

## OPTIMIZACIÓN DE DISEÑO DE VIVIENDAS MEDIANTE SIMULACIONES DE CONSUMO DE ENERGÍA UTILIZANDO REDES NEURONALES ARTIFICIALES

1º Congresso de Transição Energética do Norte Fluminense, 1ª edição, de 11/11/2024 a 12/11/2024  
ISBN dos Anais: 978-65-5465-131-8

CALLE; Diego Andrés Vasco <sup>1</sup>, CHÁVEZ; Héctor <sup>2</sup>, TRONCOSO; Tomás Venegas <sup>3</sup>, ROUAULT; Fabien Rouault <sup>4</sup>, ABARCA; Rodrigo <sup>5</sup>, RUBIO; Mauricio <sup>6</sup>

### RESUMO

### RESUMEN

Con el fin de mejorar el nivel de eficiencia energética de viviendas en Chile, el gobierno ha desarrollado un programa para calificar viviendas en una escala estandarizada. Esta calificación requiere que un profesional acreditado evalúe la vivienda utilizando una herramienta que requiere complejos y extensos cálculos.

Para masificar el uso de este esquema de evaluación, se ha desarrollado una herramienta de optimización de diseño de viviendas orientada a cualquier usuario. Esto requiere un modelo simplificado de predicción de consumo de energía de viviendas basado en redes neuronales.

Para entrenar la red neuronal se han generado modelos detallados en EnergyPlus de los arquetipos de viviendas más comunes en Chile. Luego, se ha entrenado en MATLAB una red neuronal para predecir el consumo de energía de una vivienda, en base a 19 variables simples. Esta red presenta una adecuada capacidad de predicción con un valor  $R=0,81$ . La red se ha integrado exitosamente con el modelo de optimización desarrollado en AIMMS.

Las siguientes etapas del proyecto involucran calibrar el consumo de energía predicho por la red neuronal con el nivel de calificación de la herramienta oficial del país y extender el análisis para incluir diferentes climas.

### INTRODUCCIÓN

En la búsqueda constante por impulsar prácticas de construcción más sostenibles y eficientes energéticamente, el desarrollo e implementación de modelos predictivos y herramientas de optimización se han convertido en pilares fundamentales. En este informe se aborda el proceso de integración de un modelo predictivo basado en redes neuronales y la incorporación de restricciones asociadas a la calificación energética de viviendas en un modelo de optimización. Este último tiene como objetivo principal minimizar los costos de inversión, operación y mantenimiento en el contexto de la construcción de viviendas sustentables.

La importancia de este estudio radica en la necesidad urgente de abordar los desafíos asociados con el uso eficiente de la energía en el sector de la construcción. Las viviendas representan una parte significativa del consumo energético global, y mejorar su eficiencia no solo reduce costos a largo plazo, sino que también contribuye a la mitigación del cambio climático y la preservación de recursos naturales.

El enfoque adoptado combina dos áreas clave: la predicción del consumo energético mediante redes neuronales, y la optimización de los recursos en la construcción de viviendas sustentables. La sinergia entre estas disciplinas permite no solo anticipar el comportamiento energético de una vivienda, sino también diseñar estrategias óptimas para minimizar su impacto ambiental y económico.

<sup>1</sup> Universidad de Santiago de Chile, diego.vasco@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

A lo largo de este documento, se detalla el proceso de integración de estos componentes. Se espera que este informe no solo contribuya al avance del conocimiento en el campo de la construcción sustentable, sino también brinde perspectivas prácticas para profesionales y tomadores de decisiones en la industria. El objetivo general del proyecto es integrar un modelo predictivo basado en redes neuronales y la incorporación de restricciones asociadas a la calificación energética de viviendas en un modelo de optimización, con el fin de minimizar los costos de inversión, operación y mantenimiento en el contexto de la construcción de viviendas sustentables.

## METODOS

El cálculo de consumo de energía de viviendas requiere de complejos cálculos en software especializados, lo que limita la evaluación de alternativas de optimización por parte de usuarios finales. Para resolver esta brecha, se ha generado una base de datos de aproximadamente 4000 viviendas, representativa del parque habitacional en Chile a partir de información de censos y encuestas de situación socioeconómica. Con esta base de datos se ha simulado el consumo de energía de calefacción y enfriamiento para el clima de Santiago. Luego, se ha entrenado una red neuronal artificial con el fin de predecir el consumo de energía de una vivienda utilizando como variables de entrada 19 parámetros simples al alcance de un usuario no avanzado (superficie de muros por orientación, materialidad, tamaño de ventanas, etc.). La Figura 1 muestra un diagrama esquemático de la estructura de una red neuronal artificial, donde se indica el flujo de información dentro de ella, desde la capa de entrada, a través de las capas ocultas y hasta la capa de salida. Además, se presenta con mayor detalle la composición de un nodo que representa cada neurona, donde se utiliza la función de activación en base a la información recibida desde las neuronas de la capa anterior. Los valores de pesos se utilizan en cada neurona para cada conexión con neuronas de la capa anterior, mientras que los sesgos (valores  $b$ ) son valores únicos por cada neurona.

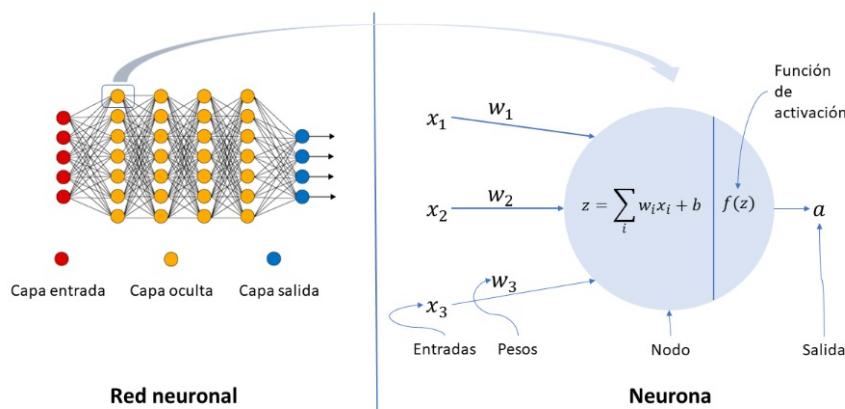


Figura 1 - Diagrama esquemático de una red neuronal y una neurona.

A continuación, se presenta la ecuación que representa las matrices de resultados del proceso de entrenamiento:

$$Y_{2,out} = w_2 * w_1 * X_{1,in} + b_1 + b_2$$

Donde:

- $Y_{2,out}$ : Salida de la red neuronal para la neurona de la capa de salida.
- $w_2$ : Corresponde a los pesos asociados con la conexión entre la neurona de la capa oculta  $w_1 * X_{1,in} + b_1$  y la neurona de la capa de salida  $Y_{2,out}$ . Se representa con una matriz de [1,100].
- $w_1 * X_{1,in} + b_1$  : Es el resultado de la suma ponderada de las entradas  $X_{1,in}$  por los pesos  $w_1$ , más el sesgo  $b_1$ . Esto representa la entrada a la neurona de la capa oculta.
- $w_1$ : Corresponde a los pesos de una capa oculta y se representa con una matriz de [100,19],
- $X_{1,in}$ : Son los parámetros de entrada (superficie de muros por orientación, transmitancias, tamaño de ventanas, etc.) y es una matriz de [19,1],
- $b_2$ : Son los sesgos (sesgos) asociados con la neurona de la capa de salida  $Y_{2,out}$ . Es una matriz de [1,1].

La expresión calcula la salida de una neurona de la capa de salida en una red neuronal, utilizando los pesos y sesgos asociados con las conexiones entre las capas de la red. La salida se calcula a partir de la suma ponderada de las entradas, más un sesgo, todo ello seguido de una función de activación.

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

## ENTRADAS X<sub>1,in</sub>

Las entradas X<sub>1,in</sub> representan los atributos o características de las viviendas que se utilizan como información de entrada para el modelo predictivo de consumo de energía para calefacción. Estas entradas se seleccionan para capturar los aspectos relevantes del comportamiento térmico de las viviendas, manteniendo al mismo tiempo la simplicidad y la eficacia del modelo. A continuación, se describen brevemente las entradas consideradas:

**Área de muros por orientación (4):** Se refiere al área de los muros de la vivienda en cada una de las cuatro orientaciones cardinales (norte, sur, este y oeste). Este atributo permite capturar la exposición de la vivienda a la radiación solar y los cambios de temperatura según la orientación.

**Área de ventanas por orientación (3):** Representa el área total de las ventanas de la vivienda para tres orientaciones (norte, este y oeste). Las ventanas son puntos críticos en la pérdida y ganancia de calor, por lo que su tamaño y orientación son factores importantes a considerar.

**Transmitancia térmica de muros:** Indica la capacidad de los muros de la vivienda para transmitir calor. Este atributo refleja la eficiencia energética de los materiales de construcción utilizados en los muros y su grosor.

**Transmitancia térmica de ventanas (4):** Similar a la transmitancia térmica de muros, pero aplicado a las ventanas. La eficiencia térmica de las ventanas es crucial para minimizar las pérdidas de calor en invierno y el sobrecalentamiento en verano.

**Coeficiente de ganancia solar de ventanas (4):** Indica la capacidad de las ventanas para captar y retener calor solar. Este atributo considera la eficiencia energética de los vidrios utilizados y el diseño de las ventanas en relación con la radiación solar incidente.

**Número de pisos de la vivienda:** Describe la altura de la vivienda en términos de pisos. La altura puede influir en la distribución del calor dentro de la vivienda y en la eficiencia de los sistemas de calefacción.

**Largo de aleros horizontales en ventanas:** Se refiere a la longitud de los aleros horizontales sobre las ventanas. Los aleros pueden proporcionar sombra en verano y protección contra la lluvia, lo que influye en la cantidad de luz y calor que ingresa a la vivienda.

**Nivel de masa térmica asociado a material de particiones interiores:** Indica la capacidad de los materiales de las particiones interiores de la vivienda para almacenar y liberar calor. La masa térmica puede ayudar a regular la temperatura interior y reducir las fluctuaciones térmicas.

## CALIFICACIÓN ENERGÉTICA

La Calificación Energética de Viviendas (CEV) es un sistema implementado en Chile para evaluar y clasificar la eficiencia energética de las viviendas, proporcionando información relevante sobre su consumo energético y promoviendo prácticas de construcción más sostenibles y eficientes desde el punto de vista energético.

## NIVEL DE EFICIENCIA ENERGÉTICA

La calificación energética de viviendas es una estimación teórica de la demanda de energía para calefacción, enfriamiento, agua caliente sanitaria e iluminación, la cual se presenta comparativamente respecto a una vivienda de referencia y se presenta junto a una escala gráfica de ocho niveles, que van desde la "A+" a la "G", siendo la "A+" la que representa una mayor eficiencia energética

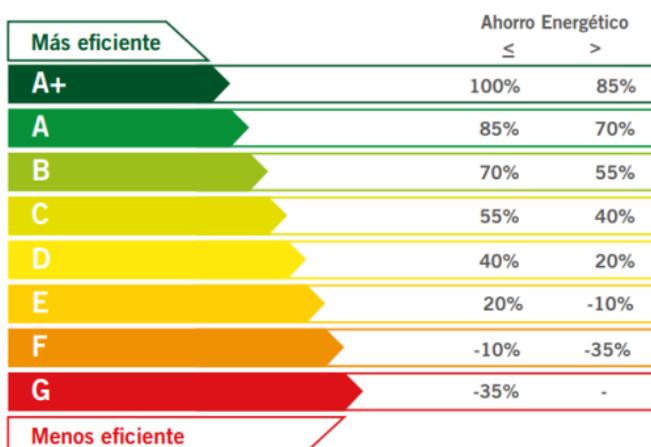


Figura 2 - Nivel de eficiencia energética de viviendas [2]

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

## FORMULACIÓN MATEMÁTICA

Para incorporar la calificación energética de las viviendas en un modelo de optimización, se puede utilizar una formulación matemática que relacione la eficiencia energética de la vivienda con las variables de decisión del modelo.

**Ahorro energético:** se define como una variable de ahorro energético

$$Ah_{\text{energético}} = 100 - E_{\text{total}}/E_{\text{referencia}} * 100$$

Donde:

- $Ah_{\text{energético}}$ : Es el ahorro energético expresado como un porcentaje.
- $E_{\text{total}}$ : Es la demanda total de energía de la vivienda [ $\text{kWh}/\text{m}^2 \cdot \text{año}$ ].
- $E_{\text{referencia}}$ : Es la demanda de referencia, que sirve como base para comparar el consumo energético de la vivienda [ $\text{kWh}/\text{m}^2 \cdot \text{año}$ ].

Esta ecuación permite calcular cuánto se está ahorrando en términos de demanda energética en comparación con una referencia establecida.

**Calificación energética máxima:** El ahorro de energía no puede sobrepasar el límite superior definido por la letra de la calificación ingresada por usuario.

$$Ah_{\text{energético}} \leq Lim_{\text{superior}}$$

**Calificación energética mínima:** El ahorro de energía no puede sobrepasar el límite inferior definido por la letra de la calificación ingresada por usuario.

$$Lim_{\text{inferior}} \leq Ah_{\text{energético}}$$

Las restricciones de la calificación energética son condiciones que se imponen en el modelo de optimización para garantizar que la eficiencia energética de la vivienda cumpla con ciertos estándares predefinidos. La primera restricción se refiere al ahorro energético, que se define como el porcentaje de reducción en la demanda total de energía en comparación con una referencia establecida. Esta restricción asegura que el ahorro energético calculado esté dentro de los límites permitidos para la calificación energética especificada por el usuario. Por otro lado, las restricciones de calificación energética máxima y mínima establecen los límites superiores e inferiores para el ahorro de energía en función de la calificación ingresada por el usuario. Estas restricciones garantizan que el ahorro energético no supere ni caiga por debajo de los valores asociados con la calificación energética seleccionada.

## INTEGRACIÓN Y FORMULACIÓN DEL PROBLEMA

### FUNCIÓN OBJETIVO

El objetivo es minimizar los costos de inversión, operación y mantenimiento de un inmueble nuevo, donde se consideran las envolventes térmicas y el mix de tecnologías disponible para satisfacer la demanda de calor según la calificación energética de viviendas que requiera el usuario.

La función objetivo del modelo de optimización está diseñada para lograr un equilibrio óptimo entre estos componentes, asegurando la eficiencia energética y la viabilidad económica del inmueble nuevo.

Este enfoque busca integrar eficientemente los aspectos técnicos y económicos para proporcionar una solución integral que satisfaga las necesidades del usuario y promueva la sostenibilidad en la construcción de viviendas.

### COSTOS DE OPERACIÓN

Para el funcionamiento de los sistemas de energía que satisfacen la demanda térmica, requieren de consumir energía dependiendo su tecnología. Este viene dado por el requerimiento energético dividido la eficiencia de dicha tecnología.

### COSTOS DE MANTENIMIENTO

Se minimizan los costos asociados con el mantenimiento y operación de la tecnología utilizada para cubrir la demanda térmica.

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

## COSTOS DE INVERSIÓN

Se minimizan los costos de inversión relacionados con la adquisición de materiales para las superficies del inmueble y el mix de tecnologías disponibles para satisfacer la demanda térmica, garantizando la eficiencia energética requerida.

## CONSUMO DE ENERGÍA TÉRMICA

La energía debe ser suficiente para satisfacer la demanda térmica de la vivienda. Para este caso, se considera quéel consumo de energía de la vivienda se determina a través del modelo predictivo. A la expresión se le incorporan variables binarias para la toma de decisión del tipo de material de muro a utilizar (transmitancia) y el tipo de ventana a utilizar (ventana simple o termo panel).

## COMPARACIÓN DE RESULTADOS

El siguiente paso corresponde a la comprobación de la correcta implementación de la estructura de la red neuronal y lectura de la información de entrenamiento en su implementación en AIMMS. Este paso es necesario debido a que la programación de la red neuronal entrenada en MATLAB requiere de ser modificada para ser utilizada por el algoritmo de optimización escrito en AIMMS.

## SELECCIÓN DE CASOS DE COMPARACIÓN

Para realizar este proceso de comprobación de implementación, se han considerado algunos de los arquetipos de vivienda más frecuentes identificados en Molina et al. 2020 [6]. Para los 3 arquetipos más frecuentes, se han considerado todos los casos paramétricos generados para la base de datos de entrenamiento, considerando los diferentes valores de cada variable utilizada para generar los modelos. Los arquetipos seleccionados y sus principales características se muestran en la Tabla 1.

Tabla 1 – Características de los 3 arquetipos más frecuentes.

### Caso

### Superficie

Dormitorios

### Pisos

### Ocupantes

### Condición

### Número de viviendas

1

53,4

2

1

3,4

### Vivienda aislada

540.000

2

78,8

3

1

4,1

### Vivienda aislada

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

470.000

3

50,9

2

1

3,4

Pareada

540.000

#### COMPARACION RESULTADOS MATLAB Y AIMMS

Identificando cada uno de los casos utilizados en la base de datos de entrenamiento de los 3 arquetipos seleccionados, se obtienen los valores de las 19 variables de predicción, y se utiliza esta información para predecir el consumo de energía tanto en la red neuronal entrenada como en la red implementada matricialmente en el modelo de optimización. Dado que estas dos instancias deben representar la misma red neuronal, se espera que los resultados de consumo de energía de calefacción predichos en ambos casos coincidan.

La comparación de valores predichos por la red neuronal la implementación en el modelo de optimización indica una alta similitud en los datos predichos en ambas plataformas. Adicionalmente no se observa ningún sesgo prevalente en las predicciones que permita suponer una desviación sistemática de los resultados. De este modo, cualquier diferencia entre los resultados predichos por ambas plataformas se debe a errores menores de redondeo. La desviación absoluta máxima entre los valores predichos en ambas plataformas no alcanza el 0,001%.

#### COMPARACIÓN RED NEURONAL Y ENERGYPLUS

Se ha realizado un proceso de comparación de predicción de resultados para los 10 arquetipos más representativos de viviendas en Chile según Molina et al. 2020 [6] entre los resultados entregados por los modelos detallados desarrollados en EnergyPlus y los resultados predichos en base a la red neuronal entrenada en base a solo 19 variables simples. De este modo, se han seleccionado todos los casos incluidos en la base de datos cubiertos por los rangos de entrenamiento de la red neuronal de los arquetipos seleccionados. Los 10 arquetipos más comunes seleccionados y sus principales características se muestran en la Tabla 2.

Tabla 2 – Características de los 10 arquetipos más frecuentes.

**Caso**

**Superficie**

**Dormitorios**

**Pisos**

**Ocupantes**

**Condición**

**Número de viviendas**

1

53,4

2

1

3,4

Vivienda aislada

540.000

2

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

78,8

3

1

4,1

Vivienda aislada

470.000

3

50,9

2

1

3,4

Pareada

540.000

4

64,7

3

2

4,1

Pareada

470.000

5

64,3

2

1

3,4

Vivienda aislada

540.000

6

78,8

2

1

3,4

Vivienda aislada

250.000

7

41,8

2

1

3,4

<sup>1</sup> Universidad de Santiago de Chile, diego.vascoc@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

Vivienda aislada

250.000

8

103,1

3

1

4,1

Vivienda aislada

470.000

9

60,1

2

1

3,4

Vivienda aislada

540.000

10

111,8

3

1

4,1

Vivienda aislada

200.000

En la Figura 3 se presenta la comparación de los resultados predichos por los modelos detallados de EnergyPlus (eje X) y los resultados predichos por la red neuronal utilizando solo 19 variables (eje Y). Se puede observar que la mayor parte de los casos se concentran en las cercanías de la recta de 45°. Esto es consistente con el resultado general de entrenamiento que alcanza un valor  $R=0,81$ .

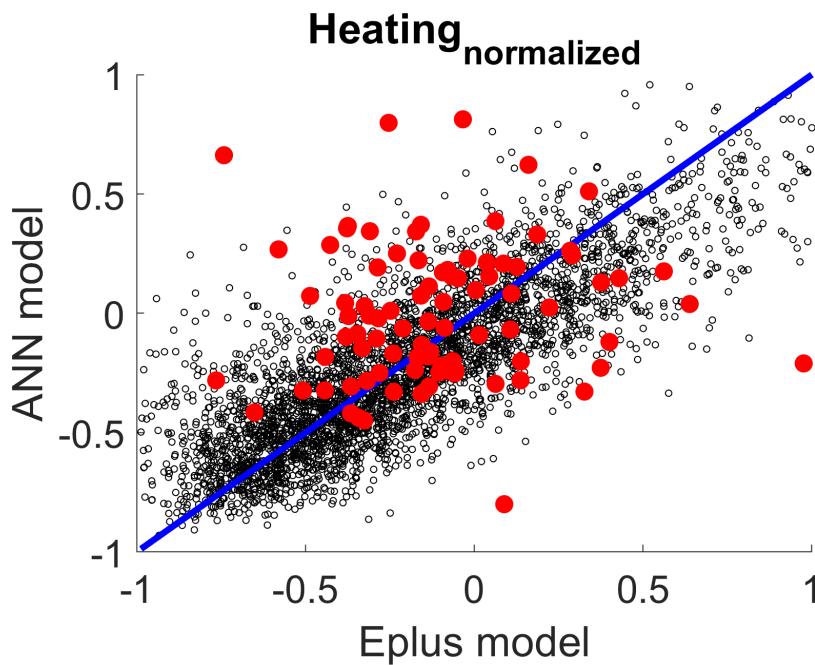


Figura 3 – Grafico de paridad, EnergyPlus vs red neuronal.

## CONCLUSIONES

El trabajo desarrollado ha permitido dar cumplimiento a los hitos planificados del proyecto:

- Se ha implementado en el modelo de optimización una versión matricial de la red neuronal entrenada.
- Se ha transferido de forma exitosa los vectores y matrices del proceso de entrenamiento a la forma matricial de la red implementada en el modelo de optimización.
- A partir de un proceso de revisión por parte del equipo del proyecto se han logrado levantar todas las diferencias en la implementación de la red en ambos modelos utilizados (entrenamiento y optimización)
- Para comprobar los resultados obtenidos de la red entrenada y la implementada en el modelo de optimización se han utilizado los casos correspondientes a los 3 arquetipos mas comunes de viviendas utilizados en el entrenamiento. La comparación de resultados predichos por ambas plataformas muestra una desviación menor a 0,001% para todos los casos analizados. Esto prueba la correcta implementación en el modelo de optimización de la red neuronal en forma matricial y el traspaso de información de entrenamiento.
- Adicionalmente, se ha realizado una comparación de los resultados de predicción de energía obtenidos por la red neuronal basada en 19 variables simples y los modelos detallados desarrollados en EnergyPlus para los casos de viviendas dentro de los rangos de entrenamiento correspondientes a los 10 prototipos de viviendas más comunes, encontrando que la mayor parte de los resultados se encuentran cercanos a la recta ideal de 45.
- Los casos que muestran desviación de resultados predichos de consumo de energía de calefacción entre la red neuronal y los modelos detallados de EnergyPlus no muestran un sesgo prevalente que sobre o subdimensione los resultados, lo que muestra que la red esta entrenada de forma neutra frente a la base de datos de entrenamiento.
- El modelo de optimización ha sido desarrollado hasta tener la capacidad de entregar una predicción de la letra asociada a la calificación de una vivienda analizada. Estos resultados se compararon con la planilla MINVU y están en proceso de calibración utilizando una base de datos ampliada de casos de comparación.

## BIBLIOGRAFIA

- [1] <https://jahazielponce.com/funciones-de-activacion-y-como-puedes-crear-la-tuya-usando-python-r-y-tensorflow/>
- [2] M. de Vivienda y Urbanismo., “Manual de procedimientos calificación de viviendas en chile,” pp. 1–254, 2019. [Online]. Available: <https://www.calificacionenergetica.cl/media/Manual-CEV-2019.pdf>
- [3] M. de vivienda y urbanismo, “Calificación energética de viviendas,” 2018. [Online]. Available: <https://www.calificacionenergetica.cl/media/Calificaion-Energetica-de-Viviendas.pdf>
- [4] D. Legal, “Optimizador Económico para Calificación Energética de inmuebles.” 2023.
- [5] “AIMMS,” p. <https://www.aimms.com/>. [Online]. Available: <https://www.aimms.com>

<sup>1</sup> Universidad de Santiago de Chile, diego.vasco@usach.cl

<sup>2</sup> Universidad de Santiago de Chile, hector.chavez@usach.cl

<sup>3</sup> Universidad de Santiago de Chile, tomas.venegas.t@usach.cl

<sup>4</sup> Universidad de Santiago de Chile, fabien.rouault@imelavi.fr

<sup>5</sup> Universidad de Santiago de Chile, rodrigo.abarca@usach.cl

<sup>6</sup> Universidad de Santiago de Chile, mauro.rubio.marquez@gmail.com

[6] Molina, C., Kent, M., Hall, I., Jones, B., "A data analysis of the Chilean housing stock and the development of modelling archetypes". Energy and Buildings, 206, 109568. <https://doi.org/10.1016/j.enbuild.2019.109568>.

**PALAVRAS-CHAVE:** Envolvente térmica, Optimización, Redes neuronales artificiales, Simulacion de consumo de energia, Sistemas activos de climatización, Vivienda