



# UNIVERSIDAD NACIONAL DE CHIMBORAZO

## DIRECCION DE POSGRADO

Trabajo de Investigación previo a la obtención del Grado de Máster en  
Ingeniería Civil con mención en Gestión de la Construcción

**Desarrollo de un modelo de predicción para evaluar la calidad de una  
edificación utilizando redes neuronales artificiales de propagación hacia  
atrás**

Autor:

Edwin Francisco Tello Oquendo

Tutor:

Ing. Luis Patricio Tello Oquendo, PhD.

Riobamba – Ecuador

Año 2024

## DECLARATORIA DE AUTORÍA

Yo, Edwin Francisco Tello Oquendo, con cédula de ciudadanía 0604236273, autor del trabajo de investigación titulado: **Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás**. Certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mí exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 11 de septiembre de 2024.



Firmado electrónicamente por:  
EDWIN FRANCISCO  
TELLO OQUENDO

---

Edwin Francisco Tello Oquendo

C.I: 0604236273

## DICTAMEN FAVORABLE DEL PROFESOR TUTOR

Quien suscribe, Luis Patricio Tello Oquendo, catedrático adscrito a la Facultad de Ingeniería por medio del presente documento certifico haber asesorado y revisado el desarrollo del trabajo de investigación titulado: *Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás*, bajo la autoría de Edwin Francisco Tello Oquendo; por lo que se autoriza ejecutar los trámites legales para su sustentación.

Es todo cuanto informar en honor a la verdad; en Riobamba, a los 11 días del mes de septiembre de 2024.



---

Ing. Luis Patricio Tello Oquendo, PhD.

C.I: 0604235242

# ACTAS DE SUPERACIÓN DE OBSERVACIONES DE LOS MIEMBROS DEL TRIBUNAL



Dirección de  
Posgrado  
VICERRECTORADO DE INVESTIGACIÓN,  
VINCULACIÓN Y POSGRADO



Riobamba, 3 de septiembre de 2024

## ACTA DE SUPERACIÓN DE OBSERVACIONES

En calidad de miembro del Tribunal designado por la Comisión de Posgrado, CERTIFICO que una vez revisado el Proyecto de Investigación y/o desarrollo denominado "Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás", dentro de la línea de investigación de Ingeniería, construcción, industria y producción, presentado por el maestrante Tello Oquendo Edwin Francisco, portador de la CI. 0604236273, del programa de Maestría en Ingeniería Civil con mención en Gestión de la Construcción, cumple al 100% con los parámetros establecidos por la Dirección de Posgrado de la Universidad Nacional de Chimborazo.

Es todo lo que puedo certificar en honor a la verdad.

Atentamente,



TITO OSWALDO  
CASTILLO CAMPOVERDE

Tito Oswaldo Castillo Campoverde

MIEMBRO DEL TRIBUNAL



Campus La Dolorosa  
Av. Eloy Alfaro y 10 de Agosto  
Teléfono (593-3) 373-0890, ext. 2002  
Riobamba - Ecuador

Unach.edu.ec  
*en movimiento*



Dirección de  
Posgrado  
VICERRECTORADO DE INVESTIGACIÓN,  
VINCULACIÓN Y POSGRADO



Riobamba, 3 de septiembre de 2024

## ACTA DE SUPERACIÓN DE OBSERVACIONES

En calidad de miembro del Tribunal designado por la Comisión de Posgrado, CERTIFICO que una vez revisado el Proyecto de Investigación y/o desarrollo denominado "Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás", dentro de la línea de investigación de Ingeniería, construcción, industria y producción, presentado por el maestrante Tello Oquendo Edwin Francisco, portador de la CI. 0604236273, del programa de Maestría en Ingeniería Civil con mención en Gestión de la Construcción, cumple al 100% con los parámetros establecidos por la Dirección de Posgrado de la Universidad Nacional de Chimborazo.

Es todo lo que podemos certificar en honor a la verdad.

Atentamente,



Ing. Kleber Augusto Jaramillo Galarza, MSc.  
MIEMBRO DEL TRIBUNAL



Campus La Dolorosa  
Av. Eloy Alfaro y 10 de Agosto  
Teléfono (593-3) 373-0880, ext. 2002  
Riobamba - Ecuador

Unach.edu.ec  
*en movimiento*



Riobamba, 3 de septiembre de 2024

## ACTA DE SUPERACIÓN DE OBSERVACIONES

En calidad de miembro del Tribunal designado por la Comisión de Posgrado, CERTIFICO que una vez revisado el Proyecto de Investigación y/o desarrollo denominado "Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás", dentro de la línea de investigación de Ingeniería, construcción, industria y producción, presentado por el maestrante Tello Oquendo Edwin Francisco, portador de la CI. 0604236273, del programa de Maestría en Ingeniería Civil con mención en Gestión de la Construcción, cumple al 100% con los parámetros establecidos por la Dirección de Posgrado de la Universidad Nacional de Chimborazo.


Es todo lo que podemos certificar en honor a la verdad.

Atentamente,



Escaneado, el contenido pertenece a:  
**LUIS PATRICIO TELLO**  
OQUENDO



Ing. Luis Patricio Tello Oquendo, PhD.  
TUTOR



Campus La Dolorosa  
Av. Eloy Alfaro y 10 de Agosto  
Teléfono (593-3) 373-0880, ext. 2002  
Riobamba - Ecuador

**Unach.edu.ec**  
*en movimiento*

# CERTIFICADO ANTIPLAGIO

 UNIVERSIDAD NACIONAL DE CHIMBORAZO	<b>CERTIFICADO DE CONTENIDO DE SIMILITUD</b>		 SGC SISTEMA DE GESTIÓN DE LA CALIDAD UNIVERSIDAD NACIONAL DE CHIMBORAZO
	CÓDIGO:	VERSIÓN:	
	FECHA:		
	MACROPROCESO: PROCESO: SUBPROCESO:		

Riobamba, 11 de septiembre de 2024

## CERTIFICADO

De mi consideración:

Yo Luis Patricio Tello Oquendo, certifico que Edwin Francisco Tello Oquendo con cédula de identidad No. 0604236273 estudiante del programa de Maestría en Ingeniería Civil con mención en Gestión de la Construcción, cohorte Primera presentó su trabajo de titulación bajo la modalidad de Proyecto de titulación con componente de investigación aplicada/desarrollo denominado: Desarrollo de un modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás, el mismo que fue sometido al sistema de verificación de similitud de contenido TURNITIN identificando el 9% de porcentaje de similitud en el texto.

Es todo en cuanto puedo certificar en honor a la verdad.

Atentamente,



Ing. Luis Patricio Tello Oquendo, PhD.

CI: 0604235242

Adj.-

- Resultado del análisis de similitud



Copia controlada por el SGC UNACH

## **DEDICATORIA**

El presente trabajo de tesis lo dedico a Dios, a la Virgen María Auxiliadora, a mis padres Lupita y Edwin, a mis hermanos Pato y Fer, quienes día a día estuvieron brindándome su apoyo incondicional, su amor y optimismo. También dedico este trabajo a mis amigos y familiares que de alguna manera han sido un apoyo y motivación para la culminación de mi carrera.

*Edwin Francisco Tello Oquendo*



## **AGRADECIMIENTO**

Agradezco a mis familiares por su amor y motivación. A mis padres, Edwin y Lupita, por estar siempre pendientes de mí. Gracias por todo su amor y por enseñarme a perseverar a pesar de las dificultades que surgen en el camino. A mis hermanos Pato y Fer, por su apoyo en cada paso que doy y por su gran ejemplo de esfuerzo y perseverancia.

Quisiera expresar mi sincero agradecimiento a mi tutor Patito, por su apoyo activo a lo largo de la realización de mi tesis. Gracias por los buenos consejos, por todo el tiempo que ha dedicado a que mi trabajo siga adelante y por su valiosa orientación en cada paso que he dado.

*Edwin Francisco Tello Oquendo*

## CONTENIDO

DECLARATORIA DE AUTORÍA.....	
DICTAMEN FAVORABLE DEL PROFESOR TUTOR.....	
ACTAS DE SUPERACIÓN DE OBSERVACIONES DE LOS MIEMBROS DEL TRIBUNAL .....	
CERTIFICADO ANTIPLAGIO .....	
DEDICATORIA .....	
AGRADECIMIENTO .....	
1. INTRODUCCIÓN.....	1
2. OBJETIVOS.....	3
3. ESTADO DEL ARTE .....	4
4. METODOLOGÍA.....	7
4.1 Modelo de evaluación de la calidad de una edificación. ....	8
4.2 Selección del caso de estudio.....	16
4.3 Red neuronal artificial feedforward backpropagation (BP) para evaluar y predecir la calidad de una edificación .....	17
4.3.1 Arquitectura de una red neuronal con alimentación hacia adelante (Feedforward).....	19
4.3.2 Aprendizaje y ejecución .....	22
4.3.3 Algoritmo de propagación hacia atrás (backpropagation).....	23
4.3.4 Entrenamiento por retropropagación del error .....	26
4.3.5 Implementación .....	29
5. RESULTADOS Y DISCUSIÓN.....	32
5.1 Obtención de datos para entrenamiento.....	32
5.2 Arquitectura de la red neuronal artificial.....	32
5.3 Análisis de varios algoritmos en la fase de entrenamiento.....	34
5.4 Validación de la predicción y evaluación de la calidad de una edificación utilizando la red neuronal de propagación hacia atrás.....	35

5.5	Discusión .....	39
6.	CONCLUSIONES Y RECOMENDACIONES .....	43
6.1	Conclusiones .....	43
6.2	Recomendaciones .....	44
7.	BIBLIOGRAFÍA .....	45
8.	ANEXOS .....	51
8.1	Anexo 1. Formulario de evaluación de la calidad de la edificación .....	51

## ÍNDICE DE FIGURAS

<b>Figura 1</b> Esquema de la metodología utilizada en la investigación.....	7
<b>Figura 2</b> Parámetros y factores de evaluación de la calidad de una edificación. ....	9
<b>Figura 3</b> Edificación del caso de estudio para evaluar la calidad.....	16
<b>Figura 4</b> Estructura de una neurona artificial simple.....	18
<b>Figura 5</b> Modelo de red neuronal BP. ....	20
<b>Figura 6</b> Proceso de aprendizaje backpropagation. ....	25
<b>Figura 7.</b> Diagrama de flujo del algoritmo BP. ....	26
<b>Figura 8</b> Arquitectura de la red neuronal artificial de propagación hacia atrás.....	33
<b>Figura 9</b> Resultados de la fase de entrenamiento. ....	35
<b>Figura 10</b> Error cuadrático medio en las fases de entrenamiento, validación y pruebas....	37
<b>Figura 11</b> Resultados de la regresión lineal (predicción) del modelo. ....	37
<b>Figura 12</b> Histograma de error en las fases de entrenamiento, validación, pruebas. ....	38

## ÍNDICE DE TABLAS

<b>Tabla 1</b> Evaluación de la calidad de la edificación en estudio. ....	32
<b>Tabla 2</b> Prueba de los algoritmos de entrenamiento de la red neuronal artificial de propagación hacia atrás. ....	35
<b>Tabla 3</b> Prueba del modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás. ....	39

## RESUMEN

La calidad de una edificación es uno de los criterios importantes de control y un aspecto crítico para las empresas, esto debido a que afecta directamente la eficiencia económica de las empresas y usuarios de las edificaciones. Una evaluación de la calidad subjetiva o no profesional es probable que provoque pérdidas económicas irreparables debido a la mala calidad de los elementos estructurales y no estructurales que componen la edificación. Por ello se realiza esta investigación, para determinar primero los parámetros y factores de un modelo de evaluación de la calidad que comprenda aspectos generales que permitan evaluar cualquier edificación y así empezar a estandarizar la forma de evaluación. En particular se definieron 5 parámetros con 16 factores a evaluar; luego, con el fin de evitar la subjetividad humana en los criterios de evaluación, se diseña e implementa un algoritmo de red neuronal artificial del tipo feedforward backpropagation para predecir la calidad de una edificación. Para ello se utiliza la evaluación de 12 expertos en una edificación de hormigón armado definida como caso de estudio; esas evaluaciones sirven para entrenar, validar y probar el algoritmo de la red neuronal. El entrenamiento del algoritmo se lo hace hasta que el error cuadrático medio final, el error del conjunto de prueba y el error del conjunto de validación sean menores a  $10^{-2}$  y presenten características similares, además, que el valor de R sea mayor al 90% en las salidas de la red, lo que significa que la red neuronal es bastante precisa con los resultados que predice y está lista para usarse.

**Palabras claves:** calidad de una edificación, modelo de evaluación, redes neuronales artificiales, propagación hacia atrás.

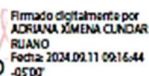
## ABSTRACT

The quality of a building is one of the essential quality control criteria and a critical aspect for companies since it directly impacts the financial efficiency of companies and the users of buildings. A subjective or non-professional quality assessment will likely cause irreparable economic losses due to the poor quality of the structural and non-structural elements that make up the building. Because quality assessment is crucial, this study aimed first to determine the parameters and factors of a quality assessment model that includes general aspects that allow the assessment of any building and thus begin to standardize how people perform assessment. In particular, the researcher defined five parameters with 16 assessment factors. The parameters help avoid human subjectivity in the assessment criteria. This study designed an artificial neural network algorithm of the feedforward backpropagation type. The implementation of the algorithm was valuable to assess the quality of a building. To do this, 12 experts assessed a building with solid concrete reinforcement. The building was the case study that provided evidence for the present research. The building assessment was valuable for training, validating, and testing the neural network algorithm. The training algorithm is performed until the final mean square error and the validation set error is less than two. In addition, the R-value is greater than 90% at the network output, which means the neural network is quite accurate with its predicted results. Therefore, the neural network is ready to be used.

**Keywords:** building quality, evaluation model, artificial neural networks, backpropagation.

Reviewed by

ADRIANA  
XIMENA  
CUNDAR RUANO



Firmado digitalmente por  
ADRIANA XIMENA CUNDAR  
RUANO  
Fecha: 2024.02.11 09:16:44  
.0500

MsC. Adriana Cundar Ruano, Ph.D.

**ENGLISH PROFESSOR**

C.C. 1709268534

## 1. INTRODUCCIÓN

La calidad de una edificación es uno de los criterios más importantes de control y un aspecto crítico para empresas y personas. Esto debido a que la calidad de una edificación no solo afecta directamente la eficiencia económica de las empresas y usuarios de las edificaciones, sino que también es más probable que provoque accidentes con pérdidas económicas irreparables e influencia social (Mashwama et al., 2017). Por lo tanto, las empresas y usuarios siempre deben colocar en una posición importante la inspección y evaluación oportuna de la calidad de una edificación para detectar de manera temprana problemas de calidad y reducir los accidentes (Harris et al., 2021).

La evaluación de la calidad de las edificaciones implica muchas variables y contenido. En base a una revisión de literatura y considerando puntos clave para evaluar la calidad de una edificación se definirá un modelo de evaluación de la calidad de una edificación que involucre parámetros clave como la seguridad, economía, estética, servicios, entre otros (Sinha et al., 2017) (Harrison, 1999).

Un problema que existe al evaluar la calidad de una edificación es la subjetividad que se tiene, al considerar que la evaluación la va a realizar una persona o personas que tienen diferentes criterios, pueden sesgar sus respuestas en una respuesta emocional en lugar de objetiva (Johnson, 2012). Esto puede ocasionar que en la evaluación se omitan aspectos que requieren intervención en la edificación, es por eso por lo que se propone utilizar redes neuronales artificiales que permitan predecir esta calidad y así minimizar la subjetividad en el criterio de una evaluación y la omisión de aspectos que podrían resultar importantes dentro de la evaluación, brindando resultados más eficientes y precisos. Esto establece un instrumento de soporte para la gestión de calidad de un proyecto.

Las redes neuronales artificiales (Alaloul et al., 2018) (Liu et al., 2021) simulan la estructura del sistema nervioso con características básicas del cerebro humano mediante un



sistema de procesamiento de información, se basa en la experiencia pasada para aprender y tiene fuerte tolerancia a fallas para información incompleta (Alzakkar et al. 2021).

En esta investigación se utiliza una red neuronal de alimentación hacia adelante y propagación hacia atrás que es una de las redes más utilizadas en este tipo de estudios (Liu et al., 2009) (Waziri et al., 2017). Esta red tiene tres capas, una de entrada, una de procesamiento de información (entrenamiento) y una de salida. De esta manera, utilizando el modelo de evaluación de la calidad, se podrán ingresar esos datos de entrada y con la ayuda de la red neuronal tener un resultado de evaluación que sea más estable, objetivo, científico y brinde un apoyo efectivo a la gestión de la calidad de una edificación.

## **2. OBJETIVOS**

### **Objetivo general**

Determinar un modelo para evaluar la calidad de una edificación e implementar una red neuronal artificial de propagación hacia atrás para predecir la calidad reduciendo la subjetividad de la evaluación humana.

### **Objetivos específicos**

1. Determinar los parámetros de entrada de un modelo de evaluación de la calidad de una edificación.
2. Diseñar e implementar un algoritmo de red neuronal artificial de propagación hacia atrás (BP) para evaluar y predecir la calidad de una edificación con el fin de reducir la subjetividad de la evaluación humana.
3. Validar el algoritmo basado en la red neuronal artificial BP con datos de prueba en la evaluación de la calidad de una edificación.

### 3. ESTADO DEL ARTE

La evaluación de la calidad de edificaciones se ha estudiado en algunos países, sobre todo la evaluación de la calidad de edificaciones tipo vivienda. Pese a la importancia de este tema, en el Ecuador se han realizado pocos estudios relacionados. En la práctica, las empresas constructoras, las inmobiliarias, los constructores locales y los dueños de edificaciones se limitan a concluir una obra y ponerla a funcionar, dejando de lado la evaluación de la calidad de la edificación post construcción. Esto se debe a que, en su gran mayoría, se hacen mantenimientos o arreglos correctivos cuando existe algún daño, lo cual puede ser peligroso para los usuarios. Además, se tiene poco interés de conocer si la edificación es segura y de calidad.

Históricamente, existen algunas investigaciones que evalúan la calidad de una edificación, Kutty (1999) estudia la calidad estructural de las edificaciones en Estados Unidos como un aspecto determinante para evaluar la calidad de una edificación, dentro del estudio se revela que la adecuación estructural está asociada con factores económicos y de ingeniería, como la antigüedad del edificio y el tipo de estructura. Otros factores influyentes son la ubicación, la calidad del vecindario, la densidad de habitaciones, la calidad del sector donde está ubicado, la seguridad del sector, los servicios públicos existentes, el acceso al trabajo y otras comodidades. El autor se centra en valorar la estructura y la zona donde está ubicada la edificación para evaluar la calidad de la edificación, no estudia las características internas de las edificaciones que también son importantes. La evaluación lo hace mediante encuestas a usuarios por lo que la evaluación depende de la percepción que tengan los mismos.

Al-Momani (2003), evalúa la calidad de viviendas en Jordania, identifica variables categorizadas en 10 grupos como el diseño exterior del edificio, diseño interior del edificio, funcionalidad de los espacios internos, tamaño de los espacios, materiales utilizados, tipo de

vecindario, proximidad a instalaciones comunitarias, espacio al aire libre, sistema de calefacción y aislamiento y gastos de mantenimiento de la vivienda. El autor se centra más en el diseño de las viviendas, dejando de lado a los otros aspectos debido a que por la zona en donde están las viviendas resulta importante el diseño y la relevancia cultural del mismo. La evaluación la hace mediante un cuestionario dependiendo así el resultado de la persona que lo haga.

Sengupta y Tipple (2007), reconocen que la calidad en una edificación es difícil de medir directamente; sin embargo, evalúan la calidad de una edificación en Asia con cuatro indicadores principales: la solidez estructural, la conexión a servicios básicos, la ubicación y las características del sitio. Los autores evalúan la calidad de manera externa y guiándose más al sitio en donde está la edificación, no evalúan aspectos de la edificación como tal.

Kurian y Thampuran (2011) mencionan que la percepción de calidad de una edificación varía ampliamente según las perspectivas de las personas. Los investigadores realizaron en Kerala, India, un estudio de la evaluación de la calidad de una vivienda, en donde los principales indicadores que evaluaron fueron: ubicación, infraestructura, diseño, estética, materiales y técnicas de construcción, sostenibilidad, concepto de la vivienda; se realizó un cuestionario en donde evaluaban cada parámetro en función de la importancia que cada encuestado daba a cada indicador. El orden de importancia que se desprende del estudio respecto a la calidad de una vivienda es: materiales y técnicas de construcción, sostenibilidad, estética, concepto, infraestructura, diseño y ubicación.

Pérez y Elena (2014) realizan una investigación sobre la evaluación de viviendas construidas en serie, en donde los factores a evaluar se distribuían en tres grupos. En el primer grupo estaban la firmeza de la edificación, durabilidad y aislamiento en base a los materiales utilizados. En el segundo grupo estaban la adaptabilidad climática, soleamiento y ventilación. Finalmente, en el tercer grupo se evaluaba la funcionalidad, el diseño de los

espacios y su organización. Los autores hacen énfasis que la evaluación puede ser relativa en función de la percepción del evaluador.

Los estudios mencionados han evaluado la calidad de edificaciones y viviendas en función de encuestas en su mayoría; sin embargo, siempre dependiendo solamente del criterio personal del evaluador o evaluadores.

En base a los estudios citados, se puede crear un listado de parámetros de evaluación de la calidad de una edificación que abarque algunos factores críticos con el fin de generalizar los criterios de evaluación.

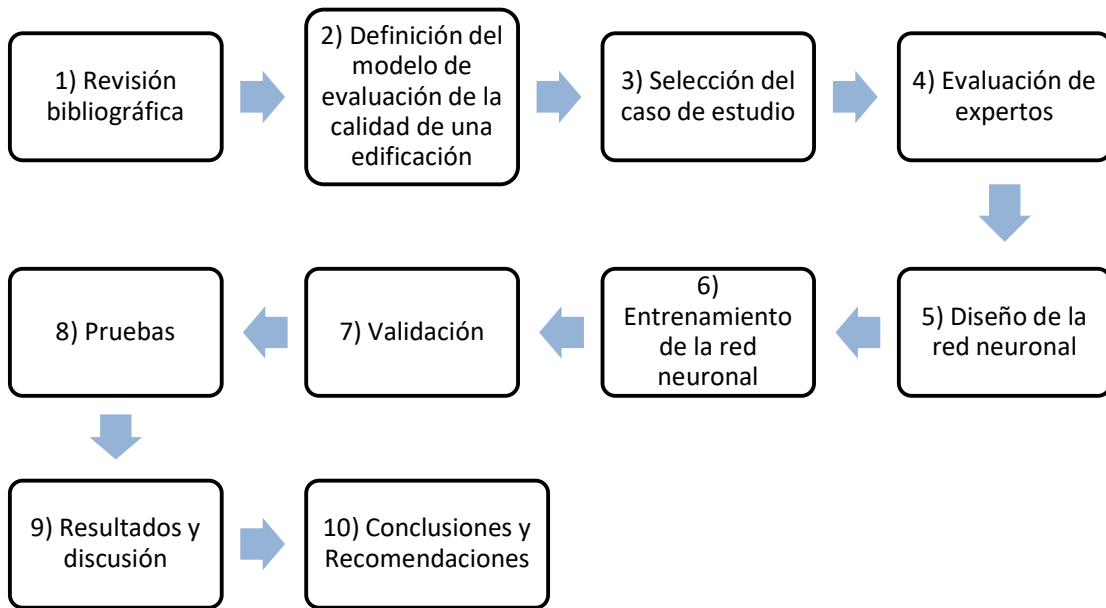
Por otra parte, se ha establecido que las redes neuronales artificiales son potentes herramientas para tareas de reconocimiento y clasificación de patrones que funcionan como una caja negra para aprender estructuras significativas en los datos (Waziri et al., 2017). En el área de la construcción e ingeniería civil, las redes neuronales se han aplicado con éxito para predecir precio de licitaciones, costos de construcción, productividad laboral, operaciones de movimiento de tierras, en etapas de precalificación de contratistas, gestión de la construcción, cuantificación y estimación de margen de riesgo. Esto gracias a que tienen el potencial de manejar datos ruidosos y lograr predicciones y pronósticos confiables y de alta precisión (Jain et al., 2014). Las redes neuronales también se han integrado con varios paradigmas de informática blanda, como el razonamiento basado en casos y diversos algoritmos de optimización, con el fin de mejorar la precisión, el ajuste excesivo e insuficiente de los datos y velocidad de convergencia (Haykin, 2009).

#### 4. METODOLOGÍA

Se siguió el proceso que se presenta en la figura 1 para desarrollar esta investigación.

**Figura 1**

*Esquema de la metodología utilizada en la investigación.*



*Nota.* La figura muestra los pasos de la metodología usada en esta investigación.

Primero se realizó una revisión bibliográfica utilizando bases de datos científicas como Google Scholar, Scopus, Scielo y ScienceDirect, para obtener información relacionada sobre los parámetros para evaluar la calidad de una edificación, así como para el diseño de la arquitectura de la red neuronal *feedforward backpropagation*.

Con la revisión bibliográfica se definieron los parámetros de evaluación y los factores que componen cada parámetro, luego se seleccionó un caso de estudio para obtener datos de 12 evaluadores expertos referente a los parámetros de evaluación definidos. Estos datos servirán como entrada a la red neuronal con el fin de predecir la calidad de una edificación.

El alto o bajo nivel de calidad está representado por los factores de evaluación de la calidad y se asigna a cada factor un valor diferente para medir su nivel. Con base en las características de la evaluación de calidad de una edificación y referencias relacionadas (Kutty, 1999) (Al-Momani, 2003) (Sengupta y Tipple, 2007) (Kurian y Thampuran, 2011) (Pérez y Elena, 2014) este documento dividió la calidad de una edificación en cinco grados, a saber: muy malo, malo, regular, bueno, muy bueno y fueron asignados los valores {1,2,3,4,5}, respectivamente. Si el rango objetivo está entre dos grados adyacentes, entonces la asignación correspondiente será {0.5 ,1.5, 2.5, 3.5, 4.5}, respectivamente.

Los expertos califican cada factor de evaluación de calidad de acuerdo con el estándar de puntuación propuesto. De la misma manera, al final califican la calidad de la edificación utilizando el mismo estándar de puntuación, basado en las calificaciones que han puesto en cada factor. Después se realizaron los pasos para diseñar y aplicar la red neuronal al problema de evaluar la calidad de una edificación (entrenamiento, validación, pruebas).

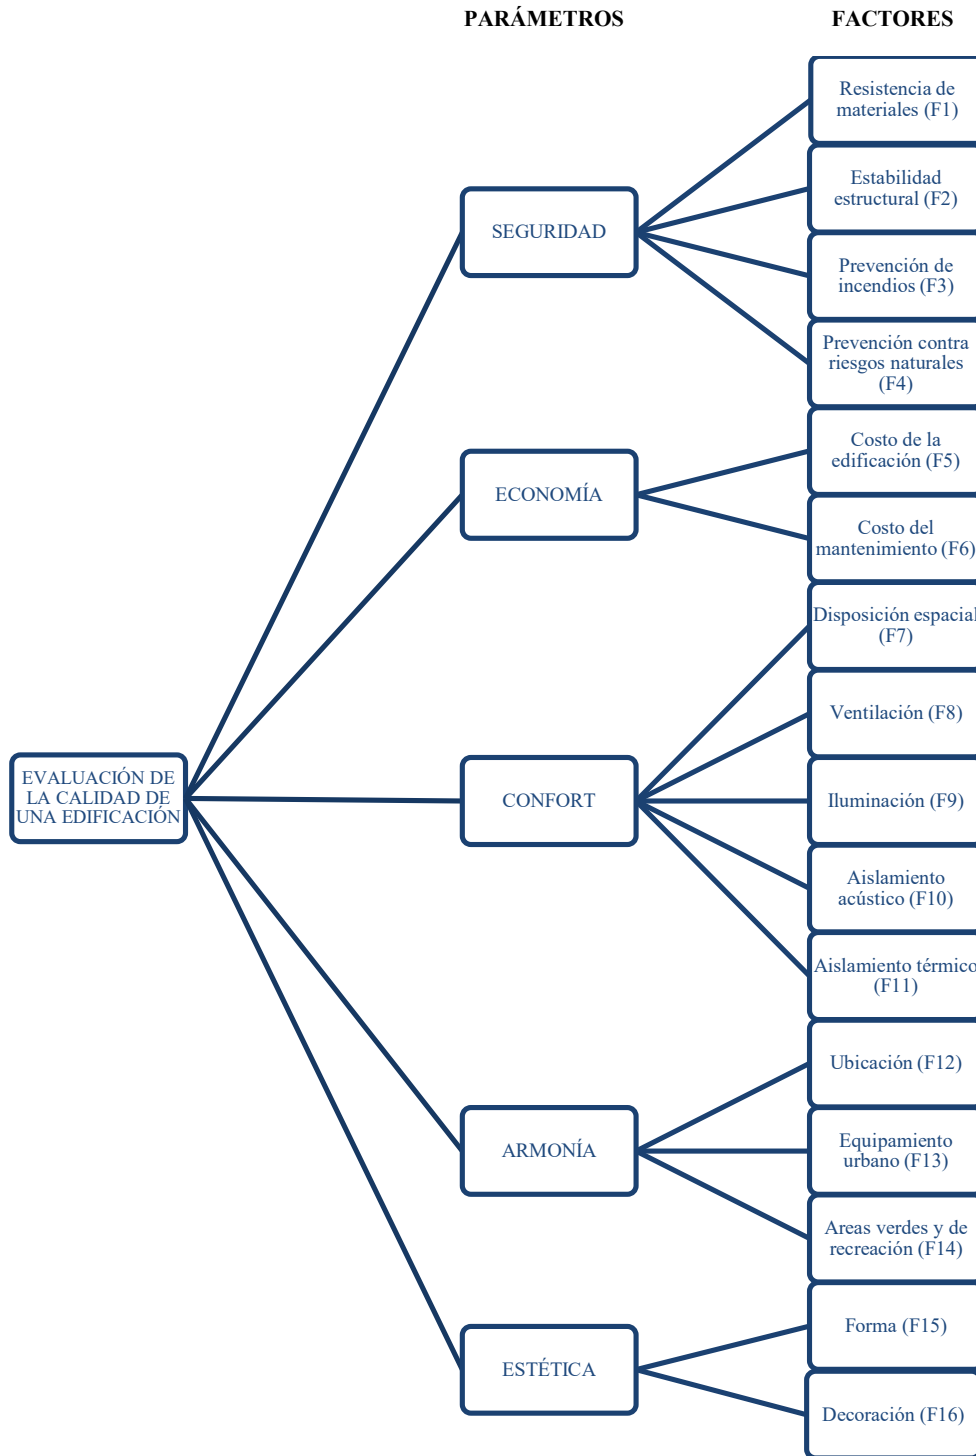
Posteriormente se presentan los resultados, la discusión y para culminar las conclusiones y recomendaciones.

#### **4.1 Modelo de evaluación de la calidad de una edificación.**

Teniendo como base la bibliografía revisada se propone la siguiente matriz que abarca a manera más general parámetros importantes para evaluar la calidad de una edificación, teniendo cada uno de estos factores de evaluación que los componen.

**Figura 2**

*Parámetros y factores de evaluación de la calidad de una edificación.*



*Nota.* La figura muestra los 5 parámetros generales para realizar la evaluación de la calidad de una edificación, cada uno de estos con factores de evaluación específicos en total 16.



Para la evaluación de la calidad de una edificación se proponen cinco parámetros a evaluar, los mismos que son:

## **1. Seguridad**

Dentro de este parámetro los factores a evaluar serán:

- Resistencia de materiales (F1)

Para esta evaluación, si se tienen ensayos completos y favorables de los materiales que se utilizaron en la construcción, se considera una valoración de 4 a 5; en caso de no haberlos, se debe hacer una inspección visual considerando lo siguiente (Alvarado y Escudero, 2021) (Cortes y Perilla, 2017) (Abitante et al., 2007):

- Revisión exhaustiva de todos los elementos estructurales visibles como columnas, vigas y losas. Se busca activamente grietas, fisuras, pérdida de sección transversal, desplazamientos o deformaciones que podrían indicar debilidad estructural o falla potencial.
- Revisión de las condiciones de superficies como paredes, revestimientos y acabados. Se examina la condición superficial de los materiales, como hormigón, acero, madera, plástico, cerámicas u otros, para detectar corrosión, desgaste, disgregación, deterioro o rotura debido a factores ambientales, de uso o de carga.
- Revisión de las conexiones y detalles constructivos. Se inspeccionan las conexiones entre elementos estructurales para asegurar que estén correctamente ejecutadas y no presenten deterioro. Se examinan detalles como juntas, anclajes y refuerzos para verificar que estén en buen estado y cumplan con las especificaciones de diseño.

Si las revisiones antes detalladas son satisfactorias se deberá dar un puntaje de hasta 4; en caso de que sean satisfactorias solo parte de ellas, el puntaje irá bajando hasta evaluar con 0 cuando no se cumpla con ninguna de las revisiones.

- Estabilidad estructural (F2)

Para evaluar este factor, si se tiene un estudio estructural aprobado y la edificación cumple con lo que dice el estudio se lo valora con un puntaje de 4 a 5. En caso de no existir, se debe evaluar la estabilidad estructural mediante una inspección visual teniendo en cuenta las consideraciones expuestas en la “Guía para evaluación sísmica y rehabilitación de estructuras de la Norma Ecuatoriana de la Construcción (NEC, 2015)” y lo expuesto por Cortes y Perilla (2017) y Fagua y Zapata (2019):

#### Configuración estructural en planta

Se debe considerar que la longitud de la edificación no exceda 4 veces su ancho. En planta la disposición y forma de elementos estructurales no debe tener plantas irregulares (en forma de T, O, U, H, L, Cruz, etc.), en donde se evidencian sitios con ángulos en la estructura que concentran esfuerzos. Los retrocesos en las esquinas de la edificación no deben exceder el 15% de la dimensión de la planta. Los ejes estructurales deben ser paralelos.

#### Configuración estructural en elevación

La edificación debe tener ejes verticales continuos, en caso de tener muros, estos no deben estar soportados por columnas. No deben existir pisos débiles o que generen discontinuidad en la edificación. Las columnas deben ser más fuertes que las vigas (el área de las columnas debe ser mayor al de las vigas). No deben existir columnas cortas o esbeltas en la edificación. La

edificación debe tener una distribución y concentración de masas uniforme en todos los pisos y deben tener una regularidad geométrica.

Si la edificación cumple con los aspectos antes detallados se lo puede valorar con una calificación de hasta 4, si cumple parcialmente la calificación irá bajando en función del número de aspectos que cumpla hasta llegar a 0 que quiere decir que no cumple con ninguno de los aspectos.

- Prevención de incendios (F3)

Si la edificación cuenta con un estudio y diseño de sistemas contra incendio y está construido como lo indica el estudio, la calificación será de 4 a 5 en función del cumplimiento de la “Norma Ecuatoriana de la Construcción Contra Incendios (NEC-HS-CI: Contra Incendios)”. En caso de no existir, se debe verificar si en la edificación existen sistemas de detección, alarma y medios de extinción contra incendios. Si existen los aspectos antes mencionados se dará una calificación de hasta 4; la calificación irá bajando en función de los aspectos que no se cumplan hasta dar una calificación de 0 cuando no cumpla ninguno.

- Prevención contra riegos naturales (F4)

En este factor se debe evaluar si la edificación cuenta con sistemas de drenaje para control de inundaciones, protección contra vientos, señalización de rutas de evacuación, puntos de reunión seguro, generación de luz en caso de cortes (Estrada, 2015) (León y Camacho, 2014). Se realizará la calificación en función de los cumplimientos de los aspectos antes mencionados siendo 5 cuando cumpla todos y 0 cuando no cumpla ninguno.

## **2. Economía**

En este parámetro se evalúan dos factores (Le et al., 2018) (Che-Ghani y Ali, 2016) (Arencibia, 2007):

- Costo de la edificación (F5)

Mientras menor sea el precio por metro cuadrado de construcción de la edificación en función de edificaciones cercanas, mayor será el puntaje de evaluación.

- Costo del mantenimiento (F6)

Se evalúa el valor que se paga para que la edificación funcione con normalidad y en buen estado. Si la edificación cuenta con un plan de mantenimiento se dará una calificación de 4 a 5; en caso de no tener, se debe evaluar la manera en que se gestionan los mantenimientos y en función de aquello dar una calificación.

## **3. Confort**

Dentro de este parámetro se evalúan los factores:

- Disposición espacial (F7)

Se evalúa la distribución de los espacios, la funcionalidad de cada área, la fluidez en la circulación, las conexiones entre los espacios que tiene la edificación, la accesibilidad universal y seguridad. (Iyengar, 2015) (Grabow y Spreckelmeyer, 2014).

- Ventilación (F8)

Se evalúa si la edificación tiene espacios suficientemente ventilados sea de forma natural, mecánica o híbrida, de manera que se garantice buena calidad del aire al interior, eliminación de posibles contaminantes, control de la

temperatura interior y control de la humedad (Jiang et al., 2023) (Yarke, 2005).

- Iluminación (F9)

Se evalúa que los espacios de la edificación tengan una buena iluminación, sea esta natural o artificial, de manera que no existan espacios oscuros. La correcta iluminación es importante porque reduce el estrés visual y la fatiga ocular especialmente en entornos de trabajo y estudio, mejora la calidad del sueño y salud en general. (Ozenen, 2023).

- Aislamiento acústico (F10)

Se evalúa si entre los espacios de la edificación existe aislación acústica, de manera que se disminuya el impacto de la contaminación sonora, como el ruido de tráfico, conversaciones y maquinaria, lo que contribuye a un entorno más tranquilo y confortable para los ocupantes (Berghlund et al., 2018) (Basner et al., 2014).

- Aislamiento térmico (F11)

Se evalúa si la edificación está construida de manera que no exista calor ni frío extremos, de manera que se mejore la eficiencia energética, el confort y la sostenibilidad del edificio. (Pérez-Lombard et al., 2008).

La evaluación de estos factores es importante debido a que los mismos permiten tener una buena calidad de vida a los usuarios, son los factores que hacen que al usuario le guste o no la permanencia en la edificación y lo hacen sostenible a largo plazo. Tiene beneficios significativos en términos de salud, productividad, eficiencia energética y valorización de la edificación.

#### **4. Armonía**

Los factores para evaluar en este parámetro son:

- Ubicación (F12)

Se evalúa el vecindario donde está ubicada la edificación, la ubicación tiene un impacto significativo en el valor inmobiliario de una propiedad, puede influir en el impacto ambiental de una edificación, puede afectar la integración social y económica de los residentes (Musa y Yusoff, 2015).

- Equipamiento urbano (F13)

Se evalúa si cerca de la edificación existen centros de educación, centros comerciales, centros de salud, mercados, estaciones de transporte. servicios que. Un buen equipamiento urbano mejora la calidad de vida y la conveniencia para los residentes, facilita el acceso a los servicios y reduce el tiempo de desplazamiento (Rehman y Jamil, 2021).

- Áreas verdes y de recreación (F14)

Se evalúa si la edificación cuenta con áreas verdes y de recreación dentro o fuera del edificio, las mismas que proporcionan esparcimiento y el descanso a los habitantes, lo que aporta al bienestar mental y físico de los mismos y fomentan su interacción social y comunitario (Wan et al., 2021) (Jennings y Bamkole, 2019).

## **5. Estética**

Se evalúa el impacto visual y la percepción agradable o no que genera la edificación en sus ambientes. La estética puede reflejar la identidad y el propósito de una edificación y de sus ocupantes, puede fomentar un sentido de orgullo y bienestar en la comunidad (Grazuleviciute-Vileniske et al., 2021).

Dentro de este parámetro se evalúa:

- Forma de la edificación (F15)
- Decoración de la edificación (F16)

## 4.2 Selección del caso de estudio

Se escogió una edificación en el centro de Riobamba como se muestra en la figura 3. La edificación está conformada por planta baja y tres pisos altos. En planta baja tiene un local comercial y parqueaderos y en los pisos altos tiene tres departamentos por cada piso.

Esta edificación fue elegida debido a que es relativamente nueva, terminada de construir en el año 2022, consta de dos servicios en la misma edificación, local comercial y vivienda y se podía tener fácil acceso a la edificación e información relevante a la construcción para que los expertos realicen las evaluaciones.

### Figura 3

*Edificación del caso de estudio para evaluar la calidad.*



*Nota.* La figura muestra la edificación elegida como caso de estudio, ubicada en Riobamba, provincia de Chimborazo, en las calles Carabobo y Febres Cordero esquina.

Una vez seleccionado el caso de estudio, se realizó la evaluación de expertos. Para esto se elaboró un formulario con los factores a evaluar de la edificación y su calificación (Anexo 1). La evaluación la realizaron 12 expertos que son diseñadores, constructores y profesionales en el área de la construcción y venta de viviendas. Hay que tener en cuenta

que para que la fase de entrenamiento, validación y pruebas, la red neuronal necesita al menos diez muestras (Stupak, 2024), (Haykin, 2009).

#### **4.3 Red neuronal artificial feedforward backpropagation (BP) para evaluar y predecir la calidad de una edificación**

Una red neuronal artificial (ANN, *Artificial Neural Network*), también conocida como red neuronal (NN, *Neural Network*), se compone de elementos de procesamiento en grandes cantidades (neuronas) que forman una extensa red de interconexión. Una ANN es la abstracción, simplificación y simulación del cerebro humano, que refleja las características básicas de este. Se puede resumir en dos aspectos: i) a través del proceso de aprendizaje utilizando redes neuronales para adquirir conocimientos del entorno externo; ii) las neuronas internas (pesos sinápticos) se utilizan para almacenar conocimientos e información adquiridos (Worden et al., 2023).

Las ANN son una rama de la ciencia de la inteligencia artificial que se ha desarrollado exponencialmente en los últimos años y su uso generalizado ha demostrado una vez más su vitalidad activa en la actualidad. En particular, la red neuronal de propagación hacia atrás (back propagation, BP) con alimentación hacia adelante es actualmente uno de los modelos más utilizados en el área de las redes neuronales y es una de las redes de alimentación directa más utilizadas para lograr la transformación del mapeo.

Las ANN son un ejemplo de aprendizaje y procesamiento automático inspirado en la funcionalidad del sistema nervioso. Es un sistema interconectado de neuronas que trabajan juntas para producir un estímulo de salida. Una red neuronal consta de unidades llamadas neuronas. Como se muestra en la figura 4, cada neurona recibe una serie de entradas a través de conexiones internas y produce una salida, Esta salida viene dada por tres funciones:

1. Una función de propagación (llamada también como función de excitación), que generalmente consiste en la suma de cada entrada multiplicada por el peso de su

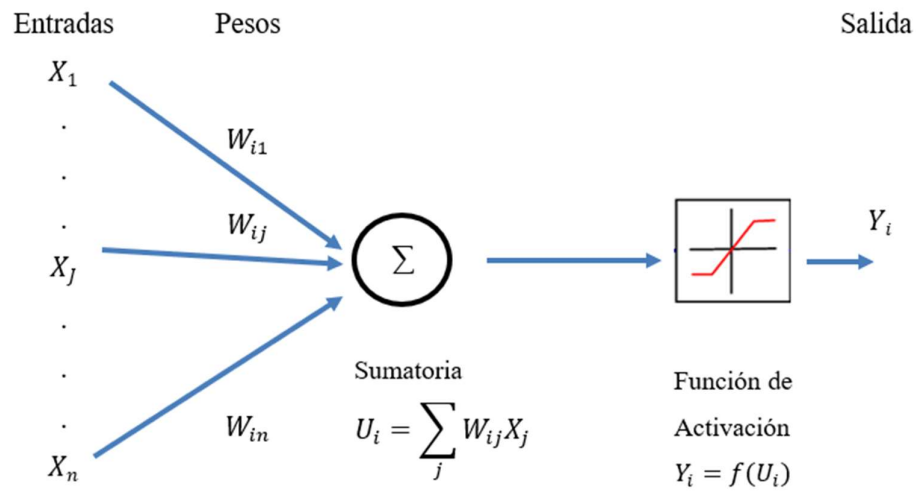


correlación (valor neto). La conexión se llama excitatoria si el peso es positivo e inhibitoria si es negativo.

2. Una función de activación, que modifica a la anterior. Es posible omitirla, lo que significa en este caso que la salida es la misma que la función de propagación.
3. Una función de transferencia, que se aplica al valor que la función de activación devuelve. Sirve para limitar la salida de la neurona y generalmente está determinada por la interpretación que se da a estas salidas. Algunas de las funciones más utilizadas son la función sigmoidea (para tomar valores en el intervalo [0,1]) y la tangente hiperbólica (para obtener valores en el intervalo [-1,1]).

**Figura 4**

*Estructura de una neurona artificial simple.*



*Nota.* La figura muestra los componentes de una neurona artificial simple: Entradas, pesos asignados, función de activación y salida.

Para aplicar y crear una red neuronal a un problema concreto, se realizan los siguientes pasos:

- **Diseño del modelo para el estudio del problema concreto.** Se deben indicar las entradas, salidas e información disponible.

- **Adecuar la información disponible a la estructura de la red a diseñar.** Esto significa construir patrones de aprendizaje en donde parte de la información se utilizará para validar la red.
- **Fase de aprendizaje.** Los patrones adecuados se introducen a la red y la red proporciona resultados o salidas, este proceso se repite un cierto número de etapas, se comparan estas salidas con las salidas esperadas y los diferentes algoritmos de aprendizaje de la red y los patrones o modelos de validación.
- **Fase de validación.** El conjunto de patrones de validación se presenta a la red entrenada y se calcula el error cometido por la red en este conjunto; este error es una medida de los beneficios de la red.
- **Fase de generalización.** Cuando se encuentra la red correcta, se la utiliza como modelo predictivo, se introduce una nueva entrada, la red la procesará y entregará una salida.

#### **4.3.1 Arquitectura de una red neuronal con alimentación hacia adelante (Feedforward)**

La arquitectura de una ANN se refiere a la organización y disposición de las neuronas en la red, que forman capas de procesadores interconectados entre sí por sinapsis unidireccionales. La arquitectura de una red neuronal artificial depende de cuatro parámetros principales: El número de capas del sistema, el número de neuronas por capa, el grado de conectividad entre las neuronas y el tipo de conexiones neuronales.

Por otro lado, la conexión entre los nodos de la red está relacionada con la manera de transmisión de las salidas de diferentes unidades y como se convierten en entradas de otros procesadores. La arquitectura de la red neuronal es la interconexión entre las diferentes neuronas. Éstas se agrupan en capas, cada una de las cuales incluye un grupo de neuronas de número variable y comportamiento similar. Sin embargo, la forma en que se estructuran

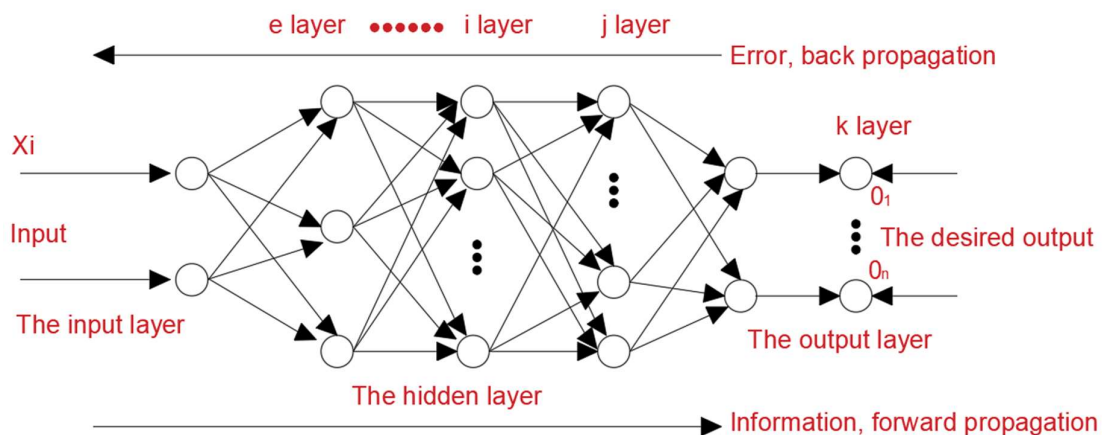
las neuronas de una red neuronal está relacionada con el algoritmo de aprendizaje (Haykin, 2009).

En las redes de alimentación hacia adelante o avance (feedforward), como sugiere el nombre, las conexiones siempre están dirigidas hacia adelante, es decir las neuronas de una capa se conectan con las neuronas de la siguiente capa. En las redes feedforward se puede identificar tres clases de configuraciones: redes monocapa (capa simple), multicapa y recurrentes, siendo la red feedforward multicapa la más utilizada.

Se muestra en la figura 5 como cada capa está conectada a la inmediata siguiente total o parcialmente, excepto la última capa que constituye la salida de la red.

**Figura 5**

*Modelo de red neuronal BP.*



*Nota.* La figura muestra la arquitectura de una red neuronal definida porque las neuronas están agrupadas en capas de diferentes niveles. Cada capa contiene un conjunto de neuronas en las que se distinguen tres tipos de capas diferentes: capa de entrada, capas ocultas y la capa de salida (Haykin, 2009).

- **Capa de entrada:** El tipo y la cantidad de neuronas en esta capa dependen de los datos sobre el problema que se está resolviendo. Esta capa recibe datos o señales del entorno, recibe vectores de entrada y los redistribuye a las neuronas de la capa intermedia sin realizar ningún procesamiento de datos; es sólo una receptora de información.

- **Capas intermedias u ocultas:** Dependiendo del problema pueden existir varias capas. Estas capas no tienen conexión directa con el entorno y gracias al procesamiento adecuado de estas capas se logra la extracción de características, adaptabilidad y generalización, es decir, esta capa proporciona a la red diferentes niveles de libertad. Los grados adicionales de libertad le permiten encontrar representaciones internas de ciertas características del entorno. Transforma los vectores de entrada en vectores intermedios que caracterizan los patrones de entrenamiento.

- **Capa de salida:** El número de neuronas en esta capa depende de la salida de la red, es decir, sus neuronas proporcionan la respuesta de la red neuronal mediante un estímulo de la capa intermedia. Por tanto, de acuerdo con su estructura en capas, se tendrían: a) Redes monocapa formada por una única capa de neuronas; b) Redes multicapa.

Las redes multicapa son capaces de caracterizar los patrones de entrenamiento creando su propio modelo de representación. Este tipo de red multicapa solo requiere una única capa intermedia para modelar la proyección no lineal entre los espacios de entrada y de salida, ya que aumentar el número de neuronas en la red conduce a una mayor variación. Una red con una única capa intermedia tiene menos variación y proporciona mayor capacidad de generalización (Haykin, 2009); también se pueden utilizar dos capas intermedias que permitirá incrementar la precisión con un tiempo de entrenamiento adecuado (Uzair y Jamil, 2020).

La elección del número ideal de capas ocultas y de neuronas depende de la complejidad del problema que se resuelve y de los criterios del diseñador para garantizar un buen rendimiento de predicción y minimizar errores.

Hay varias propuestas para el tamaño del número de neuronas en la capa oculta (Haykin, 2009). El número mínimo de neuronas en la capa oculta se puede obtener a partir de los valores conseguidos de la siguiente ecuación empírica:

$$k = \text{redondeo} (\sqrt{n + m}) + c \quad (1)$$

Donde:

k: número de neuronas de la capa oculta,

n: tamaño de la capa de entrada,

m: tamaño de la capa de salida,

c: valor constante entre 0 y 10.

### 4.3.2 Aprendizaje y ejecución

Para una red neuronal, la capacidad de cambiar sus pesos  $w = \{w_1, w_2, \dots, w_n\}$  dependiendo de las señales de entrada que recibe  $x = \{x_1, x_2, \dots, x_p\}$  se llama aprendizaje (Cisco, 2010).

Las ANN pueden realizar cálculos basados en un conjunto de patrones de entrenamiento o ejemplos, siendo el aprendizaje una de sus principales características, permitiendo a la red cambiar su propia estructura, es decir, que cambie sus pesos, adaptándolos hasta obtener la respuesta que se desea.

El entrenamiento es el proceso mediante el cual la red aprende y el aprendizaje es el resultado final de este proceso. El aprendizaje se basa en todo el conjunto más que por aportes individuales de cada elemento. El proceso de entrenamiento suele ser iterativo, los pesos se actualizan varias veces hasta que se logra el objetivo deseado.

Después del entrenamiento, la red cambia al modo de ejecución o modo memoria, lo que implica mantener fijos los pesos de la red y procesar datos, la red es capaz de responder ante entradas no vistas con anterioridad. Se pueden distinguir los siguientes tipos de aprendizaje (Haykin, 2009):

- Aprendizaje supervisado: a partir de ejemplos de entrenamiento la red aprende, es decir, la red es entrenada a partir de la entrada y la salida aprendiendo la relación entre ellos

sin necesidad de tener una forma funcional de partida, ajustando los pesos a partir de la información sobre los errores que ocurren en cada paso.

- Aprendizaje no supervisado: el conjunto de entrenamiento incluye sólo datos de entrada, sin la salida esperada para estos elementos. El aprendizaje se lleva a cabo asociando la información recibida con la información almacenada y como resultado reconoce regularidades en el conjunto de datos, es decir, la red puede extraer las características, estableciendo una clasificación o categorización.

- Aprendizaje híbrido: es una combinación de los anteriores utilizando principios de aprendizaje supervisado para casos maestros, conocidos y generales. Normalmente, el aprendizaje supervisado y no supervisado tienen lugar en capas distintas.

- Aprendizaje reforzado: está a medio camino entre el supervisado y no supervisado, la información del error es sólo global (bien, mal) y no se suministra la salida deseada.

#### **4.3.3 Algoritmo de propagación hacia atrás (backpropagation)**

El algoritmo Backpropagation para redes multicapa es una generalización del algoritmo de mínimos cuadrados. Ambos algoritmos realizan la tarea de actualizar pesos y ganancias en función del error cuadrático medio. La red Backpropagation trabaja bajo aprendizaje supervisado por lo que requiere un conjunto de instrucciones de entrenamiento que describan cada salida y su valor de salida esperado.

La red neuronal BP también se conoce como red de retroalimentación multicapa, que se basa en el algoritmo de retropropagación de errores para el aprendizaje y el entrenamiento. No requiere conocimientos previos sobre la ecuación matemática del mapeo de expresiones, será capaz de entrenar y almacenar grandes cantidades de relaciones de mapeo de modos de entrada y salida.

Debido a que la red neuronal BP utiliza un algoritmo BP clásico, que se basa en el método de descenso más pronunciado del gradiente con el error al cuadrado como función

objetivo, esto permite que el uso de algoritmos de red neuronal tenga la capacidad de aprendizaje y memoria. En teoría, la red neuronal BP puede aproximarse a cualquier función no lineal continua: una red neuronal BP simple de dos o tres capas puede lograr cualquier mapeo desde  $n$  dimensiones hasta  $m$  dimensiones, y su lógica es clara, es de fácil programación, estructura simple, alta precisión, gran operabilidad por lo que ha sido muy utilizado en muchos campos (Uzair y Jamil, 2020).

Los principales campos de aplicación incluyen reconocimiento de patrones, control inteligente, diagnóstico de fallas, procesamiento de reconocimiento de imágenes, cálculo óptimo, procesamiento de información, previsión financiera, análisis de mercado y gestión empresarial, entre otros.

La red neuronal BP no solo tiene nodos en la capa de entrada, nodos en la capa de salida y hay uno o más nodos en capas ocultas. La información de entrada primero se propaga hacia los nodos de la capa oculta, a través de la función de activación de cada unidad (también conocida como función de acción, función de conversión) para operar; después de la operación, la información de salida del nodo oculto se difunde a los nodos de salida y finalmente proporciona los resultados. El modelo de red neuronal BP se muestra en la figura 5; la red BP utiliza un método de descenso de gradiente, este método se basa en el gradiente de la función de error para cada dos pesos de nodos, y calcula la contribución de peso de la función de error, y luego, de acuerdo con la información de gradiente, modifica los pesos con el fin de lograr el propósito de aprendizaje.

La red BP puede tener múltiples capas ocultas; si consideramos  $h$  como la capa oculta, de acuerdo con el orden de feedforward, los nodos de capa oculta serían  $m_1, m_2 \dots m_h$ ; cada salida de la capa oculta es  $y_1, y_2 \dots y_h$ ; la matriz de pesos para cada capa es  $w_1, w_2 \dots w_{h+1}$ , entonces, cada fórmula de ajuste de peso es:

a) Capa de salida:

$$\Delta w_{jk}^{h+1} = \eta \delta_j^{h+1} y_j^h = \eta (d_k - o_k) o_k (1 - o_k) y_j^h, j = 0, 1, 2, 3 \dots m_k; k = 1, 2, \dots n \quad (2)$$

b) Capa oculta  $h$ :


$$\Delta w_{ij}^h = \eta \delta_j^h y_j^{h-1} = \eta (\sum_{k=1}^n \delta_k^o w_{jk}^{h+1}) y_j^h (1 - y_j^h) y_j^{h-1}, i = 0, 1, 2, 3 \dots m_{h-1}; j = 1, 2, \dots m_h \quad (3)$$

De acuerdo con las reglas anteriores se puede obtener la fórmula de cálculo de ajuste de pesos de la primera capa (Haykin, 2009).

La idea principal del algoritmo BP es dividir el proceso de aprendizaje en dos etapas: propagación de la señal hacia adelante y la retropropagación del error (figura 6). En la etapa de propagación hacia adelante, la información de entrada se transmite desde la capa de entrada mediante la capa oculta hasta la capa de salida, generando una señal de salida en un terminal de salida.

**Figura 6**

*Proceso de aprendizaje backpropagation.*



*Nota.* La figura muestra el flujo de información para aprendizaje (feedforward) y corrección de errores (backpropagation) de una red neuronal y como se distribuye esta información en los diferentes nodos.

Durante el proceso en el que la señal pasa a lo largo de la red, el valor de los pesos se mantiene fijo, y el estado de cada neurona en una capa solo afecta al estado de las neuronas en la capa anterior. Si la salida deseada no se obtiene en la capa de salida, hay un error entre el valor de salida real y el valor de salida deseado, y entonces se inicia el proceso de retropropagación.

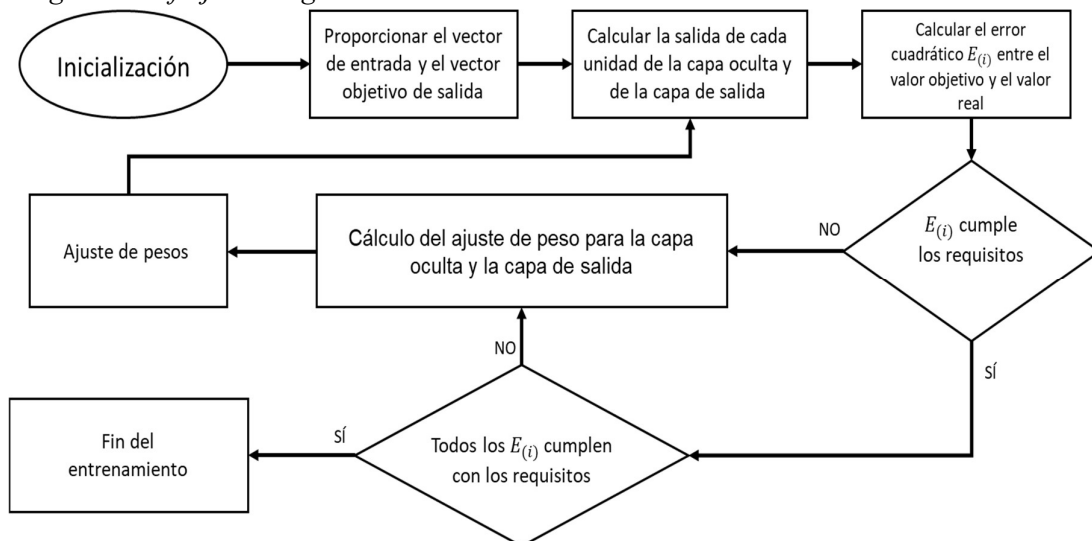


En la fase de retropropagación, la señal de error retorna a lo largo del camino de conexión original, modificando los pesos de las neuronas de cada capa, propagándose sucesivamente hacia la capa de entrada para realizar cálculos, y luego, a través del proceso de propagación hacia adelante, se repiten estos dos procesos de manera que la señal de error se minimice. De hecho, cuando el error alcanza los requisitos deseados, el proceso de aprendizaje de la red termina.

El diagrama de flujo del algoritmo BP se muestra en la figura 7.

**Figura 7**

*Diagrama de flujo del algoritmo BP.*



*Nota.* La figura muestra el algoritmo de funcionamiento de una red neuronal *feedforward backpropagation* en la fase de entrenamiento y aprendizaje.

#### 4.3.4 Entrenamiento por retropropagación del error

Asumiendo que se dispone de  $N$  datos patrones:

$$X = [x_1, x_2, \dots, x_N]^T \quad (4)$$

$$D = [d_1, d_2, \dots, d_N]^T \quad (5)$$

Siendo  $x_i$  los parámetros de entrada a la red y  $d_j$  la salida deseada.

El entrenamiento procede en dos pasos:

1. Cálculo feedforward

Con base en las entradas de red  $x_i$ ,  $i=1, \dots, N$ , son calculadas en forma progresiva: las activaciones de la capa oculta, las salidas de la capa oculta y las salidas de la red siendo, respectivamente:

$$Z = X_b W^h, \quad X_b = [X \ 1]; \quad (6)$$

$$V = \sigma(Z); \quad (7)$$

$$Y = V_b W^0, \quad V_b = [V \ 1]. \quad (8)$$

2. Adaptación de los pesos.

Se compara la salida de la red con la salida deseada. La diferencia de estos dos valores, llamado error, es:

$$E = D - Y. \quad (9)$$

Este error se usa para ajustar los pesos en la red vía la minimización de la función de costo siguiente:

$$J(w) = \sum_{k=1}^N \sum_{j=1}^n e_{kj}^2 \quad (10)$$

$$w = [W^h - W^0] \quad (11)$$

El entrenamiento de la red neuronal multicapa se formula como un problema de optimización no lineal con respecto a los pesos (minimizar  $J(w)$ ). Se pueden utilizar muchos métodos diferentes, como, por ejemplo:

- TrainLM (Levenberg-Marquardt): Es un método de optimización que requiere una gran cantidad de memoria. Para redes grandes, la matriz Jacobiana se divide en varias submatrices mediante el parámetro *mem - reduc*, lo que reduce el consumo de memoria, pero incrementa el tiempo de aprendizaje. El algoritmo de optimización *LM* realiza menos iteraciones que el BP tradicional y otros algoritmos mejorados,

con una tasa de convergencia más rápida y una precisión más alta. Por lo tanto, el algoritmo *LM* tiene cierta superioridad en el aprendizaje de redes BP.

- *Traingd*: Es un método de descenso de gradiente por lotes. La tasa de convergencia es lenta y se puede utilizar para entrenamiento en modo incremental. Es la función estándar de aprendizaje por descenso más empinado en ejecuciones por lotes. Los pesos y los sesgos se actualizan a lo largo del gradiente negativo de la función de rendimiento.
- *Traingdm*: Es un algoritmo de descenso de gradiente con momento. La tasa de convergencia es más rápida que *traingd* y se puede utilizar para entrenamiento en modo incremental.
- *Traincgf* (Fletcher-Reeves): Es un algoritmo de cambio de gradiente que ocupa el menor espacio de almacenamiento de datos.
- *Traincgp* (Polak-Ribiere): Es un algoritmo de cambio de gradiente que ocupa un espacio de almacenamiento ligeramente mayor que *Traincgf*, pero tiene una tasa de convergencia más rápida en algunos casos.
- *Traincgb* (Powell-Beale): Es un algoritmo de cambio de gradiente que ocupa un espacio de almacenamiento ligeramente mayor que *Traincgp* y tiene una tasa de convergencia más rápida.
- *Trainbfg* (BFGS): Es un algoritmo de cuasi-Newton. El almacenamiento de datos se aproxima a la matriz Hessiana. El cálculo de cada ciclo de entrenamiento es grande, pero la tasa de convergencia es más rápida.
- *Trainscg*: Es un algoritmo de cambio de gradiente con una relación de transformación fija y no se necesita una búsqueda lineal.

En el proceso que se acaba de mostrar, cada dato de entrenamiento es presentado uno tras otro (para el aprendizaje). Esto es útil, sobre todo, para el aprendizaje en línea. Esto se

puede aplicar incluso si un “batch” completo de datos está disponible para el aprendizaje. La presentación del conjunto completo de los datos se conoce como época (en inglés, *epoch*). Normalmente se deben utilizar varios *epochs* de aprendizaje para lograr un ajuste adecuado. Desde un punto de vista computacional, es más eficiente presentar el conjunto completo de datos como un “batch”.

Las fórmulas del aprendizaje backpropagation son aplicados entonces a vectores de datos en lugar de a muestras individuales. El algoritmo de retropropagación proporciona una "aproximación" de la trayectoria en el espacio de peso calculado por el método de descenso más pronunciado. Cuanto menos hacemos el aprendizaje, menores serán los cambios en los pesos sinápticos en la red entre iteraciones, y más suave será la trayectoria en el espacio de peso. Sin embargo, esta mejora se logra a costa de una tasa de aprendizaje más lenta.

Por otro lado, si hacemos que el parámetro de tasa de aprendizaje sea demasiado grande para aumentar la tasa de aprendizaje, los grandes cambios resultantes en los pesos sinápticos serán de tal forma que la red puede volverse inestable (es decir, oscilatoria) (Haykin, 2009).

#### **4.3.5 Implementación**

Para la fase de implementación se utilizó el software MATLAB. MATLAB se aplica principalmente en cálculos de ingeniería, procesamiento de imágenes, diseño y análisis de modelado financiero, entre otras áreas. MATLAB cuenta con varios cientos de paquetes de funciones integradas y treinta tipos de kits de herramientas.

En el ámbito de redes neuronales, este software proporciona diversas funciones de diseño, entrenamiento y simulación en una caja de herramientas de red neuronal. Los usuarios poseen la facilidad de usar las funciones relacionadas según sus necesidades, factibilizando así el diseño y la simulación de redes neuronales y evitando la complejidad de

compilar rutinas algorítmicas intrincadas y extensas. A continuación, se listan las principales funciones de entrenamiento y sus principales características:

Para iniciar y configurar una red neuronal entrenable alimentada hacia adelante en MATLAB, se emplea la función `feedforwardnet` (generar una red neuronal prealimentada).

- Sintaxis

```
net = feedforwardnet(hiddenSizes,trainFcn)
```

Devuelve una red neuronal prealimentada, en la que el tamaño de la capa oculta es de `hiddenSizes`, y una función de entrenamiento especificada por `trainFcn`.

Las redes prealimentadas están compuestas por una serie de capas. La primera capa tiene una conexión desde la entrada de red. Cada una de las capas posteriores contiene una conexión desde la capa anterior. Las últimas capas producen la salida de la red.

Puede utilizar redes prealimentadas para cualquier tipo de aplicación de entrada a salida. Una red prealimentada con una capa oculta y un número suficiente de neuronas en las capas ocultas puede adaptarse a cualquier problema de aplicación de entrada a salida.

Las versiones especializadas de la red prealimentada incluyen redes de ajuste y redes de reconocimiento de patrones.

- Argumentos de entrada

`hiddenSizes` — Tamaño de las capas ocultas 10 (predeterminado) | vector fila

Tamaño de las capas ocultas de la red, especificado como un vector fila. La longitud del vector determina el número de capas ocultas de la red.

Ejemplo: Por ejemplo, puede especificar una red con 2 capas ocultas, en la que el tamaño de la primera capa oculta es 15, el de la segunda es 10, de la siguiente manera:

```
hiddenSizes = [15, 10]
```

Los tamaños de entrada y salida se establecen en cero. El software ajusta los tamaños durante el entrenamiento, de acuerdo con los datos de entrenamiento.

`trainFcn` — Nombre de la función de entrenamiento

'trainlm'(predeterminado) | 'trainbr' | 'trainbfg' | 'trainrp' | 'trainscg' | ...

Nombre de la función de entrenamiento, especificado como una de las siguientes opciones:

'trainlm' (Levenberg-Marquardt), 'trainbr' (Regularización bayesiana), 'trainbfg' (BFGS quasi-Newton), 'trainrp' (Retropropagación resiliente), 'trainscg' (Gradiente conjugado escalado), 'traincgb' (Gradiente conjugado con reinicios de Powell/Beale), 'traincgf' (Gradiente conjugado de Fletcher-Powell), 'traincgp' (Gradiente conjugado de Polak-Ribière), 'trainoss' (Secante de un paso), 'traingdx' (Gradiente descendente de tasa de aprendizaje variable), 'traingdm'(Gradiente descendente con momento), 'traingd' (Gradiente descendente).

Ejemplo: Se puede establecer el algoritmo de gradiente descendente de tasa de aprendizaje variable como el algoritmo de entrenamiento, de esta manera: 'traingdx'

- Argumentos de salida

net — Red prealimentada

objeto network

Red neuronal prealimentada, devuelta como un objeto network.”

## 5. RESULTADOS Y DISCUSIÓN

### 5.1 Obtención de datos para entrenamiento

Primero se realizó la evaluación de la calidad de la edificación definida en el caso de estudio por 12 expertos. Estos expertos evaluaron los 16 factores propuestos y definieron la calidad de la edificación en un rango del 1 al 5, siendo 1 muy mala calidad y 5 muy buena calidad. Los resultados de sus evaluaciones son las que se muestran en la tabla 1.

**Tabla 1**

*Evaluación de la calidad de la edificación en estudio.*

Experto	Factores de evaluación de la edificación																Calidad
	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	F16	
1	3.5	3	3.5	4	3	2.5	3	4	4.5	4	4	3.5	3	3	3.5	4.5	V5
2	3	2	4.5	3	4	3	3.5	2.5	3.5	4	4.5	3	2	2.5	2	3	V3
3	2	4.5	3	2	2.5	2	4	3	2.5	3.5	2	4.5	3	2.5	3	4	V3
4	4.5	3.5	3	4	4.5	2	2.5	3	4	2	4.5	4	4	3	3.5	2	V4
5	3	4	4	3	2	2.5	4	3	4.5	5	3.5	3	2	4	3.5	3	V3
6	2.5	3	3.5	3	2	1.5	3	3.5	2	3	2	2.5	1.5	4	3.5	3	V2
7	3	4	3	3.5	3	2	2.5	4	4.5	3	4	3.5	3	2	2.5	4	V3
8	2	3.5	2.5	3	3.5	2	3	2.5	3	2.5	2.5	3	2	2.5	3	2.5	V2
9	4	3	4	3	3.5	3.5	4	3	4	3.5	2.5	4	3	3.5	3	2.5	V4
10	1.5	2.5	1	2	2	1.5	2.5	2	2.5	3	1.5	2.5	3	2	2	2.5	V1
11	2	3	3	2.5	3	4	3.5	3	2.5	3	4	3.5	4	2.5	3.5	2	V3
12	2.5	2	2.5	2	3	2.5	3.5	2.5	3	1.5	3	3.5	3	2.5	3	3.5	V3

*Nota.* Resultados de las evaluaciones realizadas por los 12 expertos en el caso de estudio.

La medida estadística Alpha de Cronbach en el cuestionario aplicado (que evalúa la confiabilidad interna de un conjunto de ítems en un cuestionario) es de 0.82. Esto indica que las respuestas son consistentes y el conjunto de factores de evaluación de la edificación utilizados están correlacionados de tal manera que permiten medir fiablemente la calidad de la edificación en estudio.

### 5.2 Arquitectura de la red neuronal artificial

Una vez obtenida la información de los expertos se diseñó la arquitectura de la red neuronal considerando como insumos los datos de entrada, la definición de las capas ocultas con el número de neuronas por capa, y finalmente los datos de salida. Todo esto sirve para iniciar la fase de entrenamiento de la red neuronal.

Como se muestra en la figura 8, en este estudio los datos de entrada fueron las evaluaciones que hicieron los expertos utilizando los 16 factores definidos; las salidas se corresponden con las evaluaciones de calidad que cada uno de los expertos dio a la edificación (1 a 5, siendo 1 muy mala y 5 muy buena).

Con respecto a las capas ocultas de la red neuronal, se definieron dos para tener un tiempo de entrenamiento adecuado y alta precisión; para cada una de estas se calculó el número de neuronas a utilizar según la ecuación 1 de la siguiente manera:

- Número de neuronas para la capa oculta 1:

$$k = \text{redondeo} (\sqrt{16 + 5}) + 10 ;$$

$$k = 15 \text{ neuronas .}$$

- Número de neuronas para la capa oculta 2:

$$k = \text{redondeo} (\sqrt{16 + 5}) + 5 ;$$


$$k = 10 \text{ neuronas .}$$

Con estos datos se conformó la arquitectura de la red neuronal que se muestra en la figura 8.

### **Figura 8**

*Arquitectura de la red neuronal artificial de propagación hacia atrás.*





*Nota.* La figura muestra la arquitectura de la red neuronal implementada y los elementos de cada capa que la componen. Específicamente se observa una capa de entrada con 16 factores, dos capas ocultas, con 15 y 10 neuronas, respectivamente, y una capa de salida con 5 indicadores (valoración de la calidad de una edificación).

### 5.3 Análisis de varios algoritmos en la fase de entrenamiento

Una vez conformada la arquitectura de la red neuronal se realizó la fase de entrenamiento. En esta fase, primero se probó varios algoritmos para saber qué algoritmo convergió en menor tiempo, es decir, presentaba el menor error cuadrático medio (Mean Square Error, MSE) utilizando menos épocas o períodos de entrenamiento según su condición de parada.

Como se muestra en la tabla 2, en este estudio el algoritmo más eficiente fue el algoritmo `train LM`, teniendo un MSE de  $1.03 \text{ e-}18$ , cumpliendo en 5 épocas la condición de parada definida por el algoritmo.

**Tabla 2**

*Prueba de los algoritmos de entrenamiento de la red neuronal artificial de propagación hacia atrás.*

ALGORITMO	EPOCHS TO STOP	PERFORMANCE (MSE)
<code>train LM</code>	5	$1.03 \text{ e-}18$
<code>train bfg</code>	10	0.0113
<code>train scg</code>	16	$3.72 \text{ e-}4$
<code>train cgf</code>	18	0.00604
<code>train cgp</code>	19	0.0236
<code>train gdm</code>	1000	0.0516
<code>train gd</code>	1000	0.0462
<code>train oss</code>	52	$8.27 \text{ e-}6$
<code>train br</code>	288	$2.37 \text{ e-}15$
<code>train rp</code>	24	$6.62 \text{ e-}5$
<code>train cgb</code>	14	0.00488
<code>train gdx</code>	71	0.0644

*Nota.* Dentro de la tabla se observa los resultados en términos de convergencia y error al implementar varios algoritmos de entrenamiento en la red neuronal diseñada para evaluar la calidad de una edificación. Se utilizó el algoritmo `train LM`.

#### **5.4 Validación de la predicción y evaluación de la calidad de una edificación utilizando la red neuronal de propagación hacia atrás**

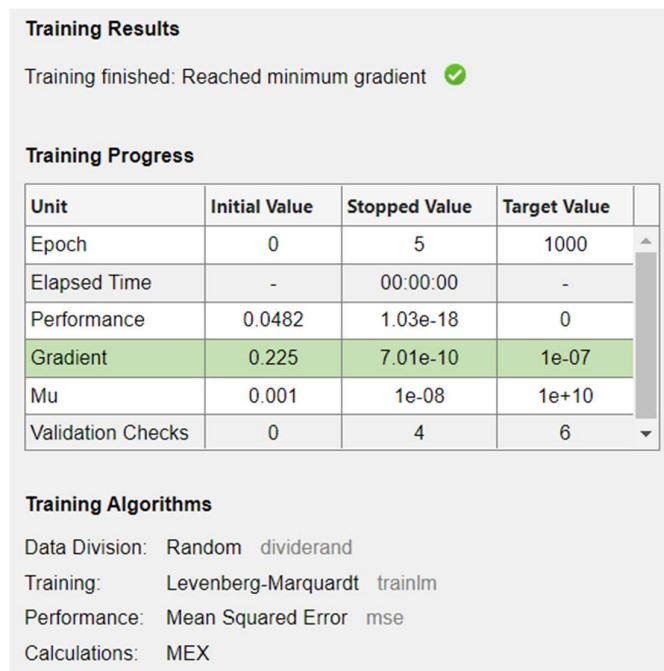
Una vez elegido el algoritmo de entrenamiento, se procedió a entrenar la red neuronal, validarla y probarla. Para esta fase, de los datos obtenidos en las evaluaciones con

expertos, se utilizó aleatoriamente el 75% de las evaluaciones para entrenamiento, el 15% para validación y el 15% restante de los datos para prueba.

Los resultados del entrenamiento se muestran en la figura 9, donde el entrenamiento continúa hasta que se cumple una condición de parada que, para el algoritmo utilizado `trainLM`, es cuando alcanza el mínimo gradiente ( $1e-7$ ).

**Figura 9**

*Resultados de la fase de entrenamiento.*

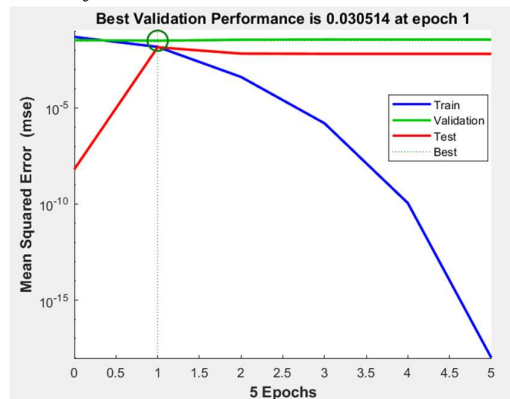


*Nota.* La figura muestra los resultados de la fase de entrenamiento, los algoritmos en la ejecución de la red neuronal y el progreso en la fase de aprendizaje.

Una vez que concluye la fase de entrenamiento, puede observarse la gráfica de errores de validación y prueba como se muestra en la figura 10. El resultado es razonable debido a que el error cuadrático medio final utilizando los datos de prueba está en torno a  $10^{-2}$ , el error del conjunto de validación presenta características similares.

**Figura 10**

*Error cuadrático medio en las fases de entrenamiento, validación y pruebas.*

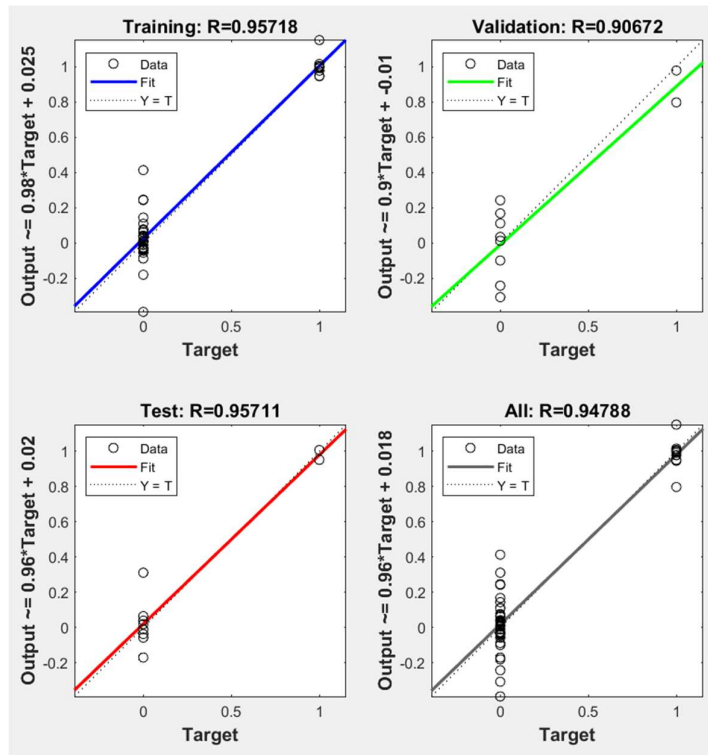


*Nota.* La figura muestra el error cuadrático medio en función de las épocas ejecutadas en las diferentes fases de evaluación de la red neuronal.

Luego se analizó los resultados de la regresión lineal para predecir la calidad de la edificación; en la figura 11 se muestra las predicciones de la red (salida, *output*) con respecto a las respuestas realizadas por los expertos (objetivo, *target*) para los conjuntos de entrenamiento, validación y prueba.

**Figura 11**

*Resultados de la regresión lineal (predicción) del modelo.*




Se observa que el ajuste es adecuado, las salidas de la red son iguales a las respuestas, en todos los casos el valor R es mayor al 90% lo que significa que la red neuronal es bastante precisa con los resultados que predice.

Para hacer una verificación adicional del rendimiento de la red, en la figura 12 se observa el histograma de error entre los valores objetivo y los valores previstos en las fases de entrenamiento, validación y prueba. Se puede notar que el histograma tiene un ajuste adecuado, el comportamiento del error coincide en los tres casos acercándose hacia el cero sin muchos datos dispersos.

### Figura 12

*Histograma de error en las fases de entrenamiento, validación, pruebas.*



Finalmente, se prueba la red neuronal con dos evaluaciones realizadas por expertos en donde, ingresados las valoraciones a cada factor de evaluación, la red neuronal predice el índice de la calidad dando como resultado la misma calidad que el experto había evaluado. De esta manera se ha conseguido una red neuronal entrenada y lista para calcular la respuesta de la red a cualquier entrada.

**Tabla 3**

*Prueba del modelo de predicción para evaluar la calidad de una edificación utilizando redes neuronales artificiales de propagación hacia atrás.*

Resultado ANN entrenada (R-value)					Predicción de calidad con ANN entrenada	Valoración experto
Índice de Calidad						
1	2	3	4	5		
0.0279	0.9997	0.0305	0.0134	-0.0282	2	2
0.0196	-0.0367	-0.0106	0.9999	0.0651	4	4

*Nota.* Se puede evidenciar que la evaluación de calidad de la predicción es igual a la del experto.

## 5.5 Discusión

Evaluar la calidad de una edificación es una tarea compleja y representa un reto medirla directamente, como lo indica Sengupta y Tipple (2007); además, la percepción de

calidad de una edificación varía ampliamente según las perspectivas de las personas (Kurian y Thampuran, 2011) (Johnson, 2012). El listado de parámetros de evaluación de la calidad de una edificación propuesto en esta investigación abarca algunos factores críticos como son la seguridad, la economía, el confort, la armonía, la estética y está acorde con aquellos propuestos por varios estudios (Kutty, 1999) (Al-Momani, 2003) (Sengupta y Tipple, 2007) (Kurian y Thampuran, 2011) (Pérez y Elena, 2014). Esto permite generalizar los criterios de evaluación y predecir la calidad de una edificación utilizando redes neuronales artificiales (ANN).

En el área de la gestión de la construcción, las ANN se han aplicado principalmente para la estimación de costos de construcción (Bala y Waziri, 2012) (Bala et al., 2014), previsión de productividad (Al-Zwainy et al., 2012), resolución de disputas (Yitmen y Soujeri, 2010) (Fatima et al., 2014), ejecución de contratos (Zin et al., 2006) (Waziri, 2012), cuantificación del riesgo (Xiang y Luo, 2012) (Liu y Guo, 2014); contingencia temporal (Yahia et al., 2011). El modelizado computacional en estas aplicaciones presenta limitaciones referentes a la falta de una técnica sistemática para determinar las características y los parámetros de control, así como el carácter de caja negra de las ANN, lo que significa que no se puede explicar el proceso de entrada-salida subyacente (Kim et al., 2013).

La comprensión de la correlación entre los parámetros de entrada y salida, que se representa mediante las ANN, está encapsulada dentro de los pesos y sesgos aprendidos. Por lo tanto, es necesario desentrañarla y, a continuación, evaluar los resultados. Aunque la mayoría de las investigaciones examinadas indican que el modelo de ANN utilizado supera a otros modelos en términos de precisión de la estimación, puede suponer un reto para los usuarios comprender y articular los resultados del modelo (Kim et al., 2004). Dedicar esfuerzos a este campo aumentará la popularidad de la técnica entre los usuarios regulares.

En referencia a estas observaciones, la importancia de esta investigación radica en explicar el diseño de la arquitectura de la ANN y su aplicación específica para evaluar la calidad de una edificación. A pesar de las numerosas ventajas de las ANN (como el aprendizaje adaptativo, la autoorganización, la operación en tiempo real y la tolerancia a fallos) sobre las herramientas estadísticas tradicionales, se ofrece poca explicación sobre las relaciones entre los parámetros utilizados para el modelado, lo que dificulta explicar qué se aprende de la red. Para ello se presenta primero los parámetros y factores de un modelo de evaluación de la calidad que comprenda aspectos generales para poder evaluar cualquier edificación y así empezar a estandarizar la forma de evaluación. Luego, se detalla el proceso interno dentro de la red neuronal para brindar una mejor comprensión de la influencia de las variables independientes en el proceso de la evaluación de la calidad de una edificación.

Los resultados de esta investigación confirman que el modelo de ANN propuesto basada en BP no solo puede reducir el problema de la aleatoriedad de la evaluación subjetiva humana (Johnson, 2012) y hacer que los resultados sean más efectivos e intuitivos como se afirma en otras investigaciones (Jain et al., 2014) (Waziri et al., 2017), sino que también puede mejorar la estabilidad, la objetividad y la naturaleza científica de los resultados de la evaluación, contribuyendo a la gestión de calidad de una edificación.

Por otro lado, esta investigación pretende incrementar la aceptabilidad de las ANN para tareas prácticas rutinarias en la gestión de la construcción. Esto puede mejorarse abordando cuestiones relacionadas con su portabilidad, como el desarrollo de una interfaz gráfica de usuario fácil de usar o la integración con software de uso común. Además, deben considerarse cuestiones de normalización, como el establecimiento de un nivel mínimo de precisión necesario para la aceptación del modelo, la identificación de los parámetros de entrada esenciales para un proyecto específico con una salida definida, la determinación de



la tasa mínima de aprendizaje, y la especificación del tanto del número de capas ocultas como del número mínimo de neuronas en cada capa oculta.

El modelo propuesto basado en ANN puede incluirse sin problemas en herramientas o software que se utilizan para una evaluación precisa de la calidad de una edificación. Esta integración permitirá a los ingenieros consultores que llevan a cabo la supervisión y a los directores de obra encargados de las responsabilidades de gestión y control de riesgos de los proyectos utilizar en la práctica la técnica sugerida.

## 6. CONCLUSIONES Y RECOMENDACIONES

### 6.1 Conclusiones

- Se determinó los parámetros de entrada para un modelo de evaluación de la calidad de una edificación, los mismos que se dividen en 5 parámetros de evaluación con 16 factores que abarcan aspectos generales para poder evaluar cualquier edificación y así empezar a estandarizar la forma de evaluar edificaciones.
- Se diseñó e implementó un algoritmo de red neuronal artificial de propagación hacia atrás (BP) entrenada con el criterio de expertos, de manera que puede evaluar y predecir la calidad de una edificación. Ingresando las valoraciones de los 16 factores definidos en el modelo, la red neuronal procesa esos datos y predice la calidad de la edificación de una manera precisa.
- Se validó el algoritmo de la red neuronal con datos de prueba, los mismos que, al procesar la información, coincidieron con el criterio de los expertos, probando así la precisión de la red neuronal.
- Con una red neuronal entrenada, validada y probada una persona/entidad/empresa puede evaluar la calidad de una edificación utilizando la red, de manera que, los resultados de la evaluación no dependan solamente de la persona que está evaluando sino del procesamiento que haga la red neuronal a sus datos, evitando así la subjetividad en la evaluación.
- La edificación seleccionada como caso de estudio tiene 3 pisos altos construida con estructura de hormigón armado por lo que el presente estudio se limita a ese tipo de edificaciones.

## 6.2 Recomendaciones

- La red neuronal artificial creada está diseñada para evaluar la calidad de edificaciones en función del modelo de evaluación planteado. Si se quisiera quitar o agregar factores de evaluación a la red neuronal, se debería volver a realizar la evaluación con expertos para así entrenar, validar y volver a probar el nuevo algoritmo de la red neuronal artificial.
- De igual manera, la red neural está entrenada con la evaluación de una edificación de hormigón armado, si se quisiera realizar la evaluación de una edificación construida con otros materiales igualmente se debe entrenar, validar y probar el algoritmo con la evaluación de expertos para esos tipos específicos de edificaciones.

## 7. BIBLIOGRAFÍA

- Abitante, A. L., Bergmann, C. P., & Ribeiro, J. L. (2007). Abrasión en baldosas cerámicas esmaltadas: Consideraciones sobre la vida útil y evaluación de su desempeño. *Engenharia Civil• UM*, 29, 71-79.
- Alaloul, W. S., Liew, M. S., Wan Zawawi, N. A., Mohammed, B. S., & Adamu, M. (2018). An Artificial neural networks (ANN) model for evaluating construction project performance based on coordination factors. *Cogent Engineering*, 5(1), 1507657.
- Alvarado Flores, F. L., & Escudero Panduro, H. (2021). Evaluación de patologías y su influencia en una propuesta de mantenimiento de las edificaciones de concreto armado en el distrito de Juan Guerra, provincia y departamento de San Martín.
- Alzakkar, A., Ilyasov, I., Cuong, L. Q., & Valeev, I. (2021, September). An Impact of Use the Artificial Neural Networks in Analysis of Electrical Power Stability at Meharde Plant (Hama-Syria). In *2021 International Russian Automation Conference (RusAutoCon)* (pp. 398-403). IEEE.
- Al-Momani, A. H. (2003). Housing quality: Implications for design and management. *Journal of urban planning and development*, 129(4), 177-194.
- Al-Zwainy, F. M. S., Rasheed, H. A., & Ibraheem, H. F. (2012). Development of the construction productivity estimation model using artificial neural network for finishing works for floors with marble. *ARPN Journal of Engineering and Applied Sciences*, 7(6), 714-722.
- Arencibia, J. M. (2007). Conceptos fundamentales sobre el mantenimiento de edificios. *Revista de Arquitectura e ingeniería*, 1(1), 1-8.
- Bala, K., Ahmad Bustani, S., & Shehu Waziri, B. (2014). A computer-based cost prediction model for institutional building projects in Nigeria: an artificial neural network approach. *Journal of Engineering, Design and Technology*, 12(4), 519-530.
- Bala, K., & Waziri, B. (2012). Parametric model for pre-design building cost estimating. *Global Journal of Engineering and Technology*, 4(1), 115-122.

- Basner, M., Babisch, W., Davis, A., Brink, M., Clark, C., Janssen, S., & Stansfeld, S. (2014). *Auditory and non-auditory effects of noise on health*. *The Lancet*, 383(9925), 1325-1332. [https://doi.org/10.1016/S0140-6736\(13\)61613-X](https://doi.org/10.1016/S0140-6736(13)61613-X)
- Berglund, B., Lindvall, T., & Schwela, D. H. (Eds.). (2018). *Guidelines for community noise*. World Health Organization.
- Cortes Henao, B., & Perilla Morales, K. (2017). Identificación de patologías estructurales en edificaciones indispensables del municipio de Santa Rosa de Cabal (sector educativo).
- CISCO, H. (2010). *Aprendizaje supervisado en redes neuronales*, México: Limusa.
- Che-Ghani, N. Z., Myeda, N. E., & Ali, A. S. (2016). Operations and maintenance cost for stratified buildings: A critical review. In *MATEC web of conferences* (Vol. 66, p. 00041). EDP Sciences.
- Estrada, C. M. (2015). *Sistema de simulación basado en reglas para la definición de rutas de evacuación en edificios: desarrollo teórico y aplicación* (Doctoral dissertation, Universidad de Oviedo).
- Grabow, S., & Spreckelmeyer, K. (2014). *The architecture of use: aesthetics and function in architectural design*. Routledge. <https://doi.org/10.4324/9780203758137>
- Grazuleviciute-Vileniske, I., Viliunas, G., & Daugelaite, A. (2021). The role of aesthetics in building sustainability assessment. *Spatium*, 79-89.
- Harrison, A. (1999). Housing quality indicators. *DEGW: United Kingdom*.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson.
- Iyengar, K. (2015). *Sustainable architectural design: an overview*. Routledge.
- Jain, M., & Pathak, K. K. (2014). Applications of artificial neural network in construction engineering and management-a review. *International Journal of Engineering Technology, Management and Applied Sciences*, 2(3), 134-142.

- Jennings, V., & Bamkole, O. (2019). The relationship between social cohesion and urban green space: An avenue for health promotion. *International journal of environmental research and public health*, 16(3), 452.
- Jiang, Z., Kobayashi, T., Yamanaka, T., & Sandberg, M. (2023). A literature review of cross ventilation in buildings. *Energy and Buildings*, 291, 113143.
- Johnson, M. R. (2012, August). FSV versus human subjective data evaluation; an informal survey. In *2012 IEEE International Symposium on Electromagnetic Compatibility* (pp. 679-684). IEEE.
- Kim, G. H., Shin, J. M., Kim, S., & Shin, Y. (2013). Comparison of school building construction costs estimation methods using regression analysis, neural network, and support vector machine.
- Kim, G. H., An, S. H., & Kang, K. I. (2004). Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning. *Building and environment*, 39(10), 1235-1242.
- Kurian, S. M., & Thampuran, A. (2011). Assessment of housing quality. *Institute of Town Planners, India Journal*, 8(2), 74-85.
- Kutty, N. (1999). Determinants of structural adequacy of dwellings. *Journal of housing research*, 10(1), 27-43.
- Le, A. T. H., Domingo, N., Rasheed, E., & Park, K. S. (2018, September). Building maintenance cost planning and estimating: A literature review. In *Proceedings of the 34th Annual ARCOM Conference, ARCOM* (pp. 697-706).
- León, M. A. A., & CAMACHO, P. I. A. E. C. (2014). *RUTAS DE EVACUACIÓN Y SU INCIDENCIA EN LA PRESENCIA DE UNA EMERGENCIA EN EL PERSONAL DEL GOBIERNO AUTÓNOMO DESCENTRALIZADO DEL CANTÓN PUJILÍ PROVINCIA DE COTOPAXI* (Master's thesis).
- Liu, J., & Guo, F. (2014). Construction quality risk management of projects on the basis of rough set and neural network. *Computer Modelling and New Technologies*, 18(11), 791-797.

- Liu, J., Xu, J., Xu, X., & Cao, Y. (2009, June). Study on Engineering Project Management Based on Neural Network. In *2009 International Conference on Electronic Commerce and Business Intelligence* (pp. 234-237). IEEE.
- Liu, S., Chang, R., Zuo, J., Webber, R. J., Xiong, F., & Dong, N. (2021). Application of artificial neural networks in construction management: Current status and future directions. *Applied Sciences*, *11*(20), 9616.
- Mashwama, N., Aigbavboa, C., & Thwala, D. (2017). An assessment of the critical success factor for the reduction of cost of poor quality in construction projects in Swaziland. *Procedia Engineering*, *196*, 447-453.
- Musa, U. S. M. A. N., & Yusoff, W. Z. W. (2015). Impact of Neighborhood Characteristics on Residential Property Values: A Critical Review of Literature. *International Review of Social Sciences*, *3*(4), 147-155.
- Norma Ecuatoriana de la Construcción. (2015). *Contra Incendios* (NEC-HS-CI: Contra Incendios). <https://www.habitatyvivienda.gob.ec/wp-content/uploads/2023/03/2.-NEC-HS-CI-Contra-Incendios.pdf>
- Norma Ecuatoriana de la Construcción. (2015). *Guía práctica para evaluación sísmica y rehabilitación de estructuras, de conformidad con la Norma Ecuatoriana de la Construcción NEC 2015*. (Guía de diseño 5). <https://www.habitatyvivienda.gob.ec/documentos-normativos-nec-norma-ecuatoriana-de-la-construccion/>
- Ozenen, G. (2023). Basic Principles of Lighting. In *Architectural Interior Lighting* (pp. 25-35). Cham: Springer Nature Switzerland.
- Pérez, M. E. T., & Elena, M. (2014). Evaluación de la Vivienda Construida en Serie con el Habitante. *Plaza y Valdés Mexico City*.
- Pérez-Lombard, L., Ortiz, J., & Pout, C. (2008). A review on buildings energy consumption information. *Energy and Buildings*, *40*(3), 394-398. <https://doi.org/10.1016/j.enbuild.2007.03.007>

- Rehman, A., & Jamil, F. (2021). Impact of urban residential location choice on housing, travel demands and associated costs: Comparative analysis with empirical evidence from Pakistan. *Transportation research interdisciplinary perspectives*, 10, 100357.
- Sengupta, U., & Tipple, A. G. (2007). The performance of public-sector housing in Kolkata, India, in the post-reform milieu. *Urban Studies*, 44(10), 2009-2027.
- Sinha, R. C., Sarkar, S., & Mandal, N. R. (2017). An overview of key indicators and evaluation tools for assessing housing quality: A literature review. *Journal of The Institution of Engineers (India): Series A*, 98, 337-347.
- Stupak, T. (18 de junio de 2024). *How Much Data Is Required To Train ML Models in 2024?*. Akkio. <https://www.akkio.com/post/how-much-data-is-required-to-train-ml#:~:text=Factor%20of%20Model%20Parameters&text=A%20suggested%20formulation%20is%20having,model%20complexity%20into%20data%20needs>
- Uzair, M., & Jamil, N. (2020, November). Effects of hidden layers on the efficiency of neural networks. In *2020 IEEE 23rd international multitopic conference (INMIC)* (pp. 1-6). IEEE.
- Wan, C., Shen, G. Q., & Choi, S. (2021). Underlying relationships between public urban green spaces and social cohesion: A systematic literature review. *City, culture and society*, 24, 100383.
- Waziri, B. S., Bala, K., & Bustani, S. A. (2017). Artificial neural networks in construction engineering and management. *International Journal of Architecture, Engineering and Construction*, 6(1), 50-60.
- Worden, K., Tsialiamanis, G., Cross, E. J., & Rogers, T. J. (2023). Artificial neural networks. In *Machine Learning in Modeling and Simulation: Methods and Applications* (pp. 85-119). Cham: Springer International Publishing.
- Xiang, P. C., & Luo, K. (2012). The evaluation for the behavioural risk of participants in construction projects based on back propagation neural network. *Advances in Information Sciences and Service Sciences*, 4(14), 97-107.




- Yahia, H., Hosny, H., & Razik, M. E. A. (2011). Time contingency assessment in construction projects in Egypt using artificial neural networks model. *International Journal of Computer Science Issues (IJCSI)*, 8(4), 523.
- Yarke, E. (Ed.). (2005). *Ventilación Natural De Edificios c/cd*. Nobuko.
- Yitmen, I., & Soujeri, E. (2010). An artificial neural network model for estimating the influence of change orders on project performance and dispute resolution. *Safety*, 9(3), 3-4.
- Zapata Cristancho, N. M., & Fagua Tuberquia, J. C. (2019). *Evaluación cualitativa de las condiciones de estabilidad estructural y funcionalidad de las edificaciones ubicadas en el barrio Coburgo del municipio de Fusagasugá–Cundinamarca* (Doctoral dissertation, Universidad Santo Tomás).
- Zin, M. R., Mansur, S. A., Bakri, A., & Caren, T. C. L. (2006). Predicting the performance of traditional general contract projects: a neural network based approach. *Proceedings of 6th APSEC*, 5-6.


## 8. ANEXOS

### 8.1 Anexo 1. Formulario de evaluación de la calidad de la edificación

# EVALUACIÓN DE LA CALIDAD DE UNA EDIFICACIÓN

Por favor evalúe los siguientes factores de la edificación que acaba de visitar con una valoración del 0 al 5 siendo 0 muy malo y 5 muy bueno. Si el rango de su evaluación está entre los dos grados adyacentes, entonces la asignación correspondiente será {0.5 ,1.5, 2.5, 3.5, 4.5}. Al final del formulario deberá poner su evaluación a la calidad de la edificación con valores del 1 al 5 siendo 1 muy mala calidad y 5 muy buena calidad.

francistellin95@gmail.com [Cambiar cuenta](#) 

 No compartido

\* Indica que la pregunta es obligatoria

#### F1 RESISTENCIA DE MATERIALES \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F2 ESTABILIDAD ESTRUCTURAL \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F3 PREVENCIÓN DE INCENDIOS \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F4 PREVENCIÓN CONTRA RIESGOS NATURALES \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F5 COSTO DE LA EDIFICACIÓN \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F6 COSTO DEL MANTENIMIENTO \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F7 DISPOSICIÓN ESPACIAL \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F8 VENTILACIÓN \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F9 ILUMINACIÓN \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F10 AISLAMIENTO ACÚSTICO \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F11 AISLAMIENTO TÉRMICO \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F12 UBICACIÓN \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F13 EQUIPAMIENTO URBANO \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5



F14 ÁREAS VERDES Y DE RECREACIÓN \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

F15 FORMA \*

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

**F16 ESTÉTICA \***

- 0
- 0.5
- 1
- 1.5
- 2
- 2.5
- 3
- 3.5
- 4
- 4.5
- 5

**EVALUACIÓN DE LA CALIDAD DE LA EDIFICACIÓN \***

- V1
- V2
- V3
- V4
- V5

Enviar

Borrar formulario