salida), las cuales se distribuyen en “capas”. Las salidas de una capa son entradas para la capa siguiente (ver Figura 3).

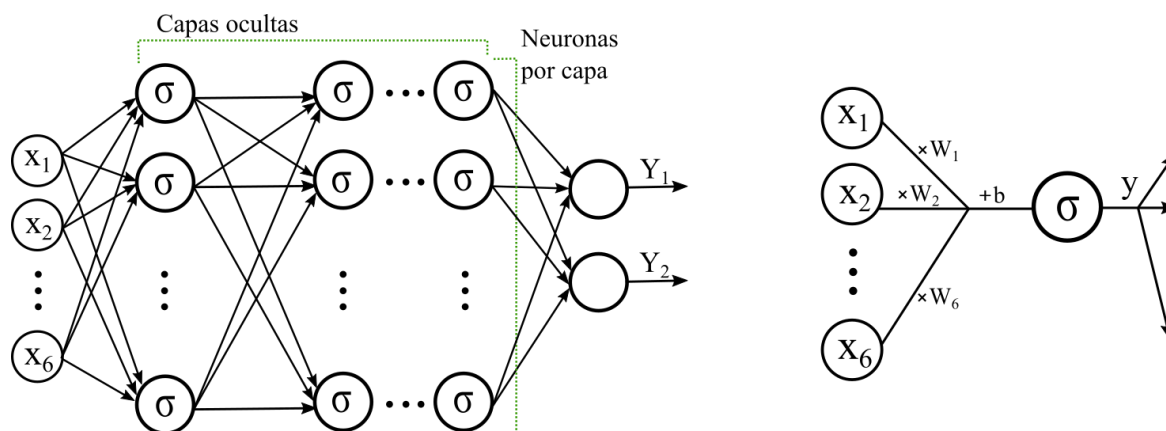


Figura 3: Esquema de red neuronal (izquierda) y esquema de una neurona (derecha).

Las operaciones realizadas por cada neurona consisten en la combinación de una operación lineal sobre las entradas, más un término independiente, y luego una operación no lineal sobre el resultado:

$$y = \sigma \left( \sum_i w_i x_i + b \right) \quad (1)$$

en donde el subíndice  $i$  indica el parámetro de entrada,  $x_i$  representa los valores de entrada a la neurona (salida de la capa anterior);  $w_i$  son los coeficientes que multiplican los valores de entrada (pesos o “weights”);  $b$  es el término independiente (“bias”);  $\sigma$  es una función no lineal (función de activación), la cual generalmente puede ser una función hiperbólica ( $\tanh$  o  $\sinh$ ) o alguna otra (en este caso se utilizó la función LeakyReLU); e  $y$  es la salida de la neurona. La

elección de la función de activación es parte del trabajo de configuración de la red. Para cada neurona de la red, se definen cada uno de estos parámetros. Las salidas de las neuronas de una capa, son entradas para las neuronas de la capa siguiente.

Mediante el uso de algoritmos de optimización, los coeficientes  $w_i$  y  $b$  se ajustan para minimizar el error entre la salida de la red (resultados de demanda) y los valores objetivo (demandas de energía provenientes de las simulaciones). A este proceso se le denomina “entrenamiento de la red”. La elección del algoritmo de optimización es parte de la configuración de la red. Por otro lado, también se debe elegir la función para el cálculo del error (pérdida o “loss” en la jerga de las redes neuronales), el cual será minimizado por el optimizador. En este caso se adoptó el error cuadrático medio (MSE) como función a minimizar.

Del conjunto de datos provenientes de las simulaciones BEM, se separa una proporción (80% en este caso) para el entrenamiento propiamente dicho de la red, y la proporción restante se usa para realizar la validación del funcionamiento de la misma. La elección del grupo de entrenamiento y de validación se hace de forma aleatoria. En general, se considera válido el error obtenido con el conjunto de datos utilizado para la validación.

En este trabajo, las redes neuronales fueron construidas utilizando la librería PyTorch para Python (desarrollada por el Laboratorio de Investigación de Inteligencia Artificial de Facebook).

Los parámetros de entrada para cada caso son los indicados en la Tabla 1, con la salvedad de que la orientación se descompone en dos entradas: seno y coseno del ángulo. De esta forma se constata una mejor convergencia, al suavizar el salto entre el ángulo  $330^\circ$  y  $0^\circ$ . Con esto, el número de entradas de la red es de 6, que alimentan a la primer capa oculta de neuronas.

La configuración de las redes neuronales finalmente utilizada es de 5 capas ocultas de 32 neuronas cada una, y la capa de salida de 2 neuronas (una por cada resultado; en este caso: demanda anual de calefacción y de refrigeración). Para inicializar los coeficientes ( $w_i$  y  $b$  de cada neurona), se utiliza la inicialización por defecto de la clase `torch.nn.Linear`, que utiliza una distribución uniforme de coeficientes en el rango  $(\sqrt{-k}, \sqrt{k})$  siendo  $k$  el inverso del número de entradas de la capa en la que se encuentra la neurona (PyTorch, 2023).

En el procedimiento de entrenamiento, se eligen algunos hiperparámetros como el “learning rate” ( $lr$ ), el cual impone el paso en el que se actualizan los coeficientes, y el número de iteraciones (“epochs”) a realizar antes de dar por terminada la actualización de coeficientes. De hecho, se trabajó con varias corridas de entrenamiento incremental, en las que se elegía adecuadamente el optimizador utilizado (Adam, de primer orden, o LBFGS de segundo) en combinación con el learning rate y el número de iteraciones. Inicialmente se partió utilizando el optimizador Adam, y valores de  $lr$  inicialmente “elevados” ( $5e-4$ ), durante algunos miles de iteraciones, y luego disminuyendo el  $lr$  hasta valores de  $1e-5$ . Al constatar un estancamiento en la disminución del error, se pasó a utilizar el optimizador LBFGS, al cual se le impone un  $lr$  de 1. El total de iteraciones fue de varias decenas de miles. Un entrenamiento completo de la red se completa en algunos minutos, utilizando el CPU de una computadora personal.

Una vez obtenida la convergencia hacia un error considerado adecuado, se descarga todo el set de coeficientes (utilizando el método `state_dict()`) y se reconstruye la red a partir de éstos y de las funciones no lineales de salida de cada neurona, en una planilla de cálculo convencional. En las planillas, por tanto, se realizan las mismas operaciones que en la red neuronal para calcular las salidas (demanda) en función de las entradas (parámetros de la envolvente y orientación).

## 2.4 Armado de la planilla de cálculo (herramienta final)

La herramienta consta de una hoja de cálculo, la cual permite realizar modificaciones en las variables de diseño mencionadas anteriormente, obteniendo como resultado el ahorro energético y económico respecto al caso base, así como el período de repago de la modificación y el VAN (valor actual neto) en un período de 20 años.

Las simulaciones en EnergyPlus, y por consiguiente la correlación, determinan la demanda de energía necesaria para alcanzar el mínimo de confort en un sistema HVAC ideal. Para calcular el consumo de energía real, y posteriormente el costo económico que tiene asociado, se contempló que la demanda se satisface con el uso de un sistema de aire acondicionado frío-calor. Si bien el consumo de energía eléctrica (kWh/año) calculado es teórico, el mismo se determina a efectos comparativos de las diferentes alternativas a analizar y no representa la realidad de los usuarios de las viviendas en estudio.

Bajo estas consideraciones, el consumo de energía eléctrica se calcula a partir del desempeño de un equipo de aire acondicionado comercial, considerando el EER (energy efficiency ratio) y COP (coefficient of performance) en su función de frío y calor respectivamente, según se expresa en las ecuaciones 2 y 3.

$$E_{Ref} (kWh) = \frac{D_{Ref}}{EER} \quad (2)$$

$$E_{Cal} (kWh) = \frac{D_{Cal}}{COP} \quad (3)$$

Una vez determinadas las demandas de energía de la vivienda en su versión original y con modificaciones (a partir de la correlación), se calcula el ahorro (o aumento) de energía demandada y consumida a partir de las modificaciones implementadas. Se determina el ahorro económico (o sobre costo) asociado, considerando el costo unitario (\$/kWh) de la energía eléctrica. El costo de la energía eléctrica es un parámetro con gran incidencia en los resultados, y por lo tanto debe ser seteado de forma precisa. Luego, se determina el VAN a 20 años de uso y el período de repago actualizado de la inversión. Para esto, en primera instancia, se debe conocer la inversión necesaria para realizar la modificación que se está evaluando en la construcción de la vivienda. El VAN se calcula como muestra la ecuación 4.

$$VAN = \sum_{i=1}^{20} \frac{F_i}{(1+k)^i} - I_0 \quad (4)$$

donde  $F_i$  corresponde al ahorro económico anual del año  $i$ ;  $k$  corresponde a la tasa de descuento o el tipo de interés mínimo esperado (se utiliza 5%, de acuerdo a lo indicado por la OPP para proyectos de interés social); e  $I_0$  corresponde a la inversión necesaria. A los efectos de tener un indicador que refleje de manera directa el retorno de la inversión, se calcula el período de repago, como el período necesario para que el VAN alcance un valor mayor que cero.

## 3. RESULTADOS

En la Figura 4 se observan los resultados de demanda para refrigeración y calefacción del caso base de la tipología tradicional, obtenidos por las simulaciones en EnergyPlus (indicado como “datos” en la gráfica) y por el modelo subrogado (indicado como “modelo”), para



distintas orientaciones de la vivienda. Se observa una muy buena concordancia entre datos y modelo. Asimismo, se puede observar el gran impacto de la orientación en la demanda energética. En este sentido, se observa que las orientaciones de  $90^\circ$  y  $270^\circ$  dejan a las ventanas en orientaciones este y oeste, y por ende, en las fachadas que reciben más radiación solar en los meses calurosos, lo cual es coherente con la mayor demanda para refrigeración en estas orientaciones.

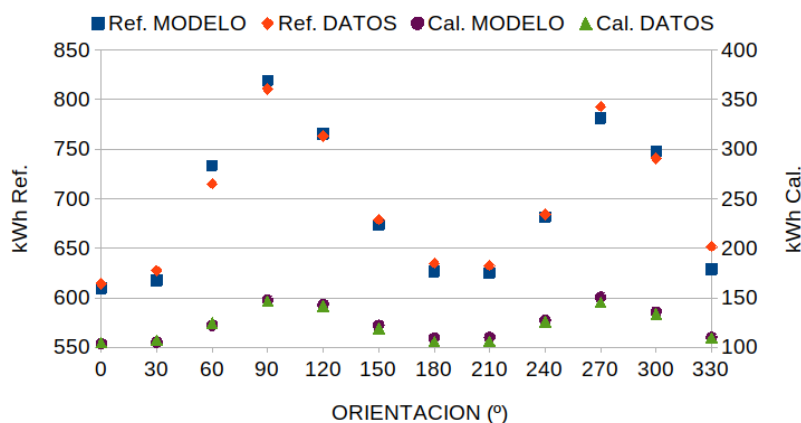


Figura 4: Resultados de refrigeración (izq) y calefacción (der) para el caso base, de simulaciones (DATOS) y del modelo subrogado (MODELO).

En la Tabla 2 se observan los resultados de errores obtenidos para la correlación obtenida para la tipología tradicional. Se observa que para la demanda de Refrigeración (de un orden de magnitud mayor que el de Calefacción) el error relativo máximo es menor al 10% en todos los casos, siendo el error relativo medio menor al 1%. En kWh, los errores máximos absolutos son del orden de 40 kWh, mientras que los errores medios son de menos de 10 kWh. En el caso de Calefacción los errores relativos son mayores debido a que las demandas son menores (y por tanto menos relevantes). Más allá de esto, si bien hay algunos puntos con error relativo alto (del orden del 30%), se trata de casos con demandas muy bajas. El error relativo medio es bajo (del orden del 3%).

En general, se considera que las correlaciones dan resultados muy cercanos a los obtenidos en las simulaciones. Más allá de esto, es posible que para casos en los que los parámetros se alejen de los rangos para los cuales fueron obtenidas estas correlaciones, los errores sean mayores. Asimismo, mediante la realización de más casos y consiguiente entrenamiento de la red, sería posible mejorar los resultados.

En la Figura 5, se observa el comportamiento de la correlación utilizada con valores de entrada diferentes a los utilizados en los datos. En este caso, se grafica la demanda de calefacción y refrigeración calculada variando la orientación de la misma. Se diferencian los puntos para orientaciones utilizados en las simulaciones (0, 30, 60, ..., 300, 330) de los valores intermedios. Se observa que los valores intermedios (los que no fueron utilizados para obtener la correlación) describen una función “suave”, no lineal, del consumo en función de la orientación.

Para mostrar las capacidades de la herramienta de cálculo elaborada, considérese que se desea evaluar el ahorro energético y económico, así como el VAN a 20 años y período de repago de realizar las siguientes modificaciones en el diseño de la solución constructiva tradicional de la tipología “Cardal” de tres dormitorios aislada:



	REFRIGERACIÓN		CALEFACCIÓN	
	Train	Test	Train	Test
Número de datos	2465	617	2465	617
Demanda promedio (kWh)	523,7	530,8	84	81,8
RMSE (kWh)	7,9	10,86	1,75	2,21
Error relativo MAX (%)	7,09 %	7,27 %	28,50%	26,90%
Error relativo MEDIO (%)	1,17 %	1,67 %	3,50%	3,90%
Error absoluto MAX (kWh)	44,3	38	7,9	14,4
Error absoluto MEDIO (kWh)	5,93	8,37	1,34	1,59

Tabla 2: Resultados de error de la correlación para la tipología Tradicional. La columna “Train” agrupa los casos utilizados para entrenar la red, mientras que la “Test” agrupa los casos de testeo.

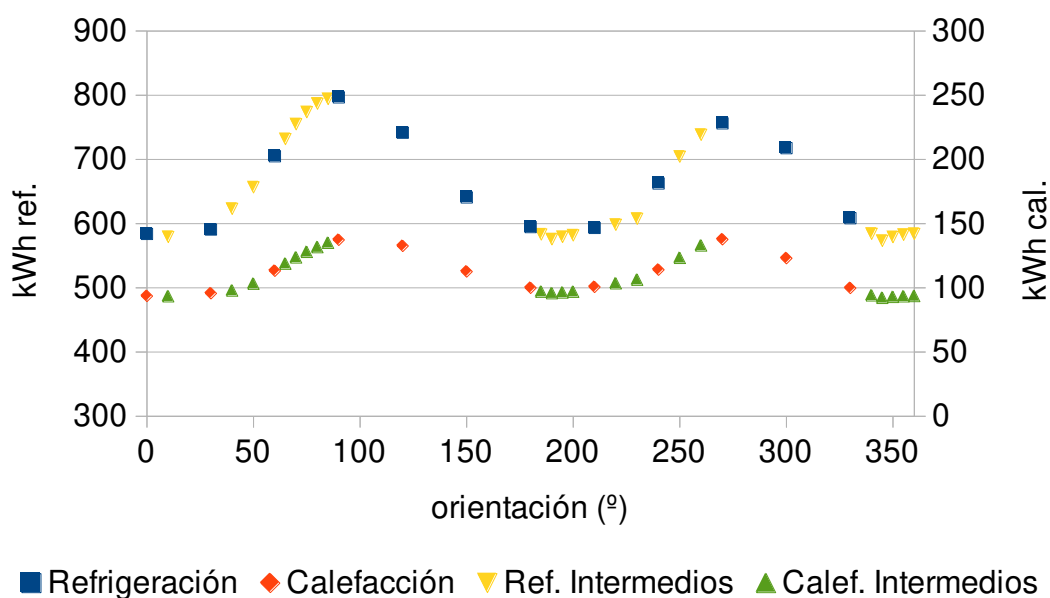


Figura 5: Resultados de demanda de refrigeración y calefacción anual, tipología tradicional, para diversas orientaciones. Los puntos indicados como “intermedios” corresponden a orientaciones no utilizadas en las simulaciones de base (datos de entrada para las correlaciones)

- Reemplazar la cubierta horizontal original por panel sandwich (isopanel) de 150 mm de espesor.
- Aumentar el aislante (EPS) de los muros exteriores de 30 a 50 mm.
- Pintar el exterior de los muros con pintura acrílica mate blanco.

Considerando la orientación  $0^\circ$  se obtiene como resultado un ahorro de la demanda de energía de 311 kWh anuales (refrigeración: 235 kWh, calefacción: 76 kWh) respecto del caso base, lo que significa un ahorro de \$U723 por año en la factura eléctrica. Considerando un sobre costo total en la vivienda de \$U14747, el período de repago es mayor a 20 años y el VAN a 20 años \$5737. Nótese que estos resultados cambian con la orientación de la vivienda. Asimismo, estos resultados se obtuvieron considerando el “usuario eficiente”, pero son fuertemente dependientes del comportamiento de los residentes, tanto debido a su comportamiento en el uso de la vivienda como a través de las condiciones de confort.

#### 4. CONCLUSIONES

Se realizaron simulaciones en EnergyPlus planteando combinaciones de modificaciones a la envolvente de una vivienda, para varias orientaciones, identificando los parámetros de diseño más influyentes en la demanda de refrigeración y calefacción. Se identificaron los parámetros de absortividad solar y conductancia del techo, absortividad solar de las paredes y orientación de la vivienda como parámetros de interés. Combinando un código en Python (librerías Eppy) y EnergyPlus, se realizaron más de 3000 simulaciones por tipología.

Luego, se desarrolló y configuró una red neuronal perceptrón multicapa, utilizando PyTorch, para correlacionar los resultados de demanda con los valores de las variables de entrada. Utilizando una red de 5 capas ocultas de 32 neuronas cada una, combinaciones adecuadas de valores de learning rate, número de iteraciones y algoritmos de optimización (Adam y LBFGS), se logró replicar los resultados de los casos de validación con errores muy bajos. El entrenamiento de las redes se pudo realizar en algunos minutos. Se observa la capacidad de la red de reproducir correlaciones no lineales entre los parámetros y los resultados.

A partir de la reproducción de las operaciones realizadas por la red entrenada en una hoja de cálculo convencional, se logró elaborar una herramienta simplificada para la evaluación de mejoras constructivas y su relación costo-beneficio, orientada a usuarios no especializados.

Se observa un potencial de desarrollo futuro, por ejemplo a través del uso de RN en combinación con modelos BEM para la realización de estudios de calibración u optimización de parámetros de diseño, o la inclusión de parámetros climáticos para la generalización de los modelos subrogados.

#### AGRADECIMIENTOS

Los autores desean agradecer a la Dirección Nacional de Energía, MIEM y a MEVIR por el apoyo financiero y en la propuesta e interés en la realización de este trabajo.

#### REFERENCIAS

- Alonso-Suárez R., Bidegain, M., Abal, G., Modernell, P. Año Meteorológico Típico para Aplicaciones de Energía Solar (AMTUes): series horarias típicas para 5 sitios del Uruguay. Memoria Técnica del LES/UdelaR, versión 2.4, junio de 2016.
- Fathi, S., Srinivasan, R., Fenner, A., Fathi, S., Machine learning applications in urban building energy performance forecasting: A systematic review, *Renewable and Sustainable Energy Reviews*, 133, 2020.
- Glorot, X., and Bengio, Y., Understanding the difficulty of training deep feedforward neural networks. In Proceedings of the thirteenth international conference on artificial intelligence and statistics (pp. 249-256). JMLR Workshop and Conference Proceedings, 2010.
- Herbinger, F., Vandenhof, C., and Kummert, M., Building energy model calibration using a surrogate neural network, *Energy and Buildings*, 289, 2023.
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... Chintala, S., PyTorch: An Imperative Style, High-Performance Deep Learning Library. In Advances in Neural Information Processing Systems 32 (pp. 8024–8035). Curran Associates, Inc, 2019.
- PyTorch. Pytorch Documentation. Class Linear. Accedido en agosto 2023. <https://pytorch.org/docs/stable/generated/torch.nn.Linear.html>
- Signor. Análise de regressão do consumo de energia elétrica frente a variáveis arquitetônicas para edifícios comerciais climatizados em 14 capitais brasileiras. Tesis de maestría,